

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ  
РОССИЙСКОЙ ФЕДЕРАЦИИ

Федеральное государственное автономное  
образовательное учреждение высшего образования  
САНКТ-ПЕТЕРБУРГСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ  
АЭРОКОСМИЧЕСКОГО ПРИБОРОСТРОЕНИЯ

---

ПРИКЛАДНОЙ  
ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ:  
ПЕРСПЕКТИВЫ И РИСКИ

Международная научная конференция

17 октября 2024 г.

Сборник докладов

УДК 004.89  
ББК 32.813  
П75

П75 Прикладной искусственный интеллект: перспективы и риски: Международная научная конференция (СПб., 17 октября 2024 г.): сб. докл. – СПб.: ГУАП, 2024. – 432 с.

ISBN 978-5-8088-1975-7

DOI: 10.31799/978-5-8088-1975-7-2024

В октябре 2024 г. в Санкт-Петербургском государственном университете аэрокосмического приборостроения состоялась Международная научная конференция «Прикладной искусственный интеллект: перспективы и риски». В работе конференции приняли участие ведущие ученые и специалисты предприятий, преподаватели, научные сотрудники и аспиранты вузов со всего мира.

Статьи сборника отражают многогранные аспекты применения искусственного интеллекта в различных сферах деятельности. Представленные работы посвящены применению технологии искусственного интеллекта в аэрокосмическом приборостроении, инженерии, информационной безопасности и образовании, а также при разработке интеллектуальных интерфейсов, прикладных интеллектуальных и информационных систем.

Сборник предназначен для научных работников, аспирантов, докторантов и студентов старших курсов технических вузов.

УДК 004.89  
ББК 32.813

### Оргкомитет конференции

#### *Председатель оргкомитета:*

Ю. А. Антохина – доктор экономических наук, профессор, ректор Санкт-Петербургского государственного университета аэрокосмического приборостроения

#### *Заместитель председателя оргкомитета:*

Т. М. Татарникова – доктор технических наук, профессор, директор Института информационных технологий и программирования

#### *Члены оргкомитета:*

В. В. Фомин – доктор технических наук, профессор, профессор кафедры информационных систем и технологий

А. М. Сергеев – кандидат технических наук, доцент кафедры вычислительных систем и сетей

А. А. Востриков – кандидат технических наук, доцент кафедры вычислительных систем и сетей

Е. А. Яковлева – кандидат физико-математических наук, доцент, доцент кафедры прикладной информатики

Ю. В. Макарова – начальник отдела международного сотрудничества

М. Д. Поляк – старший преподаватель кафедры компьютерных технологий и программной инженерии

Ю. Бабюк – ассистент кафедры компьютерных технологий и программной инженерии

Б. К. Акопян – старший преподаватель кафедры прикладной информатики

ISBN 978-5-8088-1975-7  
DOI: 10.31799/978-5-8088-1975-7-2024

© Санкт-Петербургский государственный университет аэрокосмического приборостроения, 2024

## Уважаемые участники Международной конференции «Прикладной искусственный интеллект: перспективы и риски»!



Рада приветствовать вас в стенах Санкт-Петербургского государственного университета аэрокосмического приборостроения (ГУАП) – организатора конференции, которая проводится при поддержке Министерства науки и высшего образования Российской Федерации, Комитета по науке и высшей школе Правительства Санкт-Петербурга, акционерного общества «Электронная компания „ЭЛКУС“», журнала «Информационно-управляющие системы».

ГУАП является ведущим многопрофильным техническим университетом и активным участником программы стратегического академического лидерства «Приоритет 2030». В программе своего развития ГУАП фокусируется на четырех ядерных направлениях, среди которых «Информационные технологии и искусственный интеллект» служит основой создания конкурентоспособных продуктов и сервисов в профильных для ГУАП областях. Освоение информационных технологий и изучение методов искусственного интеллекта – неотъемлемая часть образовательных программ всех

уровней обучения, реализуемых ГУАП. Отмечается рост научных работ, защищаемых на тему прикладного искусственного интеллекта.

В то же время понятны риски, связанные с развитием искусственного интеллекта, такие как потеря управления объектом, безопасность данных, создание фейков и дезинформация, деградация общества в результате передачи интеллектуальных функций искусственному интеллекту. Поэтому эта конференция может стать площадкой для обсуждения не только перспектив использования искусственного интеллекта во благо общества, но и рисков его быстрого развития.

Направления конференции охватывают широкий спектр применения технологий искусственного интеллекта: в аэрокосмическом приборостроении и инженерии, в образовании, при разработке интеллектуальных интерфейсов, создании интеллектуальных и информационных систем, в информационной безопасности. На участие в конференции откликнулись разные отраслевые организации, научно-исследовательские институты и вузы Российской Федерации, Беларуси и Узбекистана, подготовив более ста докладов.

Надеюсь, каждый участник конференции найдет интересную дискуссию при работе в секциях, единомышленников и новых друзей. И пусть идея конференции «Создай с разумом» станет новым принципом применения искусственного интеллекта.

**Ю. А. Антохина,**  
**доктор экономических наук, профессор,**  
**ректор Санкт-Петербургского государственного**  
**университета аэрокосмического приборостроения**



# ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В АЭРОКОСМИЧЕСКОМ ПРИБОРОСТРОЕНИИ И ИНЖЕНЕРИИ

УДК 004.9

*Ю. А. Антохина\**

доктор экономических наук, профессор

*Т. М. Татарникова\**

доктор технических наук, профессор

*М. Ю. Охтилев\**

доктор технических наук, профессор

*В. Н. Коромысличенко\**

кандидат технических наук

*П. А. Охтилев\**

кандидат технических наук

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ИНТЕЛЛЕКТУАЛЬНАЯ ТЕХНОЛОГИЯ ЦИФРОВИЗАЦИИ ИНФОРМАЦИОННО-АНАЛИТИЧЕСКОГО ОБЕСПЕЧЕНИЯ ЖИЗНЕННОГО ЦИКЛА РАКЕТНО-КОСМИЧЕСКОЙ ТЕХНИКИ

Рассматриваются вопросы создания, применения и развития современных систем информационно-аналитического обеспечения жизненного цикла сложных технических объектов на примере ракетно-космической техники. В основе подобных систем лежат концепции единого информационного пространства и интеллектуального управления жизненным циклом киберфизических объектов. Рассмотрены методологические и организационно-технические основы создания интеллектуальной технологии информационно-аналитического обеспечения жизненного цикла на базе единого информационного пространства при создании отечественных космических средств.

**Ключевые слова:** искусственный интеллект, жизненный цикл, ракетно-космическая техника.

*Yu. A. Antokhina\**

Dr. Sc., Economic, Professor

*T. M. Tatarnikova\**

Dr. Sc., Tech., Professor

*M. Yu. Okhtilev\**

Dr. Sc., Tech., Professor

*V. N. Koromyslichenko\**

PhD, Tech.

*P. A. Okhtilev\**

PhD, Tech.

\*St. Petersburg State University of Aerospace Instrumentation

## INTELLIGENT TECHNOLOGY OF DIGITALIZATION OF INFORMATION AND ANALYTICAL SUPPORT OF LIFE CYCLE OF SPACE TECHNOLOGY

The issues of creation, application and development of modern systems of information-analytical life-cycle support of complex technical objects are considered on the example of missile and space technology. The concepts of a single information space and intelligent management of the cyber-physical objects life cycle lie at the basis of such systems. Methodological and organizational-technical bases for the creation of intelligent information and analytical technology for life cycle support on the basis of a common information space in the creation of domestic space assets were considered.

**Keywords:** artificial intelligence, life cycle, rocket-space technology.

### Введение

Значимой задачей цифровой экономики является задача управления жизненным циклом (ЖЦ) ее объектов. Решения задач управления ЖЦ лежат в русле парадигмы искусственного интеллекта и определяются возможностями инженерии знаний [1–5]. В этой связи сквозная технология информационно-аналитического обеспечения ЖЦ может быть создана на базе модели трансформации *данные – информация – знания – решения* путем:

➤ **интеграции, включающей:**

– формирование спецификаций и унифицированных предметных посредников информационного взаимодействия;

- реализацию защищенного взаимодействия со смежными ИС;
- загрузку и консолидацию данных из разнородных информационных ресурсов;
- формирование согласованных хронологических наборов данных;
- унификацию интерфейсов и форматов данных;
- **оперативного и долговременного хранения, то есть:**
  - управления оперативным и долговременным хранением;
  - поддержки единой информационной модели, управление метаданными;
  - кластеризации и каталогизации данных;
  - поддержки гибридных и разнотипных моделей данных;
  - классификации и оптимизации структур данных;
  - управления базами данных и знаний;
- **интеллектуального анализа данных за счет:**
  - извлечения, формализации и использования экспертных знаний;
  - оперативной аналитической обработки (OLAP);
  - мониторинга состояния в реальном времени;
  - ретроспективного анализа данных и предиктивной аналитики;
  - комплексного имитационно-аналитического моделирования;
  - автоматического синтеза аналитических сервисов;
- **информационной поддержки принятия решений, включая:**
  - поддержку управления планированием работ на всех этапах ЖЦ;
  - статистический ретроспективный анализ и логико-динамический вывод оценок и рекомендаций;
  - формирование и вывод оптимальных/квазиоптимальных альтернатив решений;
  - обоснование /объяснение сформированных выводов и решений;
  - генерацию аналитических отчетов;
- **организации доступа и взаимодействия с использованием:**
  - интерактивной визуализации (инфографика, таблицы, тренды, 2D-, 3D-мнемосхемы);
  - пространственной визуализации (интеграции с ГИС);
  - обобщенной аналитической панели;
  - предметно ориентированных интерфейсов доступа;
  - интеллектуального поиска и фильтрации по множеству данных.

Задачи, решаемые в процессе информационно-аналитического обеспечения ЖЦ включают:

- автоматизацию процессов информационно-аналитического обеспечения ЖЦ СТО на основе системного анализа, формирования оптимального облика и создания унифицированного комплекса инструментальных средств и информационных технологий (единой цифровой платформы);
- интеграцию и каталогизацию данных и знаний о ЖЦ объектов СТО и о технологических процессах их создания и применения на основе онтолого-ориентированных моделей с целью формирования их **цифровых двойников**;
- организацию защищенного единого информационного пространства участников интегрированной системы информации – СТО, частей и организаций ВКС (КВ) и предприятий РКП с целью обеспечения их автоматизированного информационного взаимодействия по целевым вопросам, связанным с повышением уровня технического состояния и надежности СТО;
- оперативное обеспечение потребителей – участников интегрированной системы информации – наиболее полной актуальной и достоверной информацией о техническом состоянии СТО и связанных с ними технологических процессах на всех этапах ЖЦ;
- обеспечение сквозной и замкнутой технологии информационно-аналитического обеспечения представителей организаций различных ведомств, связанных с ЖЦ СТО;
- поддержку, совершенствование и интеграцию системы информации о техническом состоянии и надежности СТО на основе автоматизации информационно-аналитической поддержки ЖЦ СТО и формирования нормативной-правовой базы межведомственного информационного взаимодействия.

Под жизненным циклом объектов космических средств ( $O_{кр}$ ) будем понимать последовательность стадий существования данного вида сложных технических объектов (СТО) от этапа замысла их облика до снятия с эксплуатации (утилизации и/или повторного использования отдельных компонент) [2; 3; 5–8]. Анализ показывает, что при правильной скоординированной работе в рамках системы информационно-аналитического обеспечения ЖЦ СТО соответствующие технологии и модели информационно-аналитического обеспечения ЖЦ позволят, во-первых, на конструктивной основе повысить эффективность процессов управления сложным объектом в пространстве его состояний, с точки зрения конечного результата – качества выпускаемой предприятием продукции, и, во-вторых, указанные технологии в наибольшей степени влияют на совокупную стоимость владения выпускаемой продукцией, включающей суммарные затраты на этапе проектирования, производства, эксплуатации и утилизации [8].

За рубежом процессы и технологии информационно-аналитического обеспечения ЖЦ ассоциируются с информационными технологиями и системами (ИТ и ИС) класса Product Lifecycle Management (PLM). Системы класса PLM в первую очередь ориентированы на конечный результат – производство СТО в требуемые сроки и с нужным качеством, а также гармонизированное с пожеланиями заказчика его сервисное обслуживание. Для этого в рамках PLM организуется управление определенной совокупностью процессов, обеспечивающих решение задач формирования и поддержания *единого информационного пространства* (ЕИП) на всех этапах ЖЦ СТО [1; 8; 11].

Особая актуальность и необходимость создания в настоящее время ЕИП вызвана тем, что разные объекты и системы, информационно-аналитического обеспечения ЖЦ СТО имеют различный состав и структуры исходных и результирующих данных. На рис. 1 показано, как исходные и выходные данные (а, в общем случае знания) об изделии (в нашем случае ОКСР), а также о выполняемых процессах и расходуемых ресурсах совместно используются объектами и субъектами, участвующими в его ЖЦ.

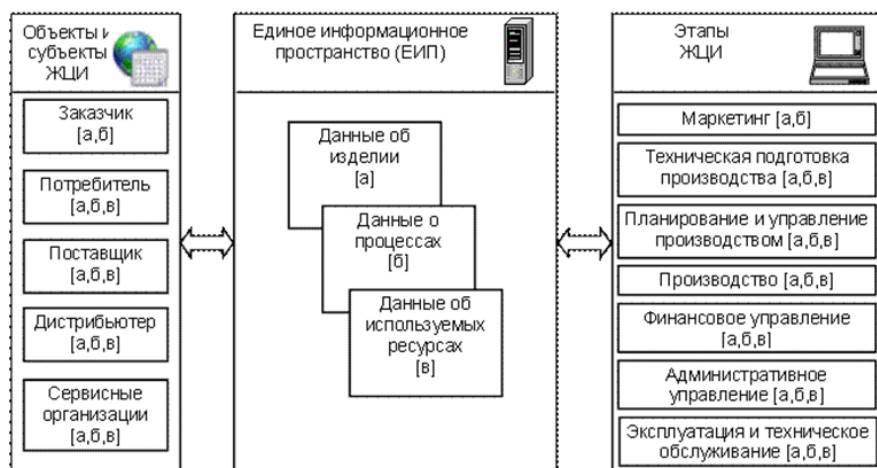


Рис. 1. Совместное использование данных (информации, знаний) об изделиях, процессах и ресурсах на различных стадиях ЖЦ СТО (в том числе ОКСР) [6]

Для того чтобы на конструктивном уровне реализовать указанные процессы информационного взаимодействия, необходимо, во-первых, создание формализованных моделей (математических, логико-алгебраических, логико-лингвистических, комбинированных), описывающих состав, структуру, технологии создания, использования, послепродажного обслуживания соответствующих СТО, и, во-вторых, наличие методов, алгоритмов, методик манипулирования указанными моделями. Кроме того, в каждом конкретном случае (для каждого конкретного СТО) должны быть четко определены цели, задачи внедрения PLM-системы, а также те количественные и качественные показатели, с помощью которых можно будет оценить эффективность внедрения данной системы.

### Методологические и организационно-технические основы создания единого информационного пространства ракетно-космической отрасли промышленности РФ

При формировании ЕИП центральными проблемами были и остаются проблемы интероперабельности, интеграции данных, информации и знаний о соответствующей проблемной области. В качестве целей создания ЕИП обычно полагают [1; 8; 9; 11; 12]: расширение возможностей пользователей по прозрачному, компетентному доступу к пространственно-распределенным информационным ресурсам (ИР); расширение возможностей пользователей по распространению, хранению, визуализации и обработке ИР; обеспечение полноты, актуальности и точности ИР, хранимых и потребляемых пользователями; предоставление пользователям новых возможностей по производству знаний.

Обобщенная структурно-функциональная схема единого информационного пространства, которая может быть положена в основу его построения, представлена на рис. 2.

Основу ЕИП составляют метаданные (мета-схема ЕИП), представляющие собой формальное описание обобщенной информационной модели данных и знаний, циркулирующих в ЕИП. Метаданные используются для описания и автоматизированного анализа содержимого ИР, построения поисковых индексов и позволяют обеспечить высокую точность и эффективность выбора разнотипной информации.

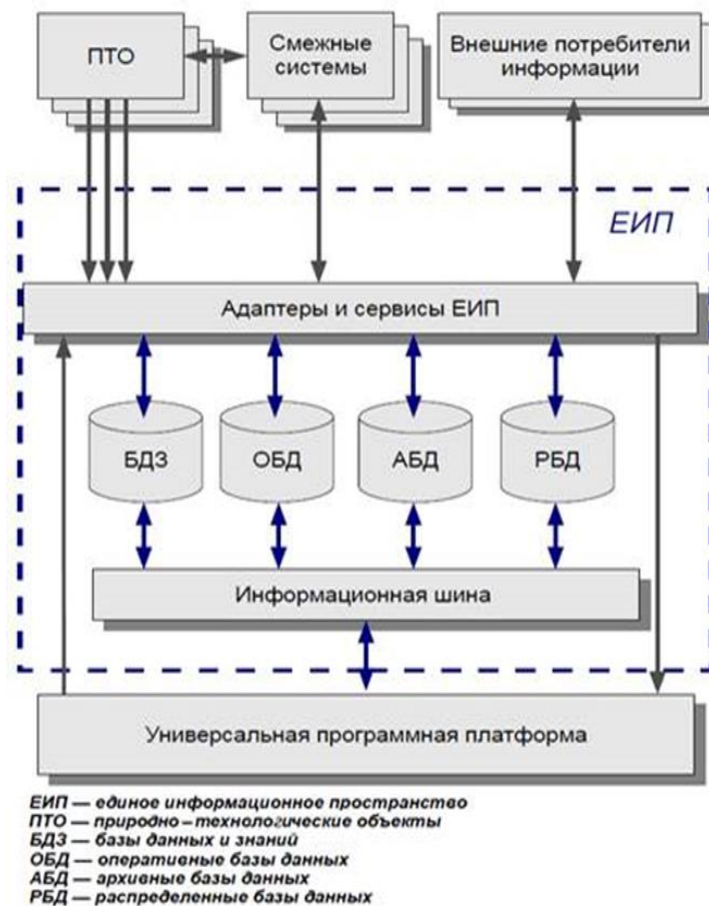


Рис. 2. Обобщенная структурно-функциональная схема ЕИП

Метасхема ЕИП определяет термины и семантику описания и применения обобщенной информационной модели и должна обеспечивать [8–19]: описание объектов инфраструктуры ЕИП с перечнем атрибутов и отношений между объектами; **синтаксическую interoperability** – описание типов данных, форматов и моделей различных информационных ресурсов на основе согласованных унифицированных подходов и стандартов; **семантическую interoperability** – создание и согласование стандартных прикладных профилей метаданных и онтологий, относящихся к различным предметным областям (ПрО), что позволяет упростить интеграцию разнообразных систем, автоматизацию обмена метаданными, их обработку и преобразование; **открытость** – доступ к соответствующей информации по описаниям (мета-элементам); **расширяемость** – возможность детализации описаний и добавление новых метаданных; **уникальную идентификацию** информации и объектов инфраструктуры – возможность установления взаимосвязей между ресурсами разных информационных источников распределенной среды, способность объединять связанные данные отдельных репозиториях в виртуально-единые ресурсы; **возможности интеграции информации** (при расширении/добавлении объектов ЕИП) на основе использования существующих информационных стандартов.

Для формирования ЕИП целесообразно использовать распределенную базу данных и знаний (РБД/З), состоящую из набора узлов, связанных коммуникационной сетью с переменной топологией (см. рис. 2).

В рамках ЕИП применительно к космической сфере в РФ в настоящее время создается единый виртуальный электронный паспорт (ЕВЭП) – цифровой двойник (ЦД), цифровая нить – разработка-производство-эксплуатация. Указанный ЦД представляет собой совокупность средств и методов сбора, обработки, обмена, хранения, поиска и представления информации, функционирующих на единых принципах и по общим правилам, которым пользуются как заказчики ОКСР, так и те, кто осуществляют их проектирование, изготовление, испытания, эксплуатацию и использование результатов космической деятельности в рамках, соответствующих АСУ ОКСР.

ЦД-ЕВЭП предназначен для своевременного обеспечения предприятий и организаций, участвующих в проектировании, производстве, испытаниях и эксплуатации ОКСР, актуальной информацией, необходимой для выполнения работ по обеспечению и повышению уровня технического состояния и надежности ОКСР и входящих в его состав изделий на всех этапах их жизненного цикла.



## Заключение

Эффективное использование существующего перспективного задела из новейших научно-технических разработок в процессах управления жизненным циклом  $O_{КСР}$  обеспечивается разработкой и повсеместным внедрением технологий ЕИП и соответствующих систем поддержки принятия решений (СППР) на базе ЦД-ЕВЭП. Цель их создания – сокращение сроков разработки и производства новых космических средств и технологий, а также повышение их качества путем формирования качественно новой среды деятельности руководителей, ученых, инженеров, конструкторов, технологов и производственников ракетно-космической отрасли промышленности РФ. Предварительные исследования показывают, что внедрение ЕИП и СППР в существующие и перспективные СУ ЖЦ  $O_{КСР}$  позволит: снизить воздействие серьезных рисков на ранних стадиях проектов создания новых поколений  $O_{КСР}$ , что ведет к минимизации затрат на их устранение; осуществлять в реальном времени мониторинг ключевых индикаторов результативности и эффективности процессов управления ЖЦ  $O_{КСР}$ ; выявлять и идентифицировать нештатные и предкризисные ситуации в рабочих процессах по всем фазам жизненного цикла; минимизировать негативное влияние «человеческого фактора»; широко использовать технологии комплексного моделирования для непрерывного тестирования принимаемых решений; своевременно обнаруживать конфликты и противоречия между целями, требованиями, моделями и текущими результатами конкретных проектов в рамках программ создания новых поколений  $O_{КСР}$ .

## Библиографический список

1. *Охтилев М. Ю., Соколов Б. В., Юсупов Р. М.* Интеллектуальные технологии мониторинга и управления структурной динамикой сложных технических объектов. М.: Наука, 2006.
2. Теоретические основы проактивного управления сложными объектами / М. Ю. Охтилев, Н. Г. Мустафин, В. Е. Миллер, Б. В. Соколов // Известия вузов. Приборостроение. 2014. Т. 57, № 11. С. 7–15.
3. *Черняк Л.* От адаптивной инфраструктуры – к адаптивному предприятию // Открытые системы. 2004. № 9. С. 30–35.
4. *Татарникова Т. М.* Системы искусственного интеллекта: учеб. для студентов высших учеб. заведений, обучающихся по направлению подготовки бакалавриата 09.03.02 «Информационные системы и технологии» / М-во науки и высшего образования Рос. Фед., Федер. гос. автоном. образоват. учреждение высшего образования С.-Петерб. гос. ун-т аэрокосм. приборостроения. СПб.: ГУАП, 2024. 300 с.
5. Основы искусственного интеллекта: учеб. пособие / Ю. А. Антохина, А. А. Оводенко, М. Л. Кричевский, Ю. А. Мартынова; М-во науки и высшего образования Рос. Фед., Федер. гос. автоном. образоват. учреждение высшего образования С.-Петерб. гос. ун-т аэрокосм. приборостроения. СПб.: ГУАП, 2022. 169 с.
6. *Кульга К. С.* Автоматизация технической подготовки и управления производством на основе PLM-системы. М.: Машиностроение, 2008. 256 с.
7. *Стародубов В.А.* Управление жизненным циклом изделий, от концепции до реализации. СПб., 2006. С. 120.
8. *Дмитриев А.* Сервис-ориентированная архитектура в современных моделях бизнеса. М.: ДК, 2006. 221 с.
9. *Калиниченко Л. А.* Методы и средства интеграции неоднородных баз данных / под ред. Л. Н. Королева. М.: Наука. Глав. ред. физ.-мат. лит., 1983. 424 с.
10. Интегрированные модели и мягкие вычисления в искусственном интеллекте: сб. науч. тр. VIII Междунар. науч.-техн. конф. (Коломна, 18–20 мая, 2015): в 2 т. Т. 2. М.: Физматлит, 2015. 388 с.
11. OWL Web Ontology Language Overview. 2004. URL: <http://www.w3.org/TR/owlfeatures/> (дата обращения: 09.09.2024).
12. *Коголовский М. Р.* Перспективные технологии информационных систем. М.: ДМК Пресс, 2003. 288 с.
13. *Steinburg A. N., Bowman C. L., White F. E.* Revisions to the JDL Data Fusion Model. Presented at the Joint NATO/IRIS Conference. Quebec, 1998.
14. *Stark J.* Product Lifecycle Management: Paradigm for 21st Century Product Realisation. Springer, 2004.
15. Product lifecycle management and information tracking using smart embedded systems. URL: <http://www.promise.no/> (дата обращения: 09.09.2024).
16. Maintenance: Changing Role in Life Cycle Management / S. Takata, F. Kimura, F. J. A. M. van Houten [et al.] // CIRP annals. 2004. Vol. 53, № 2. P. 643–655.
17. *Moubray J.* Reliability-centered maintenance. N. Y.: Industrial Press Inc. 2000. 420 p.
18. DynaWeb is an e-maintenance solution to future sustainable industrial and societal challenges. URL: <https://cris.vtt.fi/en/> (дата обращения: 09.09.2024).
19. Актуальные научно-технические проблемы разработки и внедрения взаимосвязанного комплекса унифицированных интегрированных систем поддержки принятия решений (СППР) в АСУ объектами военно-государственного управления / П. Н. Автамонов, М. Ю. Охтилев, Б. В. Соколов, Р. М. Юсупов // Известия ЮФУ. Технические науки. 2014. № 3(152). С. 14–26.

*А. С. Аминова*

инженер

Всероссийский научно-исследовательский институт метрологии имени Д. И. Менделеева, Санкт-Петербург, Россия

## МЕТРОЛОГИЧЕСКАЯ ЭКСПЕРТИЗА ПРОЕКТОВ СТАНДАРТОВ: ПЕРСПЕКТИВА РАЗРАБОТКИ НЕЙРОННОЙ СЕТИ ДЛЯ АВТОМАТИЗАЦИИ ПРОЦЕССА

Рассматривается возможность автоматизации метрологической экспертизы проектов стандартов. Акцент сделан на значимости этой задачи в связи с увеличением объема стандартов, связанных с развитием цифровых технологий. Автор предлагает разработку экспертной системы на основе нейронной сети для выявления ошибок и несоответствий в документации. В работе представлены наиболее распространенные виды нарушений в проектах стандартов, описана структура экспертной системы, а также процесс ее обучения и тестирования. Применение экспертной системы позволит автоматизировать процесс экспертизы, сократить время на проверку стандартов и повысить их надежность.

**Ключевые слова:** метрологическая экспертиза, автоматизация, экспертная система, нейронная сеть, проекты стандартов.

*A. S. Aminova*

Engineer

D. I. Mendeleev Institute for Metrology, St. Petersburg, Russia

## METROLOGICAL EXAMINATION OF DRAFT STANDARDS: THE PROSPECT OF DEVELOPING A NEURAL NETWORK FOR PROCESS AUTOMATION

The study considers the possibility of automating metrological expertise of draft standards. Emphasis is placed on the importance of this task in view of the increasing number of standards associated with the development of digital technologies. The author proposes to develop an expert system based on a neural network for detecting errors and inconsistencies in documentation. The paper presents the most common types of violations in draft standards, describes the structure of the expert system and the process of its training and testing. The use of an expert system will automate the process of expertise, reduce the time for verification of standards and increase their reliability.

**Keywords:** metrological expertise, automation, expert system, neural network, draft standards.

### Введение

Стремительно растущее количество документов национальной стандартизации в связи с развитием цифровых технологий индустрии 4.0 создает значительные трудности для метрологической экспертизы, проводимой экспертами. Для повышения качества и эффективности метрологической экспертизы необходима автоматизация этого процесса.

Согласно Программе национальной стандартизации на 2024 г. (ПНС-2024) [1] предусмотрена разработка и подготовка к утверждению более чем 4900 документов по стандартизации, из которых 913 составляют национальные стандарты Российской Федерации (ГОСТ Р). Это на 17% больше, чем в 2023 г., когда количество документов по стандартизации составляло чуть более 4200 [2]. От качества проведения метрологической экспертизы документации зависят надежность и точность будущего объекта стандартизации. Невыявленные наиболее значимые метрологические несоответствия могут повлечь за собой выпуск некачественной продукции, которая впоследствии приведет к материальным потерям предприятия, авариям оборудования и рискам для здоровья и жизни людей.

В исследовании [3] проанализирован процесс метрологической экспертизы технической документации и предложено несколько направлений улучшения процесса, такие как информационное, программное и процессное, которые могут применяться только комплексно. Похожие подходы предлагает Хорошева [4], акцентируя внимание на том, что они устраняют нарушения в документации в виде неверного назначения средств измерений, методик измерения и контроля. Шкаруба и Минакова [5] приводят общую модель процесса метрологической экспертизы, предлагая разработку методики на проведение метрологической экспертизы. В области качества ставится акцент на экспертной системе, подразумевающей под собой вспомогательный инструмент с огромным массивом данных [6]. Для проведения метрологической экспертизы необходимо обладать знаниями в области теоретической, прикладной и законодательной метрологии [7].

Хотя проблема некачественного проведения метрологической экспертизы подробно изучена, предложенные методы ее решения до сих пор не реализованы. Авторы не показали, как именно можно было бы автоматизировать процесс метрологической экспертизы без непосредственного участия людей.

Настоящее исследование предлагает создание экспертной системы на основе нейронной сети для автоматизации процесса метрологической экспертизы и впоследствии устранения возможных нарушений в проектах

стандартов. Обладая способностью обучаться и принимать решения, опираясь на свои «знания», нейронные сети открывают перспективные возможности для повышения качества выпускаемых проектов стандартов и оптимизации процессов стандартизации.

В данной статье представлены наиболее часто встречающиеся метрологические несоответствия при разработке проектов стандартов и вытекающие из них задачи, которые должна решать экспертная система на основе нейронной сети, описаны структура экспертной системы и метод ее реализации.

## 1. Анализ несоответствий в проектах стандартов

Метрологическая экспертиза подразумевает анализ задач, поставленных в документации, и оценку их решения, предложенного разработчиками, а именно: контроль выполнения обязательных метрологических требований, оценивание выбора состава измеряемых параметров, выбора норм точности, средств и методик измерений, области применения, влияющих факторов, используемой терминологии и т. д. Процесс создания экспертной системы на основе нейронной сети для автоматизации процесса метрологической экспертизы включает этап составления перечня типичных нарушений, которые могут возникнуть в результате некачественной разработки проектов стандартов и которые необходимо устранить. Далее будут представлены потенциальные причины таких нарушений.

Возможные виды несоответствий во время проведения метрологической экспертизы проектов стандартов:

- требования и правила, установленные в проекте стандарта, противоречат Конституции РФ, федеральным законам, актам Президента РФ, актам Правительства РФ и т. д.;
- дублирование требований/положений других основополагающих документов в области стандартизации, например по этой же тематике;
- несоответствие содержания проекта стандарта современному уровню развития науки, техники и технологий, передовому отечественному и зарубежному опыту;
- неверный выбор средств и методов измерений;
- значения показателей качества и норм безопасности ниже установленных в действующих стандартах;
- несоблюдение правил изложения и оформления проекта стандарта требованиям таких основополагающих стандартов, как ГОСТ Р 1.5-2012 и ГОСТ 1.5-2001;
- отсутствие специфических требований, свойственных объекту стандартизации проекта стандарта;
- несоответствие наименования проекта стандарта его содержанию;
- наличие орфографических и пунктуационных ошибок в тексте проекта стандарта;
- необоснованное использование придуманной терминологии;
- адаптация определений известных терминов не с их детализацией или уточнением, а с приданием им искаженного смысла.

Автор данной статьи участвует в проведении метрологической экспертизы проектов стандартов, подготавливаемых в рамках Технического комитета (ТК) по стандартизации № 164 «Искусственный интеллект». В процессе экспертизы иногда встречаются недобросовестные разработчики проектов стандартов, выпускающие серию стандартов по определенной тематике. Очень грубое нарушение с их стороны состоит в том, что содержание или отдельные положения одного проекта стандарта дублируют содержание или отдельные положения другого проекта стандарта из этой же серии проектов стандартов. Причем разработчик обоих стандартов – одна и та же организация. В процессе работы автор сталкивался с дублированием серии стандартов, разработанных одной организацией. При выявлении данного вида нарушения уходит много времени на сравнение проектов, создаются отдельные файлы с таблицей на несколько страниц для сравнения положений проектов.

Качество проводимой метрологической экспертизы зависит от уровня квалификации эксперта [8; 9]. Поэтому невыявленные нарушения могут быть вызваны различными причинами:

- неполнота знаний, опыта и подготовки эксперта;
- недостаточная сосредоточенность и внимание эксперта;
- некомпетентность эксперта в определенной области.

Таким образом, разработанная экспертная система, которая в значительной степени заменяет эксперта, могла бы решить ряд упомянутых проблем.

## 2. Концепция экспертной системы на основе нейронной сети

К 2024 г. нейронные сети, созданные на основе машинного обучения, продемонстрировали возможность их применения в различных областях, например распознавание людей, обработка естественного языка, анализ изображений и т. д. Использование нейронных сетей в метрологии позволяет автоматизировать решение таких задач, как анализ данных, создание систем предиктивного обслуживания оборудования, расчет неопределенности и т. д. После обучения нейронной сети на основе больших массивов данных она научится выявлять сложные закономерности и взаимосвязи, что впоследствии позволит автоматизировать процесс принятия решений и прогнозирования.

Экспертная система на основе нейронной сети, выполняющая метрологическую экспертизу проектов стандартов, должна содержать базу данных стандартов государственной системы обеспечения единства измерений, нормативные правовые акты Российской Федерации, средств измерений, стандартных образцов, эталонную базу, которые имеются в открытом доступе.

Для того чтобы нейронная сеть могла распознавать документы, могут использоваться машинопонимаемые стандарты, которые содержат текстовые и цифровые данные. Такими документами могут быть Smart-стандарты, представляющие совокупность данных, имеющихся в документе по стандартизации, представленных в машиночитаемом, машиноинтерпретируемом и машинопонимаемом форматах. SMART-стандарт является объектом информационной системы и представляет собой контейнер структурированных и неструктурированных данных, полученных в результате обработки автоматизированными средствами [10].

Основными задачами экспертной системы на основе созданной нейронной сети могут быть:

1) сбор и хранение данных – в качестве данных могут выступать документы в области стандартизации (ФЗ, ГОСТ, ГОСТ Р, общероссийские классификаторы, своды правил и т. д.), иная нормативная и рекомендательная документация (например, правила и рекомендации по стандартизации, метрологии, сертификации, аккредитации), сведения о средствах измерений (СИ) (использование системы ФГИС «Аршин») и т. д.;

2) дообучение – обновление данных посредством дополнения базы данных экспертной системы;

3) анализ (диагностика) данных, полученных для метрологической экспертизы – включает методы распознавания (анализа) загруженной документации в экспертную систему;

4) расширение области применения экспертной системы – использование новых данных для работы не только с одним видом документов, но и с другими, например ТУ или отраслевые стандарты;

5) возможность корректировать документацию, которая была подвергнута метрологической экспертизе, на основе ошибок, выявленных экспертной системой, с помощью решения пользователя (разработчика проекта стандарта).

Безусловно, экспертная система пока не сможет принимать решения самостоятельно, ответственность за окончательный вердикт будет лежать на эксперте.

В связи выдвинутыми задачами экспертной системы ее структура состоит из элементов, представленных на рис. 1.

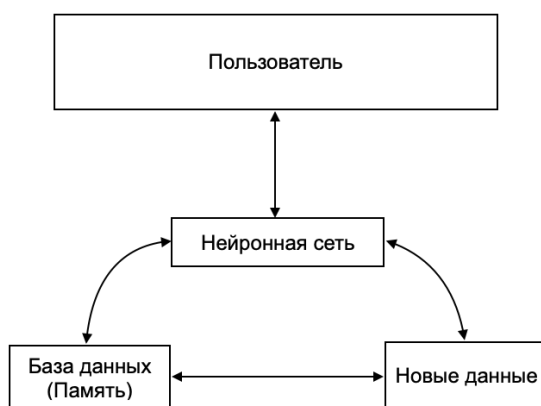


Рис. 1. Структура экспертной системы на основе нейронной сети

База данных содержит в памяти документы, требования которых необходимо учесть при проведении метрологической экспертизы для того, чтобы указать разработчику на несоответствия/ошибки в проекте стандарта, которые он не учел. Новые данные необходимы для дообучения экспертной системы, например получение дополнительных данных о новых утвержденных стандартах или замене с течением времени стандартов, утративших силу. Для работы с новыми видами документов также необходимы новые данные. Сама нейронная сеть управляет данными и взаимодействует непосредственно с пользователем через интерфейс.

На рис. 2 показан алгоритм обучения и тестирования нейронной сети предлагаемой экспертной системы. На вход нейронной сети подаются проекты стандартов. В зависимости от поставленной задачи необходимы разные обучающие данные. На основе поступающих на вход документов обучается нейронная сеть. На выходе пользователь через интерпретатор получает документ с выделенными исправлениями и найденными несоответствиями.

После обучения нейронной сети необходимо проанализировать производительность и точность результатов ее работы, чтобы оценить, насколько эффективно система выполняет поставленные задачи. Для этого необходимо собрать тестовую выборку, которая не использовалась при обучении. Эти данные должны быть размечены вручную, чтобы сравнить на выходе результаты работы нейронной сети с эталонным документом. В зависимости от типа задач выбираются различные метрики, например доля правильных исправлений среди предложенных, доля найденных ошибок среди всех имеющихся ошибок или доля правильно найденных дублирований среди всех возможных. Для оценки производительности можно рассмотреть время, которое требуется на обработку одного документа или набора документов, и объем памяти, необходимый для обработки текста.

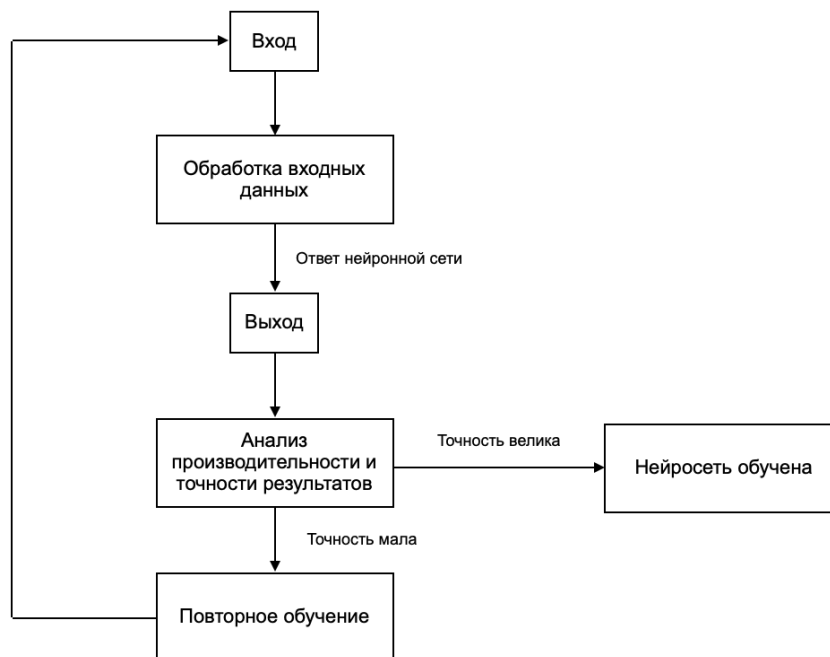


Рис. 2. Алгоритм обучения и тестирования нейронной сети

### 3. Преимущества и проблемы экспертной системы

Автоматизация метрологической экспертизы проектов стандартов предлагает ряд возможностей, таких как повышение эффективности и результативности процесса метрологической экспертизы, повышение качества разработанных документов, согласованность и непротиворечивость документов в области стандартизации. Снижая вероятность ошибок метрологической экспертизы, обычно осуществляемой экспертом (только человеком), автоматизированная экспертная система может ускорить процесс разработки документов в области стандартизации, позволяя утверждать больше документов, чем обычно может выпускаться при взаимодействии только с экспертом. Кроме того, экспертная система может повысить точность и надежность информации в проектах стандартов.

Однако при разработке и применении нейронной сети для экспертизы проектов стандартов может возникнуть несколько основных проблем:

- 1) для качественного обучения модели потребуется большой объем данных, которые могут быть труднодоступными, особенно если они связаны с конкретными техническими стандартами;
- 2) экспертная система может хорошо работать с базой данных, на которой она обучалась, но может плохо реагировать на новые, особенно если в них содержатся формулировки или закономерности, не встречавшиеся ранее;
- 3) тексты стандартов могут быть сложными и неоднозначными, что затрудняет автоматическое понимание их смысла нейронной сетью. Сложные конструкции, многоуровневые предложения и специфическая терминология могут вызывать трудности в корректном анализе.

Решение каждой из этих проблем требует внимания на этапе разработки, тестирования и эксплуатации нейронной сети. Постоянный мониторинг производительности и точности экспертной системы, а также обновление и улучшение алгоритмов могут минимизировать возникающие трудности.

### Заключение

На момент выпуска статьи в ГНЦ ФГУП «ВНИИМ им. Д. И. Менделеева» реализуется разработка экспертной системы с дальнейшей возможностью автоматизации метрологической экспертизы на основе нейронной сети с помощью машинного обучения. Написание кода для создания экспертной системы осуществляется с помощью чат-бота с искусственным интеллектом ChatGPT и программистов.

### Библиографический список

1. Приказ № 2279 от 31.10.2023 «Об утверждении Программы национальной стандартизации на 2024 год». URL: <https://www.rst.gov.ru/portal/gost/home/activity/documents/orders#/order/495368> (дата обращения: 07.07.2024).
2. Приказ № 2726 от 01.11.2022 «Об утверждении Программы национальной стандартизации на 2023 год». URL: <https://www.gost.ru/portal/gost/home/activity/standardization> (дата обращения: 08.07.2024).

3. *Минакова Н. П., Петухов А. Е.* Анализ и совершенствование метрологической экспертизы технической документации // Наука без границ. 2020. № 1(41). С. 36–41.
4. *Хорошева Ю. Н.* Пути улучшения метрологической экспертизы технической документации // Управление качеством на этапах жизненного цикла технических и технологических систем: сб. науч. тр. 2-й Всерос. науч.-техн. конф. Курск, 2020. С. 282–284.
5. *Шкаруба Н. Ж., Минакова Н. П.* Теоретические основы совершенствования метрологического обеспечения процесса разработки технической документации // Наука без границ. 2019. № 8(36). С. 32–36.
6. *Неруш К. С.* Концептуализация экспертной системы для метрологической экспертизы // Интеллектуальные информационные системы: тенденции, проблемы, перспективы: сб. науч. ст. 8-й Междунар. конф. Курск, 2020. С. 145–147.
7. *Посашкова А. Е.* Метрологическое обеспечение измерений // Мавлютовские чтения: сб. тр. XV Всерос. молодеж. науч. конф.: в 7 т. Т. 2. Уфа, 2021. С. 128–131.
8. *Неруш К. С., Маркво И. А.* Анализ факторов, влияющих на качество работ по проведению метрологической экспертизы. Качество продукции: контроль, управление, повышение, планирование // Качество продукции: контроль, управление, повышение, планирование: сб. науч. тр. 7-й Междунар. молодеж. науч.-практ. конф.: в 3 т. Т. 2. / отв. ред. Е. В. Павлов. 2020. С. 339–341.
9. *Гуминская И. Р., Малахова Ю. Г.* Применение FMEA-Анализа к процессу «Метрологическая экспертиза технической документации» // Актуальные проблемы авиации и космонавтики: сб. матер. VI Междунар. науч.-практ. конф., посвящ. Дню космонавтики: в 3 т. Т. 2 / под общ. ред. Ю. Ю. Логинова. Красноярск, 2020. С. 572–574.
10. Проект ПНСТ Умные (Smart) стандарты. Общие положения. URL: <https://docs.cntd.ru/document/728306620> (дата обращения: 10.08.2024).

*С. И. Беляев\**

студент

*П. М. Кузнецов\**

доктор технических наук, профессор – научный руководитель

\*Московский авиационный институт

## ПРИМЕНЕНИЕ ГЕНЕРАТИВНЫХ НЕЙРОСЕТЕЙ ДЛЯ ПОСТРОЕНИЯ ЦИФРОВЫХ ДВОЙНИКОВ В МЕЛКОСЕРИЙНОМ ПРОИЗВОДСТВЕ

В условиях растущей конкуренции и изменения потребительских предпочтений современная промышленность переходит от крупносерийного к мелкосерийному производству, что требует быстрой адаптации к изменяющимся условиям. Рассматривается роль цифровых двойников как инструмента, позволяющего анализировать и оптимизировать производственные процессы в реальном времени. Для оценки эффективности интеграции генеративного искусственного интеллекта с цифровыми двойниками предлагается сравнить распределения данных, сгенерированных различными методами: исходное распределение данных, генерация данных цифровым двойником без использования генеративного ИИ и генерация данных цифровым двойником с использованием генеративного ИИ. Для оценки предлагается использовать расстояние Кульбака – Лейблера и метрику Вассерштейна.

**Ключевые слова:** цифровые двойники, генеративный искусственный интеллект.

*S. I. Belyaev\**

Student

*P. M. Kuznetsov\**

Dr. Sc., Tech., Professor – Scientific Adviser

\*Moscow Aviation Institute

## APPLICATION OF GENERATIVE NEURAL NETWORKS FOR THE CONSTRUCTION OF DIGITAL TWINS IN SMALL SERIES PRODUCTION

In the face of growing competition and changing consumer preferences, modern industry is moving from large-scale to small-scale production, which requires rapid adaptation to changing conditions. The paper considers the role of digital twins as a tool to analyze and optimize production processes in real time. To evaluate the integration efficiency of generative artificial intelligence with digital twins, it is proposed to compare the distribution of data generated by different methods: initial distribution of data, data generation by digital twins without the use of generative AI and data generation by digital twins using generative AI. The Kulbakk – Leibler distance and Wasserstein metric are proposed for evaluation.

**Keywords:** digital twins, generative artificial intelligence.

Современная промышленность развивается в направлении перехода от крупносерийного производства к мелкосерийному, что обусловлено возрастанием конкуренции и увеличением индивидуализации потребительского спроса на продукцию. В этих условиях номенклатура продукции растет, а объем партий уменьшается. При этом время, необходимое для технологической подготовки производства с учетом уже имеющихся производственных заданий, начинает преобладать над другими аспектами времени перехода на выпуск новой продукции. Таким образом, возникает задача сокращения времени, затрачиваемого на поиск оптимальной загрузки оборудования [1].

В последние годы цифровые двойники стали важным инструментом в различных отраслях, включая оптимизацию мелкосерийного производства [2]. Цифровой двойник представляет собой виртуальную копию физического объекта или системы, которая позволяет моделировать, анализировать и оптимизировать процессы в реальном времени. Однако, несмотря на значительные преимущества, традиционные цифровые двойники могут сталкиваться с ограничениями, связанными с недостатком данных, сложностью моделирования и необходимостью адаптации к быстро меняющимся условиям.

С развитием технологий искусственного интеллекта (ИИ) и в частности генеративного искусственного интеллекта появилась возможность значительно улучшить функциональность и точность цифровых двойников.

Интеграция генеративного искусственного интеллекта с цифровыми двойниками открывает новые горизонты для сценарного моделирования и анализа данных [3]. Генеративный ИИ может генерировать синтетические данные, которые дополняют реальные данные, что особенно полезно в условиях ограниченного объема исходных данных. Это позволяет создавать более точные и надежные модели, которые могут адаптироваться к различным условиям и сценариям. Кроме того, генеративный ИИ может использоваться для создания различных производственных сценариев, что позволяет выявлять узкие места и оптимизировать процессы.

Среди различных подходов использования генеративного ИИ, подходящих для генерации синтетических данных при моделировании производственных процессов, можно выделить следующие.

1. Генеративно-сопоставительные сети (GAN). Генеративно-сопоставительные сети (GAN) представляют собой одну из наиболее популярных и мощных архитектур для генерации синтетических данных. GAN состоят из двух нейронных сетей: генератора и дискриминатора, которые обучаются совместно в процессе состязания. Генератор создает синтетические данные, пытаясь обмануть дискриминатор, который, в свою очередь, пытается отличить реальные данные от синтетических. Этот процесс приводит к тому, что генератор постепенно улучшает качество создаваемых данных. Применение GAN в цифровых двойниках может значительно улучшить качество синтетических данных, что позволяет создавать более точные и надежные модели [4]. GAN могут быть использованы для генерации различных сценариев производственных процессов, что помогает в выявлении узких мест и оптимизации.

2. Вариационные автокодировщики (VAE). Вариационные автокодировщики (VAE) являются еще одной мощной архитектурой для генерации синтетических данных. VAE состоят из двух основных компонентов: энкодера и декодера. Энкодер преобразует входные данные в латентное пространство, а декодер восстанавливает данные из этого латентного пространства. В отличие от традиционных автокодировщиков, VAE обучаются таким образом, чтобы латентное пространство имело конкретное распределение, что позволяет генерировать новые данные путем выборки из этого распределения. VAE могут быть использованы для создания синтетических данных, которые дополняют реальные данные, что особенно полезно в условиях ограниченного объема исходных данных. Это позволяет улучшить качество моделирования и прогнозирования в цифровых двойниках.

Для оценки эффективности интеграции генеративного искусственного интеллекта с цифровыми двойниками предлагается сравнить распределения данных, сгенерированных различными методами. В данной схеме рассматриваются три основных этапа: анализ исходного распределения данных, генерация данных цифровым двойником без использования генеративного ИИ и генерация данных цифровым двойником с использованием генеративного ИИ.

Предлагается использование расстояния Кульбака – Лейблера (формулы 1, 2) и метрики Вассерштейна для сравнения распределений данных, полученных при использовании цифрового двойника в процессе интеграции с моделями генеративного ИИ и без них:

$$D_{KL}(P \parallel Q_1) = \int_{-\infty}^{\infty} p(x) \log \frac{p(x)}{q_1(x)} dx, \quad (1)$$

$$D_{KL}(P \parallel Q_2) = \int_{-\infty}^{\infty} p(x) \log \frac{p(x)}{q_2(x)} dx, \quad (2)$$

где  $p(x)$  – плотность вероятности исходного распределения данных;

$q_1(x)$  – плотность вероятности распределения данных, сгенерированных цифровым двойником без использования генеративного ИИ;

$q_2(x)$  – плотность вероятности распределения данных, сгенерированных цифровым двойником с использованием генеративного ИИ.

### Библиографический список

1. *Тупнер Л. М., Исхакова Н. Р.* Проблемы организации в условиях единичного и мелкосерийного производства // Экономика и бизнес: теория и практика. 2019. № 5-3. С. 97–102.
2. *Следков Ю. Г., Хорошко Л. Л., Кузнецов П. М.* Управление бизнес-процессами в мелкосерийном производстве // СТИН. 2022. № 1. С. 29–33.
3. Integrating generative AI with network digital twins for enhanced network operations / K. Muhammad, T. David, G. Nassisid, T. Farus URL: arXiv preprint arXiv:2406.17112 (2024) (дата обращения: 24.08.2024).
4. *Booyse W., Wilke D. N., Heyns S.* Deep digital twins for detection, diagnostics and prognostics // Mechanical Systems and Signal Processing. 2020. 140: 106612.



*М. П. Бирюков*

начальник испытательного управления

Главный испытательный космический центр имени Г. С. Титова, Краснознаменск, Россия

## ПОЛИМОДЕЛЬНЫЙ КОМПЛЕКС ДИАГНОСТИЧЕСКИХ МОДЕЛЕЙ РАЗГОННОГО БЛОКА КАК ОБЪЕКТА АНАЛИЗА ТЕХНИЧЕСКОГО СОСТОЯНИЯ

Рассмотрены системно-когнитивные модели, позволяющие решать задачи идентификации технических состояний разгонных блоков, поддержки принятия решений, а также задачу исследования моделируемой предметной области путем изучения ее системно-когнитивной модели.

**Ключевые слова:** системно-когнитивные модели, идентификация технических состояний, интеллектуальные системы, многопараметрическая типизация.

*М. P. Biryukov*

Chief of the Testing Department

Titov Main Test and Space Systems Control Centre, Krasnoznamensk, Russia

## POLYMODEL COMPLEX OF DIAGNOSTIC MODELS OF THE GRADUATED BLOCK AS OBJECT OF ANALYSIS OF TECHNICAL CONDITION

The paper considers systems-cognitive models, allowing to solve problems of identification of technical states of the units, decision support, as well as the problem of investigation of modeled subject area by studying its system-cognitive model.

**Keywords:** systems-cognitive models, identification of technical states, intelligent systems, multiparameter typing.

В настоящее время запуск космических аппаратов (КА) на заданные орбиты и траектории, как правило, осуществляют с помощью разгонных блоков (РБ) и блоков выведения (БВ), являющихся неотъемлемой частью современных космических программ. Применение РБ позволяет значительно расширить возможности запуска КА, обеспечивая более эффективное использование ракет-носителей (РН) и снижение затрат на выведение полезной нагрузки, а также ряд преимуществ:

1) экономичность. Разгонные блоки позволяют использовать РН меньшей грузоподъемности, что может быть более экономически выгодным по сравнению с ракетами, способными выводить КА на целевые орбиты за один этап;

2) многозадачность. С помощью РБ возможно выведение нескольких КА как на однотипные, так и на различные типы целевых орбит;

3) точность выведения. Разгонные блоки позволяют более точно выводить КА на целевые орбиты, корректируя траекторию полета после основного этапа выведения РН;

4) сложность траектории. Не все РН способны выводить КА на высокоэллиптические и геостационарные орбиты. Использование РБ позволяет осуществлять запуски на более высокие орбиты, а в случае необходимости вывода на орбиту с нестандартной или сложной траекторией полета они могут обеспечить требуемые маневры для достижения цели.

Центральным местом контроля за полетом РБ (БВ), анализом их технического состояния (ТС) является единый центр управления полетами (ЕЦУП) РБ из состава наземного автоматизированного комплекса управления Министерства обороны РФ. На его обслуживании находятся все типы РБ (БВ): «Фрегат», «Бриз-М», семейство блоков «ДМ», «Персей», БВ «Волга». При этом нередки ситуации, когда за короткий промежуток времени, как правило в конце года, производятся до десяти пусков РН с использованием различных типов РБ, а иногда и по два в день. Понятно, что при такой интенсивности пусков боевой расчет не всегда успевает в установленные сроки (в зависимости от типа РБ), оперативно и с требуемой достоверностью выполнять поставленные задачи: от выдачи заключений перед пуском до выпуска отчетов. Например, для БВ «Волга», предусматривающего реализацию порядка семи схем выведения после команды на отделение от РН, анализ телеметрической информации боевым расчетом ЕЦУП РБ вообще должен проводиться в реальном или близком к реальному масштабу времени.

В связи с этим задачи оптимизации процессов анализа ТС таких сложных систем, как РБ (БВ) в различных условиях ресурсных ограничений, требуют разрешения в самом ближайшем будущем, а в задачах автоматизации процесса анализа ТС без использования интеллектуальных технологий уже не обойтись.

Для успешной реализации процесса анализа ТС РБ необходимо создать модель РБ как объекта анализа его ТС.

Разгонный блок представляет собой сложную многопараметрическую динамическую техническую систему, в которой происходят многочисленные и разнообразные физические процессы, оказывающие существенное влияние на ее характеристики. Эти процессы крайне сложно поддаются описанию в виде содержательных

аналитических моделей, основанных на уравнениях, а разработка таких моделей требует значительных временных и интеллектуальных затрат. Введение в содержательные аналитические модели большого количества упрощающих допущений снижает их универсальность, адекватность и достоверность.

Поскольку за годы эксплуатации РБ накоплены огромные массивы эмпирических данных о значениях телеметрируемых параметров в процессе полета, их можно использовать для создания феноменологических информационно-математических моделей, не имеющих аналитической формы представления и описывающих объект анализа как «черный ящик».

Для реализации таких моделей будем использовать инновационный метод искусственного интеллекта: автоматизированный системно-когнитивный анализ (АСК-анализ) и его программный инструментарий – универсальную когнитивную аналитическую систему «Эйдос» [1].

Математический метод АСК-анализа основан на системной теории информации, является непараметрическим и позволяет обрабатывать тысячи градаций признаков (факторов) и состояний (классов) нелинейных многопараметрических объектов анализа при неполных (фрагментированных), зашумленных данных числовой и нечисловой природы, измеряемых в различных единицах измерения.

На начальном этапе создания модели осуществляется формализация предметной области, т. е. создаются классификационные и описательные шкалы и градации, а затем с их помощью кодируются исходные данные и таким образом формируется обучающая выборка. Градации классификационных шкал, т. е. классы, соответствуют обобщенным категориям объекта, например его техническим состояниям, а градации описательных шкал являются значениями признаков объекта анализа, описывающих наличие или степень выраженности у него определенных свойств. При табличном представлении исходных данных каждой шкале обычно соответствует колонка или строка таблицы.

После формализации исходных эмпирических данных для выявления взаимосвязей между признаками и состояниями объекта анализа рассчитывается матрица  $N_{[M,W]}$  абсолютных частот (матрица сопряженности).

В матрице  $N_{[M,W]}$  классами (столбцами) являются состояния объекта анализа, а атрибутами (строками) – признаки. Значение каждого элемента  $N_{ij}$  матрицы  $N_{[M,W]}$  представляет собой фактическое число наблюдений  $i$ -го признака ( $i = \overline{1, M}$ ) у объектов  $j$ -го класса ( $j = \overline{1, W}$ ) по данным обучающей выборки, т. е. матрица абсолютных частот отражает число встреч различных значений (градаций) признаков по всем градациям классов. В терминологии АСК-анализа матрица  $N_{[M,W]}$  имеет название «Статистическая модель ABS».

Имея сформированную матрицу абсолютных частот, можно вычислить:

$$N_{\Sigma j} = \sum_{i=1}^M N_{ij} \text{ – суммарное количество наблюдений различных признаков у объектов, принадлежащих } j\text{-му классу;}$$

$$N_{i\Sigma} = \sum_{j=1}^W N_{ij} \text{ – суммарное количество наблюдений } i\text{-го признака у всех объектов исследуемой выборки;}$$

$$N_{\Sigma\Sigma} = \sum_{i=1}^M N_{i\Sigma} = \sum_{j=1}^W N_{\Sigma j} = \sum_{i=1}^M \sum_{j=1}^W N_{ij} \text{ – суммарное количество наблюдений различных признаков у всех}$$

объектов исследуемой выборки.

Поскольку на практике обычно имеется существенная несбалансированность данных, т. е. сильно различающееся количество наблюдений объектов обучающей выборки, относящихся к различным градациям одного класса или признака, то корректно сравнивать классы можно только по условным и безусловным вероятностям наблюдения признаков, посчитанных на основе матрицы  $N_{[M,W]}$ . Исходя из этого можно сформировать матрицу  $P_{[M,W]}$  условных и безусловных вероятностей (процентных распределений).

Элементы  $P_{ij}$  матрицы  $P_{[M,W]}$  рассчитываются по следующим выражениям:

$$P_{ij} = \frac{N_{ij}}{N_{i\Sigma}} \text{ – условная вероятность того, что объект принадлежит } j\text{-му классу при условии наличия у него}$$

$i$ -го значения признака;

$$P_{ij} = \frac{N_{ij}}{N_{\Sigma j}} \text{ – условная вероятность наблюдения } i\text{-го значения признака у объектов } j\text{-го класса.}$$

Значения  $P_{ij}$  представляют собой, строго говоря, не вероятности, а относительные частоты, которые, однако, при достаточно большом объеме выборки незначительно отличаются от вероятностей. Кроме того, элементы  $P_{ij}$  можно выражать и в процентах. После формирования матрицы  $P_{[M,W]}$  можно вычислить:

$$P_{\Sigma j} = \frac{N_{\Sigma j}}{N_{\Sigma\Sigma}} \text{ – безусловную вероятность того, что объект принадлежит } j\text{-му классу;}$$

$$P_{i\Sigma} = \frac{N_{i\Sigma}}{N_{\Sigma\Sigma}} \text{ – безусловную вероятность наблюдения } i\text{-го значения признака по всей выборке.}$$

Для расчета значений элементов матрицы  $\mathbf{P}_{[M,W]}$  условных и безусловных вероятностей в качестве  $N_{\Sigma j}$  можно использовать либо суммарное количество признаков по классу, либо суммарное количество объектов обучающей выборки по классу. Соответственно, получаются две различные матрицы условных и безусловных вероятностей (процентных распределений), которые в терминологии АСК-анализа называются «Статистическая модель PRC 1» и «Статистическая модель PRC 2».

Взяв за основу матрицы  $\mathbf{N}_{[M,W]}$  и  $\mathbf{P}_{[M,W]}$ , можно построить матрицу  $\mathbf{I}_{[M,W]}$  знаний (информативностей). Эта матрица представляет собой уже не статистическую, а системно-когнитивную модель (в терминологии АСК-анализа – модель INF 1), в которой значения  $I_{ij}$  рассчитываются по формулам:

$$I_{ij} = \Psi \log_2 \frac{P_{ij}}{P_{i\Sigma}} \quad \text{или} \quad I_{ij} = \Psi \log_2 \frac{N_{ij} N_{\Sigma\Sigma}}{N_{i\Sigma} N_{\Sigma j}},$$

где  $\Psi = \frac{\log_2 W^\varphi}{\log_2 N_{\Sigma\Sigma}}$  – коэффициент эмерджентности Харкевича;

$$\varphi = \frac{\log_2 \sum_{m=1}^M C_W^m}{\log_2 W} \quad \text{– коэффициент эмерджентности Хартли [1].}$$

Если в качестве  $N_{\Sigma j}$  использовать не суммарное количество признаков по классу, а суммарное количество объектов обучающей выборки по классу, то получится системно-когнитивная модель INF 2.

Значения  $I_{ij}$  представляют собой частные критерии знаний – количество знаний в факте наблюдения  $i$ -го значения признака о том, что объект принадлежит  $j$ -му классу.

Когда  $I_{ij} > 0$  –  $i$ -й признак способствует принадлежности объекта  $j$ -му классу, когда  $I_{ij} < 0$  – препятствует этому, когда же  $I_{ij} = 0$  – не влияет на это. В векторе  $i$ -го признака (строка матрицы информативностей) отображается, какое количество знаний о принадлежности объекта анализа к каждому из классов содержится в том факте, что данный признак наблюдается. В векторе  $j$ -го класса (столбец матрицы информативностей) отображается, какое количество знаний о принадлежности объекта анализа соответствующему классу содержится в каждом из признаков.

Таким образом, рассмотренные модели позволяют рассчитать, какое количество информации (или знаний) содержится в любом факте о наступлении любого события, причем для этого не требуется повторности этих фактов и событий. Если данные повторности осуществляются и при этом наблюдается некоторая вариабельность значений признаков, обуславливающих наступление тех или иных событий, то модели обеспечивают многопараметрическую типизацию, т. е. синтез обобщенных образов классов с количественной оценкой степени и знака влияния на принадлежность тому или иному классу различных значений признаков. Причем значения этих признаков могут быть как количественными, так и качественными и измеряться в любых типах шкал и любых единицах измерения, в любом случае в моделях оценивается количество информации (знаний), которое в них содержится о принадлежности объекта анализа к тем или иным классам.

На основе рассмотренных системно-когнитивных моделей можно решать задачи идентификации (классификации, распознавания, диагностики, прогнозирования) технических состояний разгонных блоков, поддержки принятия решений (обратная задача прогнозирования), а также задачу исследования моделируемой предметной области путем исследования ее системно-когнитивной модели [2].

### Библиографический список

1. Орлов А. И., Луценко Е. В. Анализ данных, информации и знаний в системной нечеткой интервальной математике: монография. Краснодар: КубГАУ, 2022. 405 с.
2. Татарникова Т. М. Анализ данных в прикладных задачах обеспечения информационной безопасности. СПб.: ГУАП, 2018. 115 с.

*А. А. Бурькин*\*\*\*\*\*

кандидат военных наук, доцент

*М. Н. Грачев*\*\*\*\*\*

кандидат технических наук, доцент

\*Государственный университет морского и речного флота имени адмирала С. О. Макарова, Санкт-Петербург, Россия

\*\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

\*\*\*Российская академия транспорта, Москва, Россия

\*\*\*\*ЗАО «НПП „Автоматизация“», Санкт-Петербург, Россия

## ПУТИ РЕАЛИЗАЦИИ ПЕРСПЕКТИВНЫХ СИСТЕМ УПРАВЛЕНИЯ БЕЗЭКИПАЖНОГО СУДНА ДВОЙНОГО НАЗНАЧЕНИЯ С ИСПОЛЬЗОВАНИЕМ ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

На основании опыта разработки корабельных автоматизированных систем управления и интегрированных мостиковых систем приводятся краткие сведения о путях реализации принципов e-Navigation с учетом использования технологий искусственного интеллекта в перспективных транспортных системах.

**Ключевые слова:** безэкипажные суда, автономное судовождение, интегрированные мостиковые системы, искусственный интеллект.

*A. A. Burykin*\*\*\*\*\*

PhD, Military, Associate Professor

*M. N. Grachev*\*\*\*\*\*

PhD, Tech., Associate Professor

\*Admiral Makarov State University of Maritime and Inland Shipping, St. Petersburg, Russia

\*\*St. Petersburg State University of Aerospace Instrumentation

\*\*\*Russian Academy of Transport, Moscow, Russia

\*\*\*\*CJSC «Research and production enterprise „Automation“», St. Petersburg, Russia

## WAYS TO IMPLEMENT PROMISING CONTROL SYSTEMS FOR A DUAL-PURPOSE UNMANNED VESSEL USING ARTIFICIAL INTELLIGENCE TECHNOLOGY

Based on the experience of developing shipboard automated control systems and integrated bridge systems, the article provides brief information on ways to implement the principles of e-Navigation, taking into account the use of artificial intelligence technologies in promising transport systems.

**Keywords:** unmanned vessels, autonomous navigation, integrated bridge systems, artificial intelligence.

### Введение

На сегодняшний день технологии искусственного интеллекта (ИИ) в комплексе с технологиями робототехники находятся на первом месте среди разработок приоритетных направлений научной деятельности. Транспортная система – одна из крупнейших базовых отраслей хозяйства, важнейшая составная часть производственной и социальной инфраструктуры страны. Ведущие инженеры транспортно-производящих корпораций выдвигают идею полной замены существующей концепции, т. е. не рассматривать транспортное средство (ТрС) как изолированную сложную техническую систему, а расценивать ее как локальную, неотъемлемую часть сети. Ведущие страны мира создают безэкипажные суда (БЭС), беспилотные летательные аппараты (БПЛА), которые имеют двойное назначение: применяются как в гражданских, так и в военных секторах. Применение БЭС в гражданском секторе позволяет сократить эксплуатационные затраты, увеличить его вместимость, снизить влияние человеческого фактора на безопасность мореплавания, повысить эффективность морской и речной транспортной инфраструктуры, а в военном секторе увеличить боевую мощь корабля, дополнительно возникает «гуманитарная миссия»: уменьшение или исключение присутствия военнослужащих в зоне боевого соприкосновения.

Тенденции развития IT-технологий в транспортной системе определяют направления реализации концепции a-Navigation и e-Navigation, сформулированные в 2005 г. Международной морской организацией (англ. International Maritime Organization, IMO) [1–4]. Стратегический план внедрения (СПВ) e-Navigation был сформирован и принят на 94-й сессии Комитета по безопасности мореплавания (КБМ) IMO в ноябре 2014 г. [4]. В указанном плане сформулированы проблемы и перечислены конкретные задачи, которые необходимо решать при проектировании и создании оборудования, удовлетворяющего требованиям e-Navigation [5].

В настоящее время, принято следующее определение e-Navigation – скоординированные сбор, интеграция, передача, воспроизведение и анализ информации о ситуации на море, на борту кораблей и на берегу с помо-

щью электронных средств в целях обеспечения улучшенной (более совершенной) навигации, реализующей принцип «от причала до причала», и работы соответствующих служб, повышения надежности и безопасности морской навигации и защиты морской среды» [2].

Технология a-Navigation – автоматическое и дистанционное управление судами, обеспечивает полностью самостоятельное следование судна по заданному курсу, расхождение с другими судами, уклонение от объектов, представляющих опасность. На сегодня в рамках автономного судовождения речь идет о дистанционно управляемых и полуавтономных судах, на которых часть или большинство систем являются автономными, но в той или иной степени находятся под наблюдением человека.

Впервые идея автономного судовождения и создания морских автономных надводных судов (МАНС) в России описывалась в 2016 г. в «дорожной карте» АНО «Отраслевой центр MariNet» Фонда Национальной технологической инициативы Агентства стратегических инициатив (АСИ) при поддержке Минпромторга РФ с участием Минтранса РФ и Российского морского регистра судоходства.

Несмотря на то, что Россия, представлена в ИМО, она на сегодняшний день не участвует ни в одном крупном международном e-Navigation-проекте. Кроме того, к сожалению, Россия не входит и в число лидеров производства и применения безэкипажных судов и кораблей, более того, имеет серьезное отставание в этой области.

### Обсуждение

Состояние и тенденции развития информационных технологий, опыт разработки боевых информационных управляющих систем (БИУС) и роботизированных элементов навигационного оборудования позволяют определять пути реализации концепции e-Navigation и a-Navigation по созданию перспективных интеллектуальных информационных систем управления БЭС на основе включения в состав АСУ судна/корабля программно-аппаратного комплекса «Интегрированная мостиковая система» (ИМС) для реализации «интеллектуального автопилота» (ИАП) выполняющего функции навигационного/боевого маневрирования как одиночным судном/кораблем, так и в составе каравана судов / корабельной группы.

Базовыми элементами такой подсистемы АСУ судна/корабля должны являться электронные средства позиционирования с высоким уровнем интеграции (интегрированные навигационные системы – ИНС), электронные навигационные карты (ENC), аналитические функции, минимизирующие влияние человеческого фактора и позволяющие снизить нагрузку на судоводителя (пилота, командира корабля).

Для подтверждения сказанного приведем часть списка проблем, которые необходимо решить в рамках СПВ e-Navigation [6]:

- S1 – совершенствование проектирования мостиков, включая стандартизацию диалога, соответствие оборудования мостика современным требованиям, отображение информации о текущем состоянии оборудования;
- S2 – стандартизация и автоматизация процедур составления докладов (донесений);
- S3 – повышение надежности и целостности (в плане программного обеспечения) мостикового оборудования, а также способности к восстановлению как оборудования, так и навигационной информации;
- S4 – комплексирование и представление на многофункциональных графических дисплеях такой информации, как данные ИНС по безопасности мореплавания, цифровые карты, данные радара и т. д.; внедрение единой морской структуры данных (EMSD), используя универсальную модель представления гидрографических данных S-100 (дальнейшее развитие S-57), разработанную Международной гидрографической организацией (МГО).

### Результаты

При разработке интеллектуальной системы управления (ИСУ) БЭС, кроме традиционной методологии научного познания, основу которой составляет системный подход, предлагается применить процессный и ситуационный подходы. Предлагаемая система, основанная на динамической гибридной экспертной системе, построенной по модульному принципу с использованием базы продукционных правил, в принципе может использоваться для управления любым подвижным объектом. Конструктивно система может представлять вычислительный модуль – дополнение к ИМС, реализующий систему управления безэкипажного судна (корабля) с элементами искусственного интеллекта [7–9].

Система управления реализуется с применением современных подходов к созданию ПО, а именно технологий: модель – представление – контроллер (MVC); grid-системы; интегрированное хранение данных; клиент-сервер.

При построении системы применяется принцип расширяющего ядра. Это позволяет наращивать и изменять функциональность системы управления в зависимости от предназначения судна (корабля), не перепрограммируя всю систему, а лишь подключая дополнительные модули робототехнической подсистемы и перезагружая продукционные правила.

На рис. 1 представлена двухуровневая архитектура ИСУ БЭС: подсистема управления верхнего уровня, динамическая гибридная экспертная система на основе продукционных правил; подсистема управления нижнего уровня, робототехническая подсистема на основе операционной системы реального времени с микроядром.

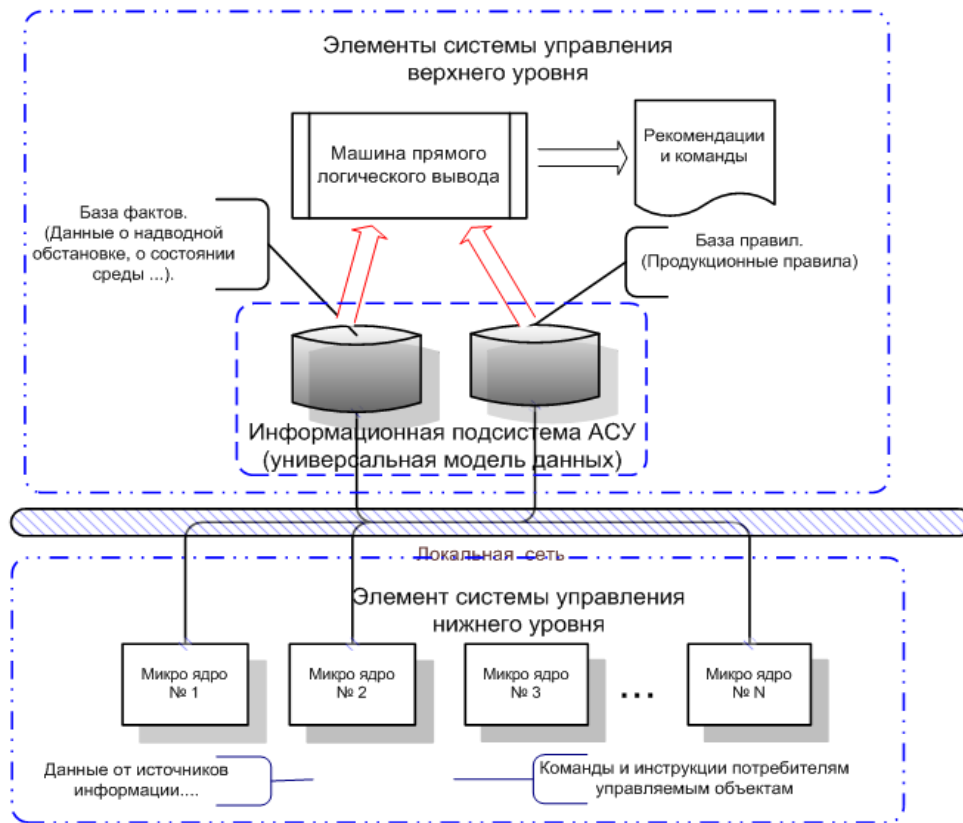


Рис. 1. Архитектура интеллектуальной системы управления судном

На рис. 2, 3 демонстрируются образы экранов многофункционального дисплея, компонента разрабатываемой системы с различной степенью детализации информации о навигационной обстановке в интересах выбора курса расхождения корабля с целями в контролируемой зоне. В данном примере информация поступает в подсистему от имитатора движения целей и имитатора системы позиционирования, после чего обрабатывается и отображается на дисплее, используя в качестве подложки стандартную электронную навигационную карту в формате S-57, рекомендованную МГО.

На рис. 2 показаны при текущих координатах и параметрах движения целей (КПДЦ):

- секторы относительных опасных курсов (СООК) – желтым цветом;
- опасная зона цели (круг) в относительных перемещениях – желтым цветом;
- сектор опасных курсов корабля – красным цветом;
- граница зоны контроля – круг радиусом 12 миль зеленого цвета с центром корабля, где автоматически выполняются расчеты и построения указанных секторов и зон.




Рис. 2. Навигационная обстановка с секторами опасных курсов корабля

На рис. 3 при текущих КПДЦ показаны:

- опасные зоны в абсолютных координатах для корабля на текущий момент времени (номера зон совпадают с номерами целей, порождающих эти зоны) – красным цветом;
- генеральный курс корабля – красная линия;
- рекомендованные курсы, точки поворота, обеспечивающие безопасное расхождение корабля – желтого цвета.




Рис. 3. Маневр нашего корабля по расхождению с возвратом на генеральный курс

При утверждении указанного маневра судоводителем после соответствующего преобразования (обработки) указанная информация может передаваться в автопилот судна/корабля, и указанный маневр может выполняться автоматически, тем самым снижается нагрузка на судоводителя и исключаются ошибки, вызванные человеческим фактором.

При создании информационной системы на программных средствах СУБД «Линтер» реализован универсальный подход к информационной модели объектов управления, который позволяет хранить и поддерживать в актуальном состоянии информационные экземпляры отражающие реальные объекты с необходимыми на текущий момент параметрами. Учитывая сказанное, эту реализацию можно смело назвать «базой фактов», отражающей навигационную обстановку в заданном районе, состояние и характеристики объектов.

Модель вычислений для автоматизации задач выбора и принятия решений в маневрировании основана на производственных правилах, представляющих знания в виде правил «ЕСЛИ условие, ТО действие» [10]. Системы, основанные на знаниях, или экспертные системы (ЭС) стали называться интеллектуальными системами [11; 12].

Отличительная особенность интеллектуальных систем (в том числе экспертных), основанных на правилах продукции, – сравнительная простота описания зависимостей и ограничений предметной области, а также достаточное их понимание пользователем. Готовые экспертные системы не являются универсальными с точки зрения использования, так как работают только в одной предметной области, исходя из этого, машина прямого логического вывода реализована в виде хранимых процедур СУБД «ЛИНТОР». Таким образом в среде СУБД «ЛИНТОР», кроме «базы фактов», создается «база знаний», и, используя машину автоматического логического вывода, мы получаем гибридную экспертную систему. Гибридной она называется потому, что, помимо формализованных правил экспертов, в качестве «экспертов» используются еще расчетные модули, без которых при реализации боевого маневрирования не обойтись. Экспертами в нашем случае служат правила, составленные на основе МППСС-72, тактических руководств и других документов. Ввиду сложности задачи (корабль не математическая точка, а материальный объект, у него есть размеры, инерция, радиус циркуляции и т. д.) правила, хранящиеся в «базе знаний», разбиты на соответствующие разделы, а некоторые разделы имеют иерархическую структуру. Работа того или иного раздела инициируется изменением обстановки и характеристиками объекта управления через систему соответствующих триггеров СУБД.

### Заключение

Таким образом, предложенный подход к разработке ИСУ БЭС, включающий две принципиальные системы, является перспективным:

- система управления верхнего уровня – динамическая гибридная экспертная система, построенная по модульному принципу с использованием базы производственных правил (интеллектуальная составляющая);

– система управления нижнего уровня – робототехническая подсистема на основе операционной системы реального времени с микроядром, которая вместе с контроллерами обеспечивает передачу команд на технические системы, реализующие движение судна и заданный курс судна.

Предлагаемый подход реализации принципов a-Navigation и e-Navigation тестировался на программном «скелете» системы: клиентская часть – на программных средствах Qt 5.3 в операционной среде MS Windows 7; серверная часть – операционная среда QNX Альтлинукс; СУБД – «Линтер-Бастион».

#### Библиографический список

1. Ривкин Б. С. Е-навигация на марше // XIII Всероссийское совещание по проблемам управления. М., 2019. С. 1–7.
2. Patraiko D. J. e-Navigation Concept // European Journal of Navigation. 2007. Vol. 5, № 5.
3. Mitropoulos E. E-navigation: a global resource // Seaways. 2007. March.
4. E-navigation // International Maritime Organization. URL: <https://www.imo.org/en/OurWork/Safety/Pages/eNavigation.aspx> (дата обращения: 02.09.2021).
5. Ривкин Б. С. Е-Навигации – 10 лет // Гироскопия и навигация. 2015. № 4(81).
6. Бурькин А. А., Грачев М. Н. Реализация принципов E-Navigation с использованием технологий искусственного интеллекта // Арктика. Морская транспортировка грузов: проблемы и решения – 2021: Междунар. конф. СПб., 2021.
7. Бурькин А. А., Грачев М. Н. Реализация элементов технологии искусственного интеллекта в перспективных АСУ надводного корабля и АСУ временного формирования сил ВМФ // Военная мысль. 2021. № 4.
8. Интеллектуализация процессов функционирования сложных транспортных систем: монография / А. В. Курлов, А. А. Бурькин, М. Н. Грачев М. Н. [и др.]. СПб.: Издат.-полиграф. ассоц. высших учеб. заведений, 2024. 198 с.
9. Burykin A. A., Grachev M. N., Kolesnichenko S. V. Artificial intelligence technologies in the implementation of the e-Navigation concept // Springer Proceedings in Business and Economics. Challenges and Solutions in the Digital Economy and Finance. Proceedings of the 5th International Scientific Conference on Digital Economy and Finances. (DEFIN 2022) St. Petersburg, 2022. P. 351–356.
10. Иванова Г. С., Авдошин А. П. Продукционная машина автоматического логического вывода для создания экспертных систем // Экономика и качество систем связи. 2018. № 1.
11. Частиков А. П., Гаврилова Т. А., Белов Д. Л. Разработка экспертных систем. Среда CLIPS. СПб.: БХВ-Петербург, 2003.
12. Советов Б. Я., Колбанев М. О., Татарникова Т. М. Диалектика информационных процессов и технологий // Информация и Космос. 2014. № 3. С. 96–104.



**В. В. Венгеренко\***

магистр

**М. М. Лукашевич\*\*\***

кандидат технических наук, доцент

**А. В. Инютин\***

заведующий лабораторией

\*Объединенный институт проблем информатики Национальной академии наук Беларуси, Минск, Республика Беларусь

\*\*Белорусский государственный университет, Минск, Республика Беларусь

## РАЗРАБОТКА МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНАЛИЗА ТЕЛЕМЕТРИЧЕСКОЙ ИНФОРМАЦИИ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ПОИСКА АРХИТЕКТУР

Исследование посвящено разработке модели машинного обучения для анализа телеметрической информации с малых космических аппаратов методом поиска архитектур. Описана методика поиска архитектуры нейронной сети на макро- и микроуровне на основе архитектуры Transformer. Представленный подход показал эффективность автоматизации поиска архитектуры нейронной сети в сравнении с ручным проектированием.

**Ключевые слова:** машинное обучение, поиск архитектуры.

**V. V. Vengerenko\***

Master

**M. M. Lukashevich\*\*\***

PhD, Tech., Associate Professor

**A. V. Inyutin\***

Laboratory Chief

\*\*The United Institute of Informatics Problems of the National Academy of Sciences of Belarus, Minsk, Republic of Belarus

\*\*Belarusian State University, Minsk, Republic of Belarus

## DEVELOPMENT OF MACHINE LEARNING MODELS FOR ANALYSIS OF TELEMETRY INFORMATION USING ARCHITECTURAL SEARCH METHODS

The study is devoted to the development of a machine learning model for analysis of telemetry information from small spacecraft by architecture search. The methodology of searching architecture of neural network on macro- and micro level based on Transformer architecture is described. The described approach showed the efficiency of automation of search for neural network architecture in comparison with manual design.

**Keywords:** machine learning, search for architecture.

### Введение

Относительно низкая стоимость производства и развитие электроники в последние годы определили интерес к малым космическим аппаратам (МКА), которые в большом количестве функционируют на околоземной орбите. Анализ телеметрической информации (ТМИ) с МКА является важной и актуальной задачей, позволяющей определить техническое состояние МКА и своевременно обнаружить нештатные ситуации (отказы, сбои, некорректную работу). Прогнозирование и мониторинг состояния МКА требуют автоматизации, включая сбор, хранение и обработку ТМИ. В связи с этим актуальным стал интеллектуальный анализ ТМИ с целью диагностики оборудования МКА. Цель исследования – разработать модели машинного обучения для анализа ТМИ с МКА методом поиска архитектур.

На сегодняшний день ряд исследователей используют нейросетевой подход для анализа ТМИ и предлагают нейросетевые архитектуры на основе MLP (MultiLayer Perceptron, многослойный перцептрон), CNN (Convolutional Neural Network, сверточная нейросеть), GRU (Gated Recurrent Unit, управляемый рекуррентный блок) и LSTM (Long Short-Term Memory, долгая краткосрочная память) моделей. В последние годы глубокие нейронные сети на базе архитектуры трансформер (Transformer) крайне успешно используются в задачах компьютерного зрения, при разработке больших языковых моделей, а также при работе с табличными данными. Применяют либо общеизвестные архитектуры, которые прошли определенную апробацию и показали свою эффективность, либо «вручную» подбираются модели под конкретную задачу и данные. Ручное проектирование нейронной архитектуры – трудоемкая процедура, требующая знаний в предметной области и значительной вычислительной инфраструктуры для обучения и оценки множества сетей [1; 2]. Поиск новых эффективных архитектур на основе Transformer занимается ряд исследователей [3]. В работе основной акцент сделан на автоматизации этапа проектирования архитектуры нейронной сети для анализа ТМИ. Исследование обусловлено потребностью в улучшении результатов, полученных на предыдущих этапах проекта по анализу ТМИ, в которых использовались ансамбли нейронных сетей [4].

## Экспериментальные наборы данных (телеметрическая информация)

Для построения моделей машинного обучения использованы 3 набора данных ТМИ звездного датчика (ЗД) Белорусского космического аппарата (БКА) за 2015, 2021 годы. Фрагмент файла телеметрии представлен на рис. 1. Набор 1 содержит 73 046 записей, 2 – 131 905, 3 – 2 384 627 записей.

ТМИ ЗД БКА содержит датчики, определяющие следующие параметры: координаты по солнцу, ток на ЗД, значения кватернионов, температуру процесса обработки сигналов и температуру ПЗС матрицы (которая делает снимки). Также каждому объекту в таблице соответствуют две метки для бинарной классификации (0 – нештатного состояния подсистемы, 1 – штатного состояния подсистемы) и для многоклассовой классификации (0 – завершено, 2 – инициализация разворота, 3 – ожидание разворота, 4 – разворот, 8 – отмена).

	YBC	YAC	TOK58	STRQ1	STRQ2	STRQ3	STRQ4	TSTR1CCD	TSTR1DSP	Class	Class1
0	0.000	0.000	139.0	0.137	-0.312	0.78	0.524	9.849	23.41	0	0
1	0.000	0.000	135.0	0.137	-0.312	0.78	0.524	9.849	23.41	0	0
2	0.000	0.000	135.0	0.132	-0.315	0.78	0.525	9.849	23.41	0	0
3	46.865	32.324	135.0	0.132	-0.315	0.78	0.525	9.849	23.41	0	0
4	21.464	19.704	135.0	0.132	-0.315	0.78	0.525	9.849	23.41	0	0

Рис. 1. Фрагмент файла телеметрии

Исходя из наборов ТМИ, можно сформулировать две задачи машинного обучения: бинарная (нштатное/штатное состояние подсистемы) и многоклассовая (определение одного из 5 состояний подсистемы) классификация данных ТМИ.

## Методика поиска архитектуры нейронной сети

Поиск архитектуры нейронной сети (Neural Architecture Search, NAS) – это процесс автоматизации проектирования архитектуры, когда на вход поступают данные и формулируется решаемая задача (например, классификация), а на выходе получаем архитектуру, которая дает лучший результат (например, при решении задачи классификации показывает максимальную точность на тестовом наборе). Приведем ключевые элементы, которые должны быть определены для поиска архитектуры: набор элементов поиска, пространство поиска, стратегия поиска и стратегия оценки производительности архитектуры для выбора оптимальной. Поиск архитектуры выполняется на микроуровне (ячейки) или на макроуровне (слои). Классические стратегии поиска параметров архитектур – это поиск по решетке и случайный поиск. В рамках NAS исследователи реализуют и более сложные стратегии (алгоритмы) поиска: обучение с подкреплением (RL-NAS), эволюционное обучение (EL-NAS) и One-shot NAS.

За основу при проведении экспериментов взята архитектура Transformer, которая хорошо подходит для обработки последовательных данных, таких как ТМИ. Базовыми элементами разрабатываемой архитектуры являются полносвязные слои (Dense-слои) и механизм множественного внимания (MultiHeadAttention). При проектировании архитектуры механизм множественного внимания дополнялся слоями сложения и нормализации. Слой сложения при этом производит операцию поэлементного сложения входных и выходных значений слоя внимания. Основными параметрами слоев внимания в терминологии фреймворка Keras являются num\_heads (количество «голов» внимания) и key\_dim (размер каждой «головы» внимания для запроса (query) и ключа (key)).

В полносвязных скрытых слоях использовалась функция активации ReLU. При решении задачи бинарной классификации выходной полносвязный слой содержал 1 нейрон с функцией активации sigmoid или 2 нейрона с функцией активации softmax. Для многоклассовой классификации выходной слой содержал 5 нейронов с функцией активации softmax.

Ключевые элементы поиска архитектуры представлены в табл. 1.

Таблица 1

### Ключевые элементы поиска архитектуры

Задача	Бинарная классификация	Многоклассовая классификация
Элементы поиска	1. MultiHeadAttention. 2. Dense слои	
Пространство поиска	1. Значения num_heads и key_dim в диапазоне [8; 10]. 2. Количество нейронов в диапазоне [32; 128]. Количество всех слоев модели в диапазоне [11; 25]	1. Значения num_heads и key_dim в диапазоне [3; 5]. 2. Количество нейронов в диапазоне [32; 128]. Количество всех слоев модели в диапазоне [11; 25]
Стратегия поиска	Случайный поиск и RL-NAS	
Стратегия оценки производительности	Оценка точности модели на тестовом наборе	

На вход нейронной сети подавались векторы из 9 признаков. При реализации стратегии выполнялся случайный поиск последовательности слоев. Далее на основе RL-NAS-стратегии в найденной оптимальной последовательности слоев выполнялся поиск количества структурных элементов.

Экспериментальное программное обеспечение было реализовано на языке Python с использованием библиотек Tensorflow, Keras, gym, rl, dear. С помощью библиотеки gym создавалась среда для поиска, а библиотека rl позволила реализовать стратегию поиска на основе обучения с подкреплением. Библиотека dear использовалась для случайного поиска. Для вычислений использовалась GPU NVIDIA GeForce RTX 3060.

### Результаты экспериментальных исследований

Поиск архитектуры нейронной сети выполнялся для каждого из трех экспериментальных наборов данных и для каждой задачи (бинарная и многоклассовая классификация). На основе оценки точности (*accuracy*, доля верных предсказаний модели) моделей классификации на тестовом наборе было найдено 7 архитектур. На рис. 2 представлена архитектура для решения задачи бинарной классификации, полученная с помощью 1-го набора данных.

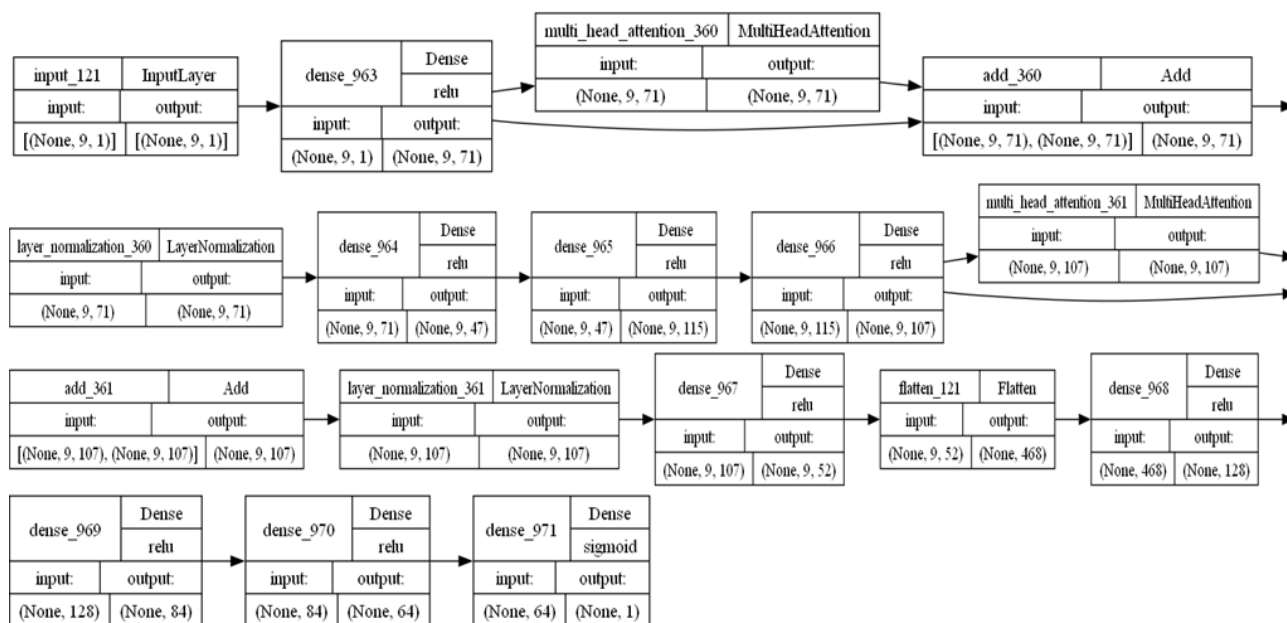


Рис. 2. Архитектура нейронной сети

Результаты экспериментов с выбранными архитектурами представлены в табл. 2. Описанный подход позволил улучшить результаты предыдущих исследований [4] и показал эффективность автоматизации поиска архитектуры нейронной сети в сравнении с ручным проектированием.

Таблица 2

### Результаты классификации для наборов ТМИ

Функция активации на выходе модели	Точность / функция потерь		
	Обучение	Валидация	Тестирование
<i>1-й набор</i>			
sigmoid	0.97746 / 0.05361	0.97383 / 0.08788	0.96888 / 0.10521
softmax	0.97651 / 0.05656	0.96774 / 0.09495	0.96688 / 0.09082
<i>2-й набор</i>			
sigmoid	0.98159 / 0.04707	0.97510 / 0.07510	0.97600 / 0.07407
softmax	0.98495 / 0.03848	0.97783 / 0.07996	0.97920 / 0.06891
<i>3-й набор</i>			
sigmoid	0.92488 / 0.17879	0.92170 / 0.18774	0.92118 / 0.18670
softmax (2 класса)	0.92967 / 0.16812	0.92774 / 0.17492	0.92820 / 0.17423
softmax (5 классов)	0.87191 / 0.35549	0.86872 / 0.36578	0.86942 / 0.36404

## Заключение

В работе представлены результаты исследований в области автоматического поиска архитектуры нейронной сети для решения задачи классификации ТМИ. В качестве базовой архитектуры выбрана архитектура Transformer, определены элементы и пространства поиска, предложена методика, сочетающая стратегии случайного поиска и RL-NAS. Под каждый набор данных и в зависимости от задачи классификации (бинарная или многоклассовая) на основе значения метрики точности для тестового набора выбраны архитектуры нейронных сетей. Были улучшены результаты предыдущих исследований, в которых использовались ансамблевые алгоритмы и ручное проектирование архитектур.

## Библиографический список

1. Скобцов В. Ю. Нейросетевая классификация данных телеметрической информации малых космических аппаратов // Информационные технологии в управлении (ИТУ-2022): матер. конф. СПб., 2022. С. 107–111.
2. Абрамов Н. С., Талалаев А. А., Фраленко В. П. Интеллектуальный анализ телеметрической информации для диагностики оборудования космического аппарата // Информационные технологии и вычислительные системы. 2016. № 1. С. 64–75.
3. Neural architecture search for transformers: A survey / К. Т. Chitty-Venkata, М. Emani, V. Vishwanath, А. К. Somani // IEEE Access. 2022. Vol. 10. P. 108374–108412.
4. Ансамбли нейронных сетей для классификации состояний и режимов функционирования подсистем космического аппарата = Neural networks ensembles for classification of operation states and modes of spacecraft subsystems / М. М. Лукашевич, В. Ю. Скобцов, А. В. Инютин, В. В. Ганченко // Big Data и анализ высокого уровня = Big Data and Advanced Analytics: сб. науч. ст. X Междунар. науч.-практ. конф., Минск, 13 марта 2024 г. 2024. Ч. 2. С. 217–228.

**И. В. Войтов\***

доктор технических наук, профессор

**М. Ю. Охмилев\*\***

доктор технических наук, профессор

**В. Н. Штепа\***

доктор технических наук, доцент

\*Белорусский государственный технологический университет, Минск, Республика Беларусь

\*\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## АКТУАЛЬНОСТЬ СОЗДАНИЯ И ВНЕДРЕНИЯ НА ВОДОПРОВОДНО-КАНАЛИЗАЦИОННЫХ ХОЗЯЙСТВАХ ИНТЕЛЛЕКТУАЛЬНО-АНАЛИТИЧЕСКИХ ПРОГРАММНЫХ ПРОДУКТОВ

Рассматривается актуальность разработки и внедрения интеллектуально-аналитических программных продуктов в водопроводно-канализационных хозяйствах. Выделены технологические проблемы, затрудняющие управление очистными сооружениями и системами водоотведения. Введение описанных в работе программных продуктов направлено на создание единой информационной платформы, способной интегрировать данные и знания о водоснабжении и водоотведении, обеспечивать доступ к актуальной информации и автоматизировать процессы управления.

**Ключевые слова:** интеллектуально-аналитические программные продукты, управление очистными сооружениями, автоматизация процессов, превентивное управление, экологическая безопасность, цифровая платформа, анализ данных.

**I. V. Voitov\***

Dr. Sc., Tech., Professor

**M. Yu. Okhtilev\*\***

Dr. Sc., Tech., Professor

**V. N. Shtepa\***

Dr. Sc., Tech., Associate Professor

\*Belarusian State Technological University, Minsk, Republic of Belarus

\*\*St. Petersburg State University of Aerospace Instrumentation

## RELEVANCE OF CREATION AND IMPLEMENTATION IN WATER SUPPLY AND SEWERAGE SYSTEMS OF INTELLECTUAL-ANALYTICAL SOFTWARE PRODUCTS

The article considers the relevance of development and implementation of intellectual-analytical software products in water supply and sewage. Technological problems that hinder the management of sewage treatment plants and water systems are highlighted. The introduction of the software products described in this paper aims at creating a common information platform capable of integrating data and knowledge on water supply and water management, providing access to relevant information and automating management processes.

**Keywords:** intellectual-analytical software products, sewage treatment plant management, process automation, preventive management, environmental safety, digital platform, data analysis.

На данном этапе развития водопроводно-канализационных хозяйств (ВКХ) объективно сформировался ряд технологических причин, вызывающих необходимость создания новых программных продуктов [1]. На примере системы водоотведения населенных пунктов (предприятий), включая очистные сооружения, к таким негативным факторам относятся [2]:

- сложность адаптивного управления очистными сооружениями (ОС);
- отсутствие системных решений оперативного измерения и прогноза показателей качества и объемов сточных вод непосредственно в сетях водоотведения до их поступления на очистные сооружения;
- отсутствие оперативного контроля состояния сети водоотведения и несвоевременное проведение их технического обслуживания и ремонта (ТОиР);
- отсутствие средств импактного (по месту) интеллектуального мониторинга ключевых объектов-загрязнителей сточных вод с обоснованием превышения ими нормативных требований к водоотведению и логическим прогнозом опасности воздействия их отходов на сеть канализования и ОС;
- нерепрезентативное (неверное) формирование технических заданий (ТЗ) на строительство (реконструкцию, модернизацию) сетей водоотведения, включая ОС.

На предприятиях используется некоторое количество специализированных программных продуктов, однако они не решают указанных проблем вследствие того, что единые информационные системы предприятий ВКХ отсутствуют – внедрены только фрагментарные элементы надстройки над SCADA (Supervisory Control And Data Acquisition) в виде аналитических модулей оценки работы биологических очистных сооружений, станций очистки питьевой воды, насосных групп.

При этом имеются следующие недостатки SCADA:

- они решают только задачи технологической диспетчеризации без прогноза развития рисков и ресурсоэффективности – нет косвенной оценки технологической ситуации;
- отсутствует решение смежных задач: ТОиР, управления ресурсами и персоналом, анализа экономической эффективности; пользователь во многих случаях не видит производственной ценности от создаваемых и наполняемых баз данных, которые поддерживаются в рамках функционирования SCADA;
- отсутствует оперативная связь технической системы с инженерно-технологическими специалистами (как правило, только через мобильного оператора SCADA, когда последний считает, что ситуация угрожающая);

Ситуация усугубляется тем, что необходимо поддерживать значительный перечень измерительных средств в рабочем состоянии, при этом пользователь в силу ограниченности функциональности SCADA не видит в этом необходимости: контрольно-измерительные приборы и другие инструментальные средства выходят из строя без обслуживания [3].

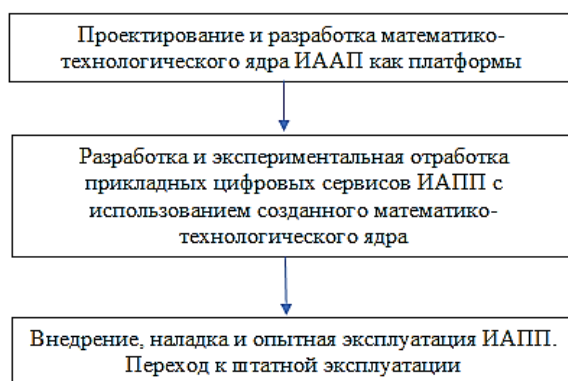
Программные продукты GPS-X, Sludge Expert, «Экосим» используются для математического моделирования (проектирования), симуляции техпроцессов, являются продуктовым решением для проектировщиков, но не предназначены для управления техпроцессами.

Соответственно, целями для перспективных программных средств обоснованно считать:

- обеспечение интеграции и каталогизации данных и знаний о ВКХ;
- обеспечение защищенного оперативного доступа к актуальной, достоверной и полной информации о состоянии ВКХ, технологических процессах реализации их жизненного цикла;
- обеспечение автоматизированного информационного взаимодействия в едином информационном пространстве ВКХ;
- обеспечение повышения степени осведомленности ЛППР (лиц, принимающих решения) для принятия обоснованных решений, организациях и предприятиях ВКХ по обеспечению заданного уровня технического состояния и прогнозируемых показателей качества и надежности.

При этом, в отличие от традиционно используемого реактивного управления сложными объектами, необходимо ориентироваться на оперативное реагирование и последующее недопущение инцидентов. Такое проактивное управление предполагает предотвращение возникновения негативных ситуаций за счет создания в соответствующей системе мониторинга и управления принципиально новых прогнозирующих и упреждающих возможностей при формировании и реализации управляющих воздействий, базирующихся на концепции системного (комплексного) моделирования.

Тогда технология создания новых интеллектуально-аналитических программных продуктов (ИАПП) может состоять из трех ключевых этапов (рисунки).



*Последовательность создания нового класса интеллектуально-аналитических программных продуктов для ВКХ*

На первом этапе на основе глубинного последовательного исследования (drill down) предметной области, технического проектирования и прототипирования строится интеллектуальная система унифицированных решений – «движок» для прикладных цифровых сервисов.

Аппаратно ИАПП ВКХ должна обеспечивать:

- поддержку периферийных устройств ввода-вывода, например на основе технологии OPC, а также имеющих в системе множества встроенных драйверов популярных приборов и устройств или API: простое подключение Plug&Play разнообразных устройств по шаблонам; широкий перечень поддерживаемых PLC, приборов учета; подключение любых устройств через Modbus RTU/ASCII/TCP; использование разнообразных каналов коммуникации: GSM/Lan/Radio, Online-визуализация на всех платформах: Windows, Linux, Mac OS, мобильные приложения;
- сохранение работоспособности уже существующих и используемых систем;
- объединение разнотипных технических платформ;
- множественное подключение и одновременное использование сервисов;

- загрузку базы объектов из ГИС и других хранилищ данных;
- быстрое разворачивание системы;
- невысокие финансовые, временные и кадровые вложения;
- неограниченное количество рабочих мест, в том числе виртуальных (VR и/или AR).

Обоснованно, что системное внедрение ИАПП ВКХ с точки зрения технологических процессов потенциально позволит [4]:

- достичь эффективного управления объектами водоснабжения и водоотведения;
- повысить ресурсо- и энергоэффективность технологических процессов ВКХ;
- обеспечить санитарно-гигиеническую и экологическую безопасность систем водоснабжения и водоотведения, включая оптимизацию функционирования очистных сооружений;
- достичь качественного планирования операций и выполнение работ по техническому обслуживанию и ремонту агрегатов, оборудования и других составляющих элементов систем водоснабжения и водоотведения;
- обеспечить адекватную оценку рисков и раннее предупреждение потенциальных чрезвычайных ситуаций техногенного характера, недопущение их возникновения на объектах ВКХ, например в случае попадания опасных токсикантов на биологические ОС;
- формировать качественные технические задания на строительство, реконструкцию или модернизацию объектов ВКХ согласно критерию «минимизация затрат»;
- проводить системное практико-ориентированное обучение персонала современным информационным решениям.

### **Заключение**

Перспективные интеллектуально-аналитические программные продукты ВКХ, прежде всего их математико-технологическое ядро, должны строиться как предметно-ориентированная цифровая платформа, обеспечивающая возможности построения и исполнения многофункциональных прикладных решений цифрового информационно-аналитического обеспечения водопроводно-канализационных хозяйств на основе извлечения, комплексирования, цифровизации и интеграции разнородных информационных ресурсов и разноаспектных экспертных знаний, манипулирования ими, а также генерации на их основе цифровых сервисов обработки и анализа данных с использованием передовых технологий онтологического проектирования, интеллектуального анализа данных, больших данных (Big Data), машинного обучения, low-code проектирования, когнитивной 2D- и 3D-графики, высоконагруженных приложений, оперативных аналитических вычислений (OLAP), информационной поддержки изделий (CALS), цифровых двойников.

### **Библиографический список**

1. *Войтов И. В., Штепа В. Н.* Использование цифровой платформы водоотведения для предупреждения технологических рисков биологической очистки сточных вод // Инновационные биотехнологии для охраны окружающей среды: от теории к практике: матер. I Междунар. науч.-практ. конф., Минск, 23–25 апр. 2024 г. / Институт микробиологии НАН Беларуси; орг. комитет конф.: А. А. Шепшелев (пред.) [и др.]. Минск: ИнМи, 2024. С. 83–84.
2. О задачах цифровизации систем водоотведения коммунально-промышленных объектов / И. В. Войтов, В. В. Смелов, А. В. Дернович, В. Н. Штепа // Нефтегазохимия-2023: матер. VI Междунар. науч.-техн. форума по хим. технологиям и нефтегазопереработке, Минск, 1–3 нояб. 2023 г. / УО «Белорусский государственный технологический университет»; отв. за выпуск К. В. Вишнеvский. Минск: БГТУ, 2023. С. 147–151.
3. *Штепа В. Н., Золотых Н. Ю., Куреев С. Ю.* Обоснование и схемы использования ранжирующих измерительных систем экологического мониторинга и интеллектуального анализа режимов водоотведения // Вестник Полоцкого государственного университета. Серия F. Строительство. Прикладные науки. 2023. № 1. С. 94–103.
4. Практическое использование информационно-аналитической системы оценки экологической безопасности водоотведения / В. Н. Штепа, А. Б. Шикунец, А. В. Козырь, Н. Ю. Золотых // II Форум IT-Академграда «Искусственный интеллект в Беларуси»: доклады, Минск, 12–13 окт. 2012 г. / Нац. акад. наук Беларуси, Объединен. ин-т проблем информатики; науч. ред.: С. В. Кругликов, С. Н. Касанин. Минск: ОИПИ НАН Беларуси, 2023. С. 251–256.

**В. Ф. Волков\***

доктор военных наук, профессор

**Н. А. Шуваев\***

адъюнкт

**Р. Р. Хайдаров\***

адъюнкт

\*Военно-космическая академия имени А. Ф. Можайского, Санкт-Петербург, Россия

## **МЕТОДОЛОГИЧЕСКИЙ ПОДХОД К ПРИМЕНЕНИЮ ЦИФРОВОГО ДВОЙНИКА ДИСТАНЦИОННО ОБСЛУЖИВАЕМОГО ОБЪЕКТА В ПРОЦЕССЕ ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ В ИНТЕРЕСАХ СОКРАЩЕНИЯ ВРЕМЕНИ ПРИНЯТИЯ РЕШЕНИЯ ОПЕРАТОРОМ**

Рассматривается задача автоматизации процесса контроля состояния дистанционно обслуживаемых объектов путем внедрения нейросетевого алгоритма. Обучение нейронной сети осуществляется на данных, полученных в результате создания цифрового двойника дистанционно обслуживаемого объекта. Представленный алгоритм обеспечивает минимизацию времени принятия решения оператором о техническом состоянии дистанционно обслуживаемого объекта.

**Ключевые слова:** дистанционное обслуживание, контроль состояния, нейронная сеть, сверточный слой.

**V. F. Volkov\***

Dr. Sc., Military, Professor

**N. A. Shuvaev\***

Adjunct

**R. R. Khaidarov\***

Adjunct

\*A. F. Mozhaysky Military-Space Academy, St. Petersburg, Russia

## **METHODOLOGICAL APPROACH TO THE APPLICATION OF DIGITAL BINARY REMOTELY SERVICED OBJECT IN NEURAL NETWORK LEARNING PROCESS FOR REDUCING OPERATOR DECISION TIME**

The article considers the task of automating the process of monitoring the status of remotely serviced objects by introducing a neural network algorithm. Neural network training is carried out on data obtained as a result of the creation of a digital double of remotely serviced object. The presented algorithm ensures minimization of time for decision by operator about technical condition of remotely serviced object.

**Keywords:** remote maintenance, condition control, neural network, convoluted layer.

### **Введение**

Непрерывные изменения, происходящие в околоземном космическом пространстве и связанные с ростом числа дистанционно обслуживаемых объектов (ДОО), приводят к возрастанию значимости своевременной идентификации их состояния за счет автоматического наблюдения и контроля за КО, выполняемых информационной системой – системой мониторинга космического пространства.

Одним из способов своевременной идентификации является применение технологий машинного обучения. В качестве классификатора рассмотрим нейронную сеть.

Для постановки и решения задачи классификации состояния ДОО были смоделированы измерения наземных радиолокационных станций, а именно замеров эффективной площади рассеяния (ЭПР) стабилизированных и вращающихся ДОО, расположенных на низкой орбите.

### **Постановка задачи**

Контроль состояния ДОО осуществляется различными методами, основанными на использовании отраженных от ДОО электромагнитных волн. Анализ литературы по методам дистанционного распознавания состояний технических систем [1–5] показал, что к настоящему времени разработаны два подхода к оцениванию целесообразности проведения дополнительных процедур контроля состояния ДОО. Первый подход основан на использовании методов расчета апостериорных вероятностей, второй – на применении стохастического динамического программирования.

Для реализации первого подхода необходимы словарь признаков, данные по априорным вероятностям нахождения ДОО в соответствующих состояниях (работоспособен, частично работоспособен, неработоспособен



и т. п.) и статистические характеристики плотностей распределения значений признаков. Значения апостериорных вероятностей гипотез о состояниях ДОО «пересматриваются» в соответствии с теоремой Байеса по результатам очередного управляющего воздействия.

Для реализации второго подхода, основанного на следовании априорно введенным правилам сочетания управляющих воздействий, процедур контроля состояния ДОО и пошагового принятия решения после каждого этапа процесса целевого применения, в рамках ретроспективной и прямой разверток вычислительного алгоритма решаются функциональные уравнения Беллмана.

Таким образом, возникает необходимость решения новой научной задачи по обоснованию целесообразности проведения процедур контроля состояния ДОО в условиях отсутствия апостериорных сведений о результатах управляющих воздействий. Один из возможных подходов к решению данной задачи может быть основан на использовании цифровых двойников в процессе обучения нейронных сетей (НС) [6–10].

### **Подготовка цифрового двойника и обучение нейронной сети**

Для обучения нейронной сети рассмотрим два варианта получения совокупности замеров ЭПР: до и после управляющего воздействия. Обучение НС производится по результатам вычислительного эксперимента, для чего разрабатывается модель ДОО, имитирующая геометрические размеры и характеристики материалов и покрытий конструктивных элементов, формируется таблица соответствия распознаваемых признаков техническому состоянию ДОО, имитируется множество замеров ЭПР для различных бортовых систем ДОО.

Для моделирования электродинамических отражательных характеристик объекта целесообразно использовать уже разработанные отечественные программные продукты. Например, широкие функциональные возможности имеет программно-алгоритмический комплекс FlowVision. В результате моделирования формируется набор замеров ЭПР ДОО, который состоит из 5000 различных реализаций. Набор разбивается на 4000 обучающих и 1000 контрольных реализаций. Первая половина контрольных замеров получается по исходной 3D-модели ДОО, вторая – путем внесения небольших конструктивных изменений в 3D-модель ДОО и изменения его параметров движения относительно центра масс. Каждый замер представляет собой цветное изображение в формате JPG размером 1400×500.

При решении задач обработки изображений хорошо зарекомендовали себя многослойные сверточные НС [6–10], обеспечивающие запоминание признаков и устойчивость к изменениям масштаба, смещениям, поворотам, смене ракурса.

Первый слой в НС – входной. На него подаются замеры ЭПР. Набор замеров ЭПР необходимо нормализовать, чтобы улучшить алгоритм оптимизации, который используется в обучении НС.

Следующий слой – сверточный. На ввод этого слоя подается матрица со значениями уровней ЭПР. Зададим фильтр (ядро свертки) случайными значениями от  $-0,5$  до  $0,5$  (изначально эти веса ничем не обоснованы). В дальнейшем эти значения будут изменяться путем применения алгоритма обратного распространения ошибки. Фильтр производит свертку, т. е. передвигается по введенному изображению из левого верхнего угла в правый, он умножает значения фильтра на исходные значения ЭПР (поэлементное умножение). Все эти произведения суммируются. В итоге получается одно число, которое символизирует нахождение фильтра в верхнем левом углу изображения. Этот процесс повторяется в каждой позиции. Каждая уникальная позиция введенного изображения производит число. После прохождения фильтра по всем позициям получается матрица, которую называют функцией активации или картой признаков.

Следующим этапом при разработке НС является выбор функции активации нейронов, наименее требовательной к вычислительным ресурсам является функция ReLU [7; 8; 10].

Третий слой – слой субдискретизации. Его назначение – уменьшение размерности карт предыдущего слоя. Если на предыдущей операции свертки уже были выявлены некоторые признаки, то для дальнейшей обработки настолько подробные данные нужны.

В зависимости от результата, полученного в карте признаков, появится необходимость редактирования значений фильтра. Способ, которым НС способна корректировать веса фильтра, – это обучающий процесс, который называют методом обратного распространения ошибки. Метод обратного распространения ошибки можно разделить на 4 отдельных блока: прямое распространение, функцию потери, обратное распространение и обновление веса.

Процессы прямого и обратного распространения, а также обновления весов составляют один период дискретизации. Программа будет повторять этот процесс фиксированное количество периодов для каждого обучающего изображения. После того, как обновление параметров завершится на последнем обучающем образце, сеть должна быть достаточно хорошо обучена и веса слоев настроены правильно.

Последний слой – полносвязный персептрон. Его назначение – классификация на основе сложной нелинейной модели. Нейроны каждой карты предыдущего слоя связаны с одним нейроном слоя субдискретизации. Выходной слой связан со всеми нейронами предыдущего слоя. К выходному слою задач классификации применяется функция активации Softmax [7; 8; 10], гарантирующая равенство единице суммы всех выходных нейронов. Значение выходного нейрона в интервале  $[0,1]$  можно рассматривать как вероятность прогноза, а наибольшую вероятность – результатом классификации.

### Алгоритм определения технического состояния дистанционно обслуживаемых объектов

Верификация работы НС осуществляется контрольным набором изображений, который наполовину состоит из замеров ЭПР до управляющих воздействий. Не уменьшая общности, в рамках статьи рассмотрим три состояния ДОО: работоспособен, частично работоспособен и неработоспособен. Контрольный набор пропускается через сеть и формируются выходы, которые определяют состояния ДОО.

*Этап 1.* Ввод матриц реализаций ЭПР до управляющих воздействий:

$$Y = \left\{ y_t \mid y_t = [y_1, y_2, \dots, y_m]^T; t = \overline{1, T} \right\},$$

где  $y_t$  – столбец матрицы со значением уровня ЭПР, полученный в момент времени  $t$ ;  
 $t$  – множество моментов времени наблюдения;  
 $m$  – количество замеров ЭПР.

*Этап 2.* Введем матрицы реализаций ЭПР после управляющих воздействий:

$$U = \left\{ u_t \mid u_t = [u_1, u_2, \dots, u_p]^T; t = \overline{1, T} \right\},$$

где  $u_t$  – столбец матрицы со значением уровня ЭПР, полученный в момент времени  $t$ ;  
 $t$  – множество моментов времени наблюдения;  
 $p$  – количество замеров ЭПР.

*Этап 3.* Ввод множества возможных ТС ДОО после управляющих воздействий:

- $s_1$  – ДОО работоспособен;
- $s_2$  – ДОО частично работоспособен;
- $s_3$  – ДОО неработоспособен.

*Этап 4.* Ввод кортежа параметров НС:

$$n = \langle \eta, k, h^{(k+1)}, c^{(k)}, o^{(k)}, z \rangle,$$

где  $\eta \in (0, 1]$  – коэффициент скорости обучения НС;

$k = \overline{1, K}$  – количество повторений слоев свертки и субдискретизации;

$h^{(k+1)} = [h^{(1)}, h^{(2)}, \dots, h^{(k+1)}]$  – вектор-строка, содержащий размерности векторов весовых коэффициентов слоев

свертки, при этом последнее значение вектора  $h^{(k+1)}$  соответствует размерности полносвязного слоя НС;

$c^{(k)} = [c^{(1)}, c^{(2)}, \dots, c^{(k)}]$  – вектор-строка, элементами которого являются количества ядер свертки в каждом слое;

$o^{(k)} = [o^{(1)}, o^{(2)}, \dots, o^{(k)}]$  – вектор-строка, содержащий значения размеров окон слоев субдискретизации;

$z$  – необходимое количество циклов перебора данных.

В процессе сканирования ядром субдискретизации (фильтром) карты предыдущего слоя не пересекаются в отличие от сверточного слоя. Вся карта признаков разделяется на ячейки по  $o^{(k)}$  элементов, из которых выбираются максимальные по значению.

*Этап 5.* Ввод множества весовых коэффициентов ядер свертки  $w^{(k),c}$  и полносвязного слоя НС  $w^{(k+1)}$  случайными значениями от  $-0,5$  до  $0,5$ :

$$w^{(k),c} = [w_1^{(k),c}, w_2^{(k),c}, \dots, w_h^{(k),c}]^T, w_{c,h}^{(k)} \in [-0,5; 0,5], c \in c^{(k)}, h \in h^{(k)},$$

$$w^{(k+1)} = [w_1^{(k+1)}, w_2^{(k+1)}, \dots, w_h^{(k+1)}]^T, w_h^{(k+1)} \in [-0,5; 0,5]$$

где  $w^{(k),c}$  – весовые коэффициенты с ядер свертки  $k$ -го слоя;

$w^{(k+1)}$  – весовые коэффициенты полносвязного слоя.

*Этап 6.* Получение карт признаков через операцию «свертки» значений нормализованного вектора входных данных  $d^{norm}$  с весовыми коэффициентами ядер свертки  $w^{(1),c}$ :

$$v^{(1),c} = d^{norm} * w^{(1),c},$$

$$v_j^{(1),c} = \sum_{l=0}^{(m+p)} d_l^{norm} w_{h-l}^{(1),c} \mid j = 1, \overline{(m+p-h^{(1)}+1)}.$$

*Этап 7.* Использование функции активации ReLU:

$$\mathbf{v}^{(1),c,ReLU} = f_{ReLU} \left\{ \mathbf{v}^{(1),c} \right\},$$

$$v_j^{(1),c,ReLU} = f_{ReLU} \left( v_j^{(1),c} \right) = \max \left( 0, v_j^{(1),c} \right) = \begin{cases} v_j^{(1),c}, & v_j^{(1),c} > 0, \\ 0, & v_j^{(1),c} < 0; \end{cases}$$

$$| j = \overline{1, (m + p - h^{(1)} + 1)}.$$

*Этап 8.* Операции слоя субдискретизации или подвыборки:

$$\mathbf{v}^{(1),c,maxpool} = f_{\maxpool(o^{(1)})} \left\{ \mathbf{v}^{(1),c,ReLU} \right\},$$

$$v_j^{(1),c,maxpool} = f_{\maxpool(o^{(1)})} \left\{ v_{(j+o^{(1)}-1)}^{(1),c,ReLU} \right\} = \max \left\{ v_{(j+o^{(1)}-1)}^{(1),c,ReLU} \right\}.$$

*Этап 9.* Повтор выполненных шагов алгоритма  $k - 1$  раз. При этом выходной вектор одного слоя является входным вектором следующего слоя.

*Этап 10.* Операции полносвязного слоя НС:

$$s^* = w^{(k+1)} v^{(k+1)},$$

$$s_g^* = \sum_{i=0}^j w_i^{(k+1)} v_i^{(k+1)}.$$

*Этап 11.* Использование функции активации SoftMax:

$$s^{*,SoftMax} = f_{SoftMax} \left( s^* \right),$$

$$s_g^{*,SoftMax} = \frac{e^{s_g^*}}{\sum_{i=1}^G e^{s_i^*}} | g = \overline{1, G}.$$

Функция SoftMax – это обобщение логистической функции для многомерного случая. Функция преобразует вектор  $s^*$  размерности  $G$  в вектор  $s^{*,SoftMax}$  той же размерности, где каждая координата  $s_g^{*,SoftMax}$  полученного вектора представлена вещественным числом в интервале  $[0, 1]$  и сумма координат равна 1.

*Этап 12.* Расчет функции потерь:

$$L = - \sum_{i=1}^n P(s_i) \log Q \left( s_i^{*,SoftMax} \right),$$

где  $P(s_i)$  – распределение вероятностей истинных ответов;

$Q \left( s_i^{*,SoftMax} \right)$  – распределение вероятностей прогнозов модели.

В качестве функции потерь выбрана кросс-энтропия, так как она хорошо зарекомендовала себя при многоклассовой классификации. Кросс-энтропия измеряет расхождение между двумя вероятностными распределениями. Если кросс-энтропия велика, это означает, что разница между двумя распределениями велика, а если мала, то распределения похожи друг на друга.

*Этап 13.* Корректировка весовых коэффициентов полносвязного слоя НС и весовых коэффициентов ядер сверток по алгоритму градиентного спуска:

$$w^{(k+1)} = \left\{ w_i^{(k+1)} = w_i^{(k+1)} - \eta \frac{\partial L}{\partial w_i^{(k+1)}} | i = \overline{1, I} \right\};$$

$$w^{(k),c} = \left\{ w_i^{(k),c} = w_i^{(k),c} - \eta \frac{\partial L}{\partial w_i^{(k),c}} | i = \overline{1, I} \right\}.$$

*Этап 14.* Шаги алгоритма повторяются до достижения требуемой минимальной ошибки процесса обучения.

*Этап 15.* Проверка работы НС на немодельных исходных данных.

## Заключение

Разработанный алгоритм предназначен для использования в составе математического обеспечения автоматизированных систем управления ДОО различных классов. Он обеспечивает минимизацию времени на обработку поступающей информации и повышает достоверность данных для принятия решения о состоянии ДОО.

## Библиографический список

1. Демидова А. В., Семенчев Е. А. Системный подход к планированию действий при организации целенаправленного поведения беспилотных транспортных платформ // Известия Тульского ГУ. Технические науки. 2022. Вып. 6. С. 10–19.
2. Волков В. Ф., Пономарев А. С. Применение метода динамического программирования при организации контроля применения ОТС // Современные наукоемкие технологии. 2021. № 10. С. 23–27.
3. Селекция и распознавание на основе локационной информации. / А. Л. Горелик, Ю. Л. Барабаш, О. В. Кривошеев, С. С. Эпштейн. М.: Радио и связь, 1990. 240 с.
4. Ладыгин А. И. Анализ сигнатур. Теория и практика радиолокационного распознавания космических объектов & Космические трагедии глазами аналитиков сигнатур. М.: Университетская книга, 2008. 256 с.
5. Шпаков П. А. Тенденции развития способов передачи и регистрации телеметрической информации ракетно-космической техники США // Т. Com. 2018. Vol. 1, 2. № 7. P. 31–35.
6. Бужинский В. А. Исследование влияния упругих колебаний крупногабаритных элементов конструкции космического аппарата на искажение геометрических характеристик рефлектора // Космонавтика и ракетостроение. 2007. № 2(47). С. 102–108.
7. Блощинский В. Д. Применение свёрточных нейронных сетей в задачах детектирования облачности и снежного покрова по данным прибора МСУ-ГС КА Электро-Л №2 // Современные проблемы дистанционного зондирования Земли из космоса: матер. 17-й Всерос. открытой конф. М.: ИКИ РАН. 2019. С. 18.
8. Кучма М. О. Анализ возможности использования нейронной сети для тематической обработки спутниковых изображений // Решение: матер. Восьмой Всерос. науч.-практ. конф. Березники: Изд-во Перм. нац. политех. ун-та. 2019. С. 70–72.
9. Нестечук А. Н., Шавин А. С., Хлебников С. Г. Нейросетевая модель идентификации состояния космического объекта по результатам оптических измерений // Оборонный комплекс – научно-техническому прогрессу России. 2022. № 1. С. 37–42.
10. Ананенко В. М., Голяков А. Д., Сасункевич А. А. Обоснование структуры нейронной сети для определения параметров движения орбитального объекта по результатам его наблюдений с борта космического аппарата // Известия высших учебных заведений. Приборостроение. 2022. № 6. С. 565–574.

*Е. Д. Григорьева\**

студент

*В. А. Ушаков\**

кандидат технических наук – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## РАЗРАБОТКА АППАРАТНО-ПРОГРАММНОГО КОМПЛЕКСА «УМНОГО» ПРОИЗВОДСТВА С ПРИМЕНЕНИЕМ ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Рассмотрен вопрос применения технологий искусственного интеллекта в аппаратно-программном комплексе «умного» производства для решения задачи выбора расположения датчиков в производственном помещении.

**Ключевые слова:** интернет вещей, киберфизические системы, аппаратно-программный комплекс, «Умный город», искусственный интеллект.

*E. D. Grigorieva\**

Student

*V. A. Ushakov\**

PhD, Tech. – Scientific Adviser

St. Petersburg State University of Aerospace Instrumentation

## DEVELOPMENT OF HARDWARE AND SOFTWARE COMPLEX «SMART» PRODUCTION WITH THE APPLICATION OF ARTIFICIAL INTELLIGENCE TECHNOLOGY

The issue of application of artificial intelligence technologies in hardware and software complex «smart» production for solving the problem of selection of location of sensors in the production room has been considered.

**Keywords:** internet of things, cyber-physical systems, hardware and software complex, «Smart city», artificial intelligence.

### Введение

Киберфизические системы [1; 2] – это комплексные системы, состоящие из вычислительных и физических элементов, которые постоянно получают данные из окружающей среды, обрабатывают их и передают конечному потребителю [3; 4]. Они объединяют два типа моделей: традиционные инженерные (механические, строительные, электрические, биологические, химические, экономические и др.) и компьютерные.

Интернет вещей (Internet of Things, IoT, ИВ) – одна из основных технологических тенденций, лежащих в основе киберфизических систем. ИВ представляет собой объединенную сеть, к которой посредством коммуникационной и информационной инфраструктуры подключено множество объектов [5–7]. Они обмениваются между собой информацией и работают без вмешательства человека в режиме реального времени.

Искусственный интеллект (ИИ) – одна из самых быстрорастущих областей технологического развития и один из важнейших компонентов киберфизических систем. Это система, которая способна воспринимать окружающую среду и принимать меры, чтобы максимизировать шансы на успешное достижение поставленных целей, а также интерпретировать и анализировать данные таким образом, чтобы они обучались и адаптировались по мере развития [8; 9]. ИИ позволяет машинам решать сложные задачи и мыслить интуитивно. Совокупность применения технологий ИВ и ИИ позволяет существенно повысить качество работы системы, выходя за рамки простой автоматизации.

На основе технологии ИВ был разработан аппаратно-программный комплекс «умного» производства, выполняющий управление оборудованием производственного помещения с целью снижения затрат на его содержание. Система подразумевает широкий спектр возможностей и применима в различных сферах. Необходимо провести обзор возможных вариантов использования методов ИИ в аппаратно-программном комплексе «умного» производства для будущего применения их в системе с целью улучшения ее работы.

### Описание аппаратно-программного комплекса «умного» производства

«Умное» производство состоит из двух основных модулей: аппаратного и программного. Аппаратный модуль представляет собой централизованную систему с беспроводными каналами обмена информации по Wi-Fi и включает набор датчиков и микропроцессорную платформу Arduino. Программная часть состоит из обработчика, базы данных (БД) «Датчики», мобильного приложения для операционной системы Android и программного интерфейса приложения (Application Programming Interface, API). Датчики отправляют свои данные на центральный модуль управления Arduino. Затем данные помпугают в обработчик, где информация преобразовывается в удобный формат и записывается в БД. API необходим для обмена данными между мобильным приложением и БД. Мобильное приложение позволяет осуществлять ручное управление системой: контролировать текущее состояние всех ее компонентов, осуществлять ручное включение и выключение устройств, а также просматривать информацию о зависимости значений датчиков от времени в графическом виде для отслеживания динамики и анализа данных.

Система «Умное производство» может работать с любым набором подключенных к ней устройств, что позволяет использовать ее в различных сферах для решения различных задач.

### **Обзор возможных путей применения методов искусственного интеллекта в аппаратно-программном комплексе «умного» производства**

Аппаратно-программный комплекс «умного» производства имеет широкий спектр применений и соответствующих им преимуществ. В базовом варианте «умное» производство используется для контроля и обеспечения соблюдения техники безопасности, норм труда и ресурсосбережения в производственном помещении. Система собирается из соответствующего требованиям заказчика набора датчиков и обеспечивает экономию электроэнергии и улучшение условий работы сотрудников, за счет контроля за показаниями датчиков в помещении и автоматического включения и выключения «вещей»: розеток, лампочек и т. д.

При первоначальной настройке системы самым сложным этапом является выбор расположения датчиков в помещении. Неправильное расположение устройств может привести к получению некорректных данных и ошибкам в работе системы.

Традиционно для решения этой задачи используются системы поддержки принятия решений [10]. Для решения проблемы необходимо добавить в систему модуль, основанный на технологии ИИ, который помогал бы пользователю принимать решение об оптимальном расположении датчиков. Для этой цели можно использовать методы оптимизации.

Генетические алгоритмы (ГА) – это алгоритмы поиска и оптимизации, прообразом которых является биологический принцип естественного отбора. Данный метод может быть использован для нахождения оптимального расположения датчиков путем эволюционного моделирования, исследуя большое пространство возможных решений и находя лучшие комбинации расположения датчиков.

В результате выполнения ГА предлагает на выбор несколько решений и выполняется достаточно быстро за счет параллельности вычислений. Однако на качество выполнения алгоритма сильно влияет полнота исходных данных, а также корректность заданной функции пригодности, что может вызвать сложность у пользователей системой.

Алгоритмы роя частиц (PSO) моделируют поведение роя, чтобы найти оптимальное расположение датчиков. Частицы (предположения о расположении датчиков) перемещаются в пространстве возможных решений на основе определенных правил, учитывающих положение других частиц и их историю.

Алгоритм прост в реализации и не требует сложной настройки параметров. Его можно легко адаптировать под конкретные требования задачи, например учитывать ограниченные зоны или специфические характеристики датчиков. В большинстве случаев PSO сходится быстрее, чем многие другие методы глобальной оптимизации, что может быть важно при необходимости оперативного развертывания системы. Однако в алгоритме PSO стартовое распределение частиц сильно влияет на эффективность поиска. Неудачно выбранная начальная конфигурация может затруднить достижение хорошего результата.

Методы на основе градиентного спуска широко применяются в машинном обучении, в том числе в нейронных сетях. Они используются для нахождения локального минимума или максимума функции, связанной с показателями эффективности системы при различных расположениях датчиков.

Градиентные методы могут давать очень точные результаты при поиске минимума, что особенно важно, если требуется высокое качество решения для оптимального размещения. Они хорошо масштабируются и могут быть адаптированы для задач с большим числом переменных, таких как оптимизация размещения множества датчиков. Однако методы на основе градиентного спуска, как правило, более эффективны для задач с гладкой целевой функцией, где можно легко вычислить градиенты. В задачах оптимизации размещения датчиков целевая функция [11] часто бывает дискретной и многомодальной, что приводит к неточным результатам выполнения алгоритма.

Для выбора решения задачи расположения датчиков в помещении воспользуемся методом анализа иерархий (АИ). Для анализа проблемы принятия решений в методе АИ были выделены следующие критерии: точность полученных результатов, скорость выполнения алгоритма, возможность работы с ограниченным набором начальных условий, возможность получения нескольких вариантов расположения. Наибольшую значимость имеет критерий «Возможность работы с ограниченным набором начальных условий», так как при использовании системы конечным пользователем возможны неточности и неполнота данных. Наименьшую значимость имеет критерий «Скорость выполнения алгоритма», поскольку оптимизация времени поиска решения не является первостепенной задачей.

В таблице представлен итоговый результат весов альтернатив с точки зрения достижения поставленной цели. По результатам подсчета наиболее подходящим решением является алгоритм PSO, так как он позволяет получить точные результаты имея ограниченный набор начальных параметров.

#### **Весовые коэффициенты альтернатив с точки зрения достижения поставленной цели**

Метод	Весовые коэффициенты в долях	Весовые коэффициенты в процентах
ГА	0,364	36%
PSO	0,397	40%
Методы на основе градиентного спуска	0,239	24%

## Заключение

Был проведен обзор возможного применения ИИ в аппаратно-программном комплексе «умного» производства. Для решения задачи выбора расположения датчиков в производственном помещении был выбран метод PSO с помощью метода АИ.

## Библиографический список

1. *Мецержкова Е. Н.* От сложных технических систем к киберфизическим системам // Современные информационные технологии. 2019. № 30. С. 51–54.
2. Исследование возможностей оптимизации процессов управления киберфизическими системами / Т. В. Аветисян, Я. Е. Львович, А. П. Преображенский, Ю. П. Преображенский // Информационные технологии и вычислительные системы. 2023. № 2. С. 96–105.
3. *Ушаков В. А.* Модели и алгоритмы управления информационными процессами при взаимодействии подвижных объектов // Морские интеллектуальные технологии. 2022. № 3-1(57). С. 235–247.
4. *Соколов Б. В., Ушаков В. А.* Модели и алгоритмы комплексного планирования информационных процессов при взаимодействии подвижных объектов // Региональная информатика (РИ-2022): матер. конф. (СПб., 26–28 окт. 2022 г.). СПб.: СПОИСУ, 2022. С. 53–54.
5. *Колесник П. Д.* Перспективы Интернета вещей как инструмента цифровой экономики // Хроноэкономика. 2019. № 1(14). С. 53–58.
6. Internet of things: Theory to practice. Boca Raton / P. R. Gunjal, S. R. Jondhale, J. L. Mauri, K. Agrawal. CRC Press, 2024. 410 p.
7. *Taneja M.* A mobility analytics framework for Internet of Things // 2015 International Conference on Green Computing and Internet of Things (ICGCIoT). 2015. P. 113–118.
8. Что такое искусственный интеллект // SAP. URL: <https://www.sap.com/central-asia-caucasus/products/artificial-intelligence/what-is-artificial-intelligence.html> (дата обращения: 20.08.2024).
9. *Барсукова М. А., Пальмов С. В.* Методы искусственного интеллекта: краткий обзор // Форум молодых ученых. 2018. № 5/1(21). С. 412–416.
10. Методологические и методические основы создания и использования интегрированных систем поддержки принятия решений / А. В. Крылов, М. Ю. Охтилев, В. А. Соболевский [и др.] // Известия высших учебных заведений. Приборостроение. 2020. Т. 63, № 11. С. 963–974.
11. *Жуков А. Д., Ушаков В. А.* Формирование алгебраической целевой функции с помощью Matlab/Simulink при разработке систем автоматического управления // Научная сессия ГУАП, посвященная дню космонавтики. СПб.: ГУАП, 2016. С. 251–255.

*Н. Н. Григорьева*

старший преподаватель

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ПРОБЛЕМЫ ВНЕДРЕНИЯ СРЕДСТВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ПРИ СОЗДАНИИ АВИАНИКИ ГРАЖДАНСКОЙ АВИАЦИИ С ТОЧКИ ЗРЕНИЯ ПРОЦЕССНОГО ПОДХОДА

Рассмотрены организационно-технические проблемы, возникающие на различных этапах жизненного цикла встроенных бортовых программных систем, использующих методы искусственного интеллекта. Приводится исследование возможности применения к подобным системам существующих стандартов и технологий, направленных на обеспечение качества разработки и надежности авионики.

**Ключевые слова:** встроенное бортовое программное обеспечение, верификация, искусственный интеллект, безопасность.

*N. N. Grigoryeva*

Senior Lecturer

St. Petersburg State University of Aerospace Instrumentation

## THE IMPLEMENTATION OF ARTIFICIAL INTELLIGENCE IN CIVIL AVIONICS SYSTEMS: PROCESS APPROACH ASPECTS

The organizational and technical problems arising at certain stages of the life cycle of AI-based airborne embedded software systems are considered. An analysis of the possibility of applying existing standards and technologies, aimed at quality of development and reliability assurance of avionics, to such systems is presented.

**Keywords:** airborne embedded software, verification, artificial intelligence, safety.

В настоящее время один из трендов развития встраиваемых систем – использование программно-аппаратных средств, создаваемых с использованием технологий искусственного интеллекта. В принципе средства искусственного интеллекта (ИИ) могут применяться практически на всех этапах жизненного цикла авионики – от проектирования и контроля качества комплектующих до функционирования бортовых средств поддержки принятия решений. Соответственно, различные приложения средств ИИ имеют различный уровень ответственности, максимальный из которых – именно средства, используемые в качестве встраиваемого программного обеспечения бортовой авионики.

Авиационная отрасль в целом характеризуется не только сложностью управления, но в первую очередь высокими рисками. Последние проявляются в возможности катастрофических последствий вследствие соответствующих отказных состояний. Поэтому необходимо в первую очередь рассматривать вопрос об использовании средств ИИ в авионике с точки зрения потенциальных рисков внедрения этих средств [1]. Активное использование средств ИИ растет, но, например, по данным опроса, проведенного в 2023 году среди разработчиков программного обеспечения (ПО), порядка 70% которых используют или в ближайшее время планируют использовать инструменты ИИ, степень доверия к этим инструментам невысока и оценка точности этих средств распределяется следующим образом:

- полностью доверяют – 2,85%;
- скорее доверяют – 39,3;
- затрудняются оценить – 30,68;
- скорее не доверяют – 21,71;
- полностью не доверяют – 5,46% [2].

Подобные оценки доверия системам с ИИ не только основаны на субъективном опыте разработчиков кода, но и определяются вполне конкретными количественными данными. С 2012 г. проводится конкурс ImageNet Challenge на создание модели компьютерного зрения для классификации изображений (обучающая база изображений содержит 1,3 млн изображений). В настоящее время частота ошибок моделей-победителей конкурса, выполняющих задачи обнаружения объектов и классификации изображений, составляет около 3% [3]. Конечно, точность работы системы с ИИ постоянно возрастает, но пока еще имеет порядок единиц процентов. С чем могут быть связаны ошибки функционирования систем, использующих ИИ? Конечно, в первую очередь с недостаточным объемом обучающей выборки или ее неточностью, неудачным выбором структуры сети и/или ее параметров. Значительное число ИИ-решений базируется на иностранных платформах, что повышает риск внешнего воздействия и оставляет возможность манипулирования данными. Также нельзя исключать проведение атак на подобные системы на любом из этапов их жизненного цикла [4]. Если система искусственного интеллекта работает как распознающая система, при ее эксплуатации могут возникнуть ошибки распознавания первого и второго рода (пропуск нужного объекта и признание неверного объекта за нужный). В авиационных приложениях подобные ошибки могут привести к катастрофическим ситуациям [5].



Нельзя не сравнить возможности подобных программных средств с требованиями, предъявляемыми к надежности аппаратной части бортового оборудования. В соответствии с требованиями консультативного циркуляра FAA (Federal Aviation Administration) AC 25.1309-1, сбои оборудования, носящие катастрофический характер (сбои критических функций), должны иметь среднюю вероятность не более  $10^{-9}$  на час полета, т. е. быть крайне маловероятными. Сбои существенных (основных) функций должны быть маловероятными и иметь среднюю вероятность не более  $10^{-5}$  на час полета [6].

Вопросы анализа и обеспечения надежности и безопасности оборудования высококритичных сложных систем опираются на соответствующий математический аппарат и отработанные методологии. Задачи оценки структурной и функциональной надежности сложных технических систем и повышения показателей надежности имеют четкие алгоритмы решения [7]. С анализом уровня надежности и безопасности встроенного программного обеспечения (ПО) дело обстоит значительно сложнее, причем даже в случае традиционного ПО, работа которого построена на детерминированных алгоритмах. Доказательство гарантированного уровня надежности является прерогативой разработчиков ПО, базируется на реализации требований проектного подхода и представляет собой совокупность отчетов, подтверждающих выполнение целей, сформулированных для каждого из этапов жизненного цикла ПО. Методики проверки ПО сформулированы в государственном стандарте РФ [8] и квалификационных требованиях Авиационного Регистра МАК КТ-178 [9]. Основным рабочим документом, указаниями которого пользуются при обосновании уровня надежности разрабатываемого встраиваемого бортового ПО, служат квалификационные требования, достаточно подробно отражающие аспекты и логику процессного подхода к проектированию ПО. Процесс оценки безопасности подразумевает формулировку требований, связанных с безопасностью ее применения, в том числе требования к процессам жизненного цикла (ЖЦ) программного обеспечения и целей, которые должны быть достигнуты в каждом из процессов. В первую очередь определяются уровни ПО, необходимые для безопасности системы, в соответствии с классификацией отказных состояний системы (таблица).

**Классификация уровней ПО по их влиянию на безопасность системы**

Уровень ПО и соответствующее отказное состояние	Количество целей процесса ЖЦ (по КТ-178В)
<b>Уровень А.</b> Некорректная работа ПО может привести к отказу функции, приводящему к <b>катастрофическому</b> состоянию (невозможно предотвращение гибели людей)	66
<b>Уровень В.</b> Некорректная работа ПО может привести к отказу функции, приводящему к <b>аварийным</b> состояниям (значительное ухудшение характеристик ВС и работы экипажа)	65
<b>Уровень С.</b> Некорректная работа ПО может привести к отказу функции, приводящему к <b>сложным</b> отказным состояниям (заметное ухудшение характеристик и/или выход отдельных параметров за эксплуатационные ограничения, неблагоприятные условия работы экипажа)	57
<b>Уровень D.</b> Некорректная работа ПО может привести к отказу функции, приводящему к <b>усложнению условий полета</b> (незначительное ухудшение характеристик ВС, незначительное увеличение нагрузки на экипаж)	28
<b>Уровень Е.</b> Некорректная работа ПО может привести к отказу функции <b>без последствий</b> (не влияет на эксплуатационные возможности ВС и работу экипажа)	–

Объем и сложность работ, которые необходимо выполнить для гарантии соответствия предъявляемым к встраиваемому ПО требованиям, повышается вместе с заявляемым уровнем ПО. Методы гарантии качества и безопасности разработанного ПО подразумевают разноуровневые проверки трассируемости ПО, точности используемых алгоритмов, полноты структурного покрытия, робастности, верификацию результатов различных процессов ЖЦ вплоть до процесса верификации результатов процесса верификации [9, 10].

В настоящее время не существует однозначно регламентированных технических средств аудита систем с ИИ. При попытке использования стандартных процессов сертификации к средствам ИИ предсказуемо возникает проблема применимости этих методов гарантии. Например, не ясно, как может быть подтверждена трассируемость такого ПО, если система ИИ представляют собой набор фильтров – матриц коэффициентов, и нет информации о том, на каких данных и какими методами делалось обучение и как результат обучения соотносится с требованиями к ПО высокого и низкого уровней [4]. Наиболее мягкие требования по процессу сертификации предъявляются к ПО уровня D (см. таблицу), но даже в этом случае для процесса разработки ПО цели процесса полностью повторяют цели для уровня А.

Одна из целей процесса планирования создания ПО – определение стандартов на разработку ПО, согласованных с требованиями по безопасности системы (цель 5 – «Устанавливаются стандарты разработки ПО»). Одно из требований таково: «Стандарты на разработку ПО должны запрещать использование конструкций или методов, приводящих к результатам, не поддающимся проверке или не совместимым с требованиями безопасности» [9]. Выполнение данного требования уже вызывает затруднения при создании ПО методами искусственного интеллекта. По приблизительным оценкам, из целей, которые ставятся при сертификации ПО уровнями А и В, порядка 20–25% несовместимы с методами разработки средств ИИ.

При верификации средств ИИ необходимо использовать специальные методы гарантии качества. Для оценки трассируемости ПО схема процесса может меняться принципиально. В традиционном ПО этот процесс линеен и его можно разбить на этапы: требования к системе (подсистеме) → требования к ПО → создание кода → сертификация ПО → проверка соответствия ПО системным требованиям.

Для подтверждения трассируемости системы с ИИ могут появляться дополнительные этапы (цели) процесса: требования к системе → требования, применимые к ИИ-компонентам → формирование обучающей выборки (управление данными) → выбор модели обучения (управление процессом обучения) → тренировка модели → проверка процесса обучения → применение модели → проверка модели при ее интеграции в систему → независимые проверки данных и процесса обучения → проверка требований к ИИ-компонентам → проверка соответствия ПО системным требованиям.

При данной схеме организации процессов разработки практически все этапы должны иметь итерационный характер, т. е. каждая из проверок при неблагоприятном исходе предусматривает возврат процесса минимум на шаг назад. Подобная организация процессов жизненного цикла уже сейчас используется при экспериментальных разработках ПО с использованием ИИ уровня D [11].

## Выводы

Первоочередной проблемой, возникающей при внедрении средств ИИ, является проблема гарантии точности и безопасности таких систем. Ее решение, помимо развития собственно технологий ИИ, возможно в двух направлениях:

– формирование и использование доверенных обучающих наборов данных; необходима сертификация процесса их разработки [4];

– комплексирование разнородного ПО, например использование ИИ в связке с программами, которые уже были верифицированы, или комплексирование компонентов программной системы, построенных на нейросетях различной структуры; уже известна подобная экспериментальная система распознавания аэродромных знаков, безопасность которой имеет уровень С [11].

Вторая принципиальная проблема – отсутствие нормативной базы, что существенно задерживает внедрение ИИ в области авиационного приборостроения.

Год назад Европарламент принял первый закон об искусственном интеллекте, который устанавливает обязательства для искусственного интеллекта на основе его потенциальных рисков и уровня воздействия, в том числе обязательства для систем высокого риска, включая критическую инфраструктуру, к которой может быть отнесена и область авионики. Такие системы должны быть прозрачными и точными, обеспечивать надзор со стороны человека, должны быть обеспечены возможность проведения оценки моделей, оценка и смягчение системных рисков, а также отчетность об инцидентах [12]. Рабочая группа Европейской организации по оборудованию гражданской авиации EUROCAE в 2025 г. планирует выпуск стандарта по сертификации и внедрению средств ИИ и машинного обучения [13]. В Российской Федерации подготовка проекта требований по безопасности искусственного интеллекта и принятие соответствующих нормативных актов планируются в 2024 г. [4].

Таким образом, как резюмировал на дискуссии о применении искусственного интеллекта в авиационной отрасли в рамках семинара «Авиация. Квалификация. Надежность», проходившего в Москве в сентябре 2023 г., А. Н. Герасимов, директор филиала ПАО «Яковлев» – «Центр комплексирования», «сейчас искусственный интеллект на борту – еще будущее. Даже не ближайшее, потому что это вопрос безопасности... Он (ИИ) придет в авиацию с другой стороны: сначала он будет занимать роль помощника при разработке, пусть и не кода, а, например, требований. Это могут быть и другие функции, не являющиеся критическими... Сюда подходит анализ послеполетных данных. И вот когда будет понятно, что он (ИИ) все-таки может успешно массово применяться в отрасли, тогда и стоит задуматься о его еще более широком применении» [14].

## Библиографический список

1. Кротова Е. Л., Андреев Р. А., Андреева П. А. Big Data в авиационной отрасли: варианты применения. URL: <https://cyberleninka.ru/article/n/big-data-v-aviatsionnoy-otrasli-varianty-primeneniya/viewer> (дата обращения: 28.08.2024).
2. Hype or not? AI's benefits for developers explored in the 2023 Developer Survey. URL: <https://stackoverflow.blog/2023/06/14/hype-or-not-developers-have-something-to-say-about-ai/> (дата обращения: 28.08.2024).
3. 7 Popular Image Classification Models in ImageNet Challenge (ILSVRC) Competition History. URL: <https://machinelearningknowledge.ai/popular-image-classification-models-in-imagenet-challenge-ilsvrc-competition-history/> (дата обращения: 28.08.2024).
4. GIZ DAYS 2023: Вопросы доверия и ИБ при использовании ИИ-систем. URL: <https://digitalcryptography.ru/news/novosti/gis-days-2023-voprosy-doveriya-i-ib-pri-ispolzovanii-ii-sistem/> (дата обращения: 28.08.2024).
5. Наталья Касперская про искусственный интеллект, биометрию и защиту данных: Эксклюзивное интервью с президентом ГК InfoWatch. URL: <https://tv.rbc.ru/archive/ekskluziv/61377e312ae59687774869a> (дата обращения: 28.08.2024).

6. Advisory Circular. URL: [https://www.faa.gov/documentLibrary/media/Advisory\\_Circular/AC%2025.1309-1.pdf](https://www.faa.gov/documentLibrary/media/Advisory_Circular/AC%2025.1309-1.pdf) (дата обращения: 28.08.2024).
7. *Острейковский В. А.* Теория надежности. М.: Высш. шк., 2003. 463 с.
8. Государственный стандарт Российской Федерации. Программное обеспечение встроенных систем. URL: <https://docs.cntd.ru/document/1200030195> (дата обращения: 28.08.2024).
9. Квалификационные требования. Часть 178В. Требования к программному обеспечению бортовой аппаратуры и систем при сертификации авиационной техники. URL: <https://kaf401.rloc.ru/TRPO/КТ-178В.pdf> (дата обращения: 28.08.2024).
10. *Миронов А. М.* Методы верификации программ. М.: ДМК Пресс, 2023. 336 с.
11. *Dmitriev K., Schumann J., Holzapfel F.* Toward Design Assurance of Machine-Learning Airborne Systems. URL: <https://ntrs.nasa.gov/api/citations/20210025705/downloads/main.pdf> (дата обращения: 28.08.2024).
12. Artificial Intelligence Act: MEPs adopt landmark law. URL: <https://www.europarl.europa.eu/news/en/press-room/20240308IPR19015/artificial-intelligence-act-meps-adopt-landmark-law> (дата обращения: 28.08.2024).
13. WG-114 AI Standards in Aviation. URL: <https://www.eurocontrol.int/sites/default/files/2024-04/20240429-flyai-forum-session-2-guegan.pdf> (дата обращения: 28.08.2024).
14. Курс на непрерывное развитие: эксперты о трендах авиаотрасли // Крылья Родины. 2023. № 9–10. С. 43–45.

*Д. С. Долженкова\**

студент

*А. П. Соколова\**

студент

*М. Ю. Егоров\*\*\**

кандидат технических наук, доцент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

\*\*Петербургский государственный университет путей сообщения Императора Александра I

\*\*\*Санкт-Петербургский государственный лесотехнический университет им. С. М. Кирова

## АДАПТИВНЫЕ СИСТЕМЫ УПРАВЛЕНИЯ АВТОНОМНЫМИ СИСТЕМАМИ В УСЛОВИЯХ КОСМИЧЕСКОГО ПРОСТРАНСТВА

Повреждения, отказы и отрицательные воздействия на воздушные судна могут привести к неопределенному изменению параметров модели судна. Рассмотрен подход к управлению автономными системами в условиях открытого космоса и осуществлен анализ адаптивных методов управления космическими аппаратами с учетом изменяющейся во времени среды. Приведены структура и обоснование одного из типов отказоустойчивых контроллеров полета MRAC, который содержит эталонную адаптивную теорию модели, но остается чувствительным к временным изменениям. Представлена отфильтрованная и оптимизированная концепция управления – L1 Adaptive Control. Показано, что методы управления решают задачи динамичности окружающей среды, снижают высокие уровни неопределенности и обеспечивают самообучение. Адаптивные алгоритмы становятся ключевым инструментом для эффективной работы автономных космических аппаратов.

**Ключевые слова:** отказоустойчивое управление, адаптивное управление, автономные системы, эталонная модель.

Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации, соглашение № FSRF-2023-0003, «Фундаментальные основы построения помехозащищенных систем космической и спутниковой связи, относительной навигации, технического зрения и аэрокосмического мониторинга».

*D. S. Dolzhenkova\**

Student

*A. P. Sokolova\**

Student

*M. Yu. Egorov\*\*\**

PhD, Tech., Associate Professor

\*St. Petersburg State University of Aerospace Instrumentation

\*\*Emperor Alexander I St. Petersburg State Transport University

\*\*\*St. Petersburg State Forest Technical University

## ADAPTIVE CONTROL SYSTEMS OF AUTONOMOUS SYSTEMS IN SPACE CONDITIONS

Nowadays all modern aircrafts are complex technical systems. Obviously, there will be an increasing complexity in newly invented and developed vehicles. Thereby, a great role in aviation safety plays correct technical process management and its security. Some defects, failures and other variety of negative impacts may cause changes of parameters of a flying model, so for this reason to solve the problem an approach to managing autonomous systems in a space was considered. Moreover, an analysis of adaptive methods for controlling spacecraft was carried out according to time-varying environment. The structure and justification for one type of fault-tolerant flight controller MRAC, which contains a reference adaptive model theory but remains sensitive to temporal changes, was presented. A filtered and more advanced version of the control system, L1 Adaptive Control, has been presented to prevent problems arising. It's connected as a spare module to the main control system and constantly monitors all its parameters during the flight. The essence of L1 work can be defined as the collection and analysis of data on transient states of the aircraft, including the processing of all kinds of inaccuracies of on-board sensors. The main feature of L1 Adaptive Control is fast and robust adaptation, which doesn't depend on a choice between efficiency and reliability. The presented control methods solve such problems as environmental dynamism, high levels of uncertainty and the need for self-learning, so adaptive algorithms are becoming a key tool to ensure efficient operation of autonomous spacecraft.

**Keywords:** fault-tolerant management, adaptive management, autonomous systems, reference model.

### Актуальность

Беспилотные летательные аппараты (БПЛА) становятся распространенными благодаря возможности их использования в сложных условиях [1]. Высокая степень неопределенности и изменчивости в космической среде ставит акцент на повышение устойчивости БПЛА и оптимизации их систем управления. Адаптивные методы управления показывают преимущества в условиях недостатка информации, позволяя эффективно справляться с

возникающими сложностями [2; 3]. Адаптивные алгоритмы обладают способностью динамически корректировать управляющие параметры в ответ на изменения условий, тем самым сохраняя эксплуатационные характеристики и обеспечивая безопасность. Это особенно важно для систем, уязвимых к ошибкам.

**Цель исследования** – анализ преимуществ адаптивных алгоритмов для управления автономными малыми космическими аппаратами в условиях открытого космоса с акцентом на необходимость изменения параметров управления в реальном времени. Продемонстрировано, как адаптивные подходы могут способствовать повышению эффективности и надежности работы автономных космических аппаратов.

### Методы и материалы

Отказоустойчивое управление можно подразделить на пассивное и активное в зависимости от методов реализации. Пассивное управление основано на высоконадежных схемах со стационарным контроллером с низкой чувствительностью к сбоям в системе для функционирования в условиях меньшей неопределенности. Активное управление, напротив, сосредоточивается на перепроектировании системы с учетом предсказуемых характеристик после возникновения неисправности, что способствует новой стабилизации. Эта форма управления обладает более широкими возможностями для развития и практического применения, так как в аварийном состоянии система перестраивает управление для достижения либо нормального, либо частично управляемого состояния. Адаптивный контроллер вступает в работу только при превышении порогового значения отклонений, не активируясь при нормальных ошибках.

Суммарный входной сигнал системы равен  $u = u_{bas} + u_{ada}$ , где  $u$  – выходной сигнал отказоустойчивой системы управления,  $u_{bas}$  – выходной сигнал базового контроллера,  $u_{ada}$  – выходной сигнал адаптивного контроллера. Структурная схема отказоустойчивой системы управления показана на рис. 1.

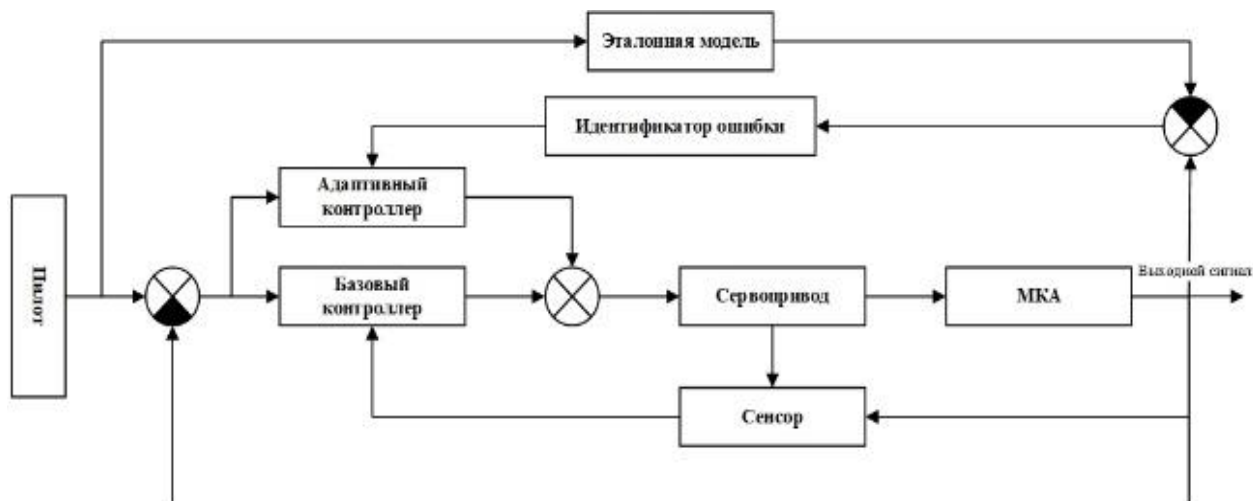


Рис. 1. Структурная схема отказоустойчивой системы управления

В нормальных условиях адаптивный контроллер предназначен для повышения надежности системы. Линейные стационарные системы ЛТИ служат точными приближениями динамики МКА. При значительных сбоях и неопределенностях их динамика становится сильно связанной, т. е. изменения в одном элементе системы могут существенно влиять на другие элементы и на общее поведение системы. В таких ситуациях контроллер базовой линии может выдать ошибку управления или полностью утратить управление, что требует активации адаптивной составляющей контроллера.

Системы адаптивного управления могут быть сконструированы таким образом, чтобы выходные данные установки соответствовали выходным данным эталонной модели – этот метод управления носит название «адаптивное управление с использованием эталонной модели» (MRAC). Он обладает преимуществами простой структуры, быстрой и стабильной реконфигурации. Адаптивное управление эталонной моделью предназначено для создания контроллера с замкнутым контуром с изменяемыми параметрами. Целью настройки параметров для прямого MRAC (рис. 2) будет реакция установки, соответствующая реакции эталонной модели, а для косвенного – имитирующая поведение установки.



Рис. 2. Прямой MRAC, при котором параметры контроллера обновляются в режиме реального времени

### Анализ результатов

Рассмотрим скалярный случай, в котором установка описывается уравнением  $\dot{x} = ax + bu$ , где состояние  $x(t)$  принадлежит  $\mathbb{R}$ , а входное усиление  $b > 0$ . Целью является приведение состояния установки в соответствие с эталонной моделью, заданной уравнением  $\dot{x}_m = -a_m x_m + b_m r$ , где  $r(t)$  также принадлежит  $\mathbb{R}$  и выступает в роли эталонного входного сигнала.

Структура контроллера может быть представлена как  $u = -kx + dr$ , что включает функции обратной связи и прямой трансляции. Параметры контроллера  $k$  и  $d$  являются неизвестными и должны быть определены так, чтобы ошибка отслеживания состояния  $e(t) = x(t) - x_m(t)$  стремилась к нулю или была минимизирована. Этого можно достичь путем настройки параметров контроллера в реальном времени, что может быть проиллюстрировано с использованием метода Ляпунова [4; 5].

Если параметры контроллера настраиваются по законам  $\dot{k} = \alpha e x$  и  $\dot{d} = -\beta e x$ , где  $\alpha$  и  $\beta > 0$ , то ошибка отслеживания  $e(t)$  будет со временем стремиться к нулю. Коэффициент обратной связи  $k$  настраивается с учетом произведения входных данных  $x(t)$  и ошибки отслеживания  $e(t)$ , в то время как коэффициент прямой связи  $d$  настраивается на основе произведения входных данных  $r(t)$  и той же ошибки  $e(t)$ . Законы динамической настройки для неизвестных параметров контроллера, подобно его структуре управления, позволяют гарантировать, что ошибка отслеживания  $e(t)$  будет равна нулю для любой скалярной установки с положительным коэффициентом управления  $b$ .

MRAC широко используется, но он особенно чувствителен к временным задержкам. Для предоставления более реалистичного адаптивного решения разработана отфильтрованная версия MRAC – L1 Adaptive Control. Адаптивное управление L1 реализует архитектуру, в которой управляющий сигнал  $u$  дополняется отфильтрованной версией адаптивного сигнала с высоким коэффициентом усиления. Динамика ошибок основывается не на традиционной эталонной модели, а на системе прогнозирования, которая представляет комбинацию эталонной модели и разности между отфильтрованным и нефильтрованным адаптивным сигналом. Применение фильтра приводит к тому, что выходной сигнал представляет реализуемый результат системы и является целью, к которой она должна стремиться, учитывая ограничения пропускной способности приводов и вычислительных ресурсов.

Поэтому важен прогноз запаса адаптивного контроллера относительно времени задержки выходного измерения. Для этого анализа создаются адаптивные комплексные системы, которые обеспечивают общую настройку управления и обратной связи.

На первом (нижнем) уровне адаптации решается задача автоматической подстройки параметров измерительной аппаратуры, которые могут изменяться под воздействием различных факторов. Это достигается с помощью адаптивных и интеллектуальных датчиков, способных идентифицировать и контролировать выходную информацию, а также адаптировать режимы работы для снижения влияния возмущений.

На втором уровне адаптации необходимо оптимально оценить текущий вектор навигации и ориентации МКА, основываясь на первичных навигационных параметрах. В условиях возмущающих факторов для этой задачи используются алгоритмы обработки навигационной информации с применением искусственного интеллекта. Это позволяет обрабатывать большие объемы данных в реальном времени и обеспечивать быструю реакцию в изменяющихся условиях.

## Выводы

1. Адаптивное управление представляет собой метод, позволяющий в режиме реального времени корректировать параметры управления автономными автоматическими объектами.
2. Метод обеспечивает эффективную реакцию на изменяющиеся условия и характеристики системы.
3. Предложенный подход способствует повышению производительности и надежности систем, работающих автономно в космическом пространстве, так как способен справляться с непредсказуемыми изменениями и новыми параметрами, что позволяет поддерживать высокую эффективность работы без вмешательства человека.

## Библиографический список

1. Гончарова Н. П., Примачук В. С. Беспилотные летательные аппараты в современном мире. Краткий обзор и перспективы развития // Символ науки. 2023. № 6-2. С. 12–14.
2. Anderson B. D., Dehghani A. Challenges of adaptive control: past, permanent and future // Annual Reviews in Control. 2008. Vol. 32, № 2. P. 123–135.
3. Knoebel N. Adaptive Control of a Miniature Tailsitter UAV // American Control Conference. Westin Seattle Hotel, Seattle, Washington, USA. June 11–13, 2008. P. 2340–2345.
4. Есаков В. А., Дудко В. Г., Шлопак А. А. Синтез адаптивных систем методом функций Ляпунова // Проблемы современной науки и образования. 2018. № 12. С. 47–50.
5. Ким Д. П. Теория автоматического управления. Многомерные, нелинейные, оптимальные и адаптивные системы. М.: Юрайт, 2024. 441 с.

*Д. В. Зелнев\**

курсант

*А. Р. Лыков\**

курсант

*М. Н. Волков\**

кандидат технических наук – научный руководитель

\*Военно-космическая академия имени А. Ф. Можайского, Санкт-Петербург, Россия

## ГЕНЕРАЦИЯ СИНТЕТИЧЕСКИХ ТЕЛЕМЕТРИЧЕСКИХ ДАННЫХ ДЛЯ ТЕСТИРОВАНИЯ СИСТЕМ КОНТРОЛЯ И ДИАГНОСТИКИ БОРТОВЫХ СИСТЕМ КОСМИЧЕСКИХ АППАРАТОВ

Рассматривается проблема синтеза телеметрических данных для тестирования систем контроля и диагностики бортовых систем космических аппаратов (КА). Предлагается использовать генеративно-состязательные нейронные сети (ГСНС) для генерации искусственных телеметрических данных, имитирующих реальные данные, полученные с борта КА. Описывается архитектура ГСНС, используемая для синтеза телеметрических данных, и результаты экспериментов по генерации данных для бортовой системы электроснабжения. Показана эффективность применения ГСНС для синтеза телеметрических данных и перспективы их использования в тестировании систем контроля и диагностики бортовых систем КА.

**Ключевые слова:** бортовые системы, синтетические данные.

*D. V. Zelenev\**

Cadet

*A. R. Lykov\**

Cadet

*M. N. Volkov\**

PhD, Tech. – Scientific Adviser

\*Mozhaisky Military Space Academy, St. Petersburg, Russia

## GENERATION OF SYNTHETIC TELEMETRY DATA FOR TESTING CONTROL AND DIAGNOSTIC SYSTEMS OF SPACECRAFT

The article considers the problem of the synthesis of telemetry data for testing control systems and diagnostics of spacecraft (SC) systems. It is proposed to use generative-concurrent neural networks (GCNN) for generating artificial telemetry data simulating real data obtained from the spacecraft. Describes the GCNN architecture used for telemetry synthesis and results of experiments on generating data for the onboard power supply system. The effectiveness of GCNN for telemetry synthesis has been shown and its potential to be used in testing of control systems and diagnostics of on-board spacecraft systems.

**Keywords:** on-board systems, synthetic data.

### Введение

Тестирование систем контроля и диагностики бортовых систем КА – критически важный этап в процессе разработки и эксплуатации КА. Один из ключевых аспектов тестирования – использование репрезентативных телеметрических данных, которые позволяют оценить эффективность алгоритмов контроля и диагностики. Однако получение реальных телеметрических данных может быть затруднено из-за ограниченности доступа к КА, особенно на ранних стадиях разработки. В статье предложен метод генерации синтетических телеметрических данных, который позволяет создать реалистичные наборы данных для тестирования систем контроля и диагностики бортовых систем КА.

### Синтетические данные

Синтетические данные – это искусственные данные, имитирующие наблюдения реального мира и используемые для подготовки моделей машинного обучения, когда получение реальных данных невозможно из-за сложности или дороговизны. Они отличаются от аугментированных и рандомизированных данных [1; 2]. Аугментирование данных добавляет слегка измененные копии существующих элементов к текущему набору данных, а рандомизаторы данных лишь сдвигают элементы в пуле данных, не создавая новых. Синтетические данные, наоборот, предоставляют новые, но имитирующие реальные данные, обладающие характеристиками исходного набора данных.



Существуют два типа синтетических данных: частичные и полные. Частичный тип – это набор данных, включающий синтетические данные и реальные данные из наблюдений и измерений. Полные синтетические данные полностью генерируются компьютером и не содержат реальных данных [3–5].

Синтетические данные могут быть созданы с помощью вычислительных алгоритмов и инструментов генерации. Они могут быть созданы по запросу и практически в неограниченном масштабе, что особенно полезно для создания гибридных наборов данных, в которых статистические свойства реальных данных сочетаются с дополнительными синтетическими элементами. Это позволяет экономично получить большой объем данных и присваивать метки (классифицировать или маркировать) для всех созданных данных, что полезно для сценариев с машинным обучением [6].

Синтетические данные могут быть использованы для тестирования моделей машинного обучения, когда нет достаточного количества реальных данных, чтобы получить нужную точность машинного обучения.

### Генеративно-сопоставительные нейронные сети

Генеративно-сопоставительные нейронные сети (ГНС) представляют собой мощный инструмент в области машинного обучения, позволяющий генерировать новые данные, неотличимые от подлинных. Это достигается за счет конкуренции между двумя нейронными сетями: генератором и дискриминатором. ГНС состоит из двух основных компонентов: генератора и дискриминатора. Генератор отвечает за создание новых данных на основе входных данных, а дискриминатор пытается определить, являются ли сгенерированные данные подлинными или поддельными. В процессе обучения генератор и дискриминатор конкурируют друг с другом, что приводит к улучшению качества сгенерированных данных [7].

Преимущество ГНС заключается в способности генерировать новые данные, неотличимые от подлинных. Недостатки ГНС заключаются в сложности в обучении, что может требовать значительных вычислительных ресурсов и возможность генерации данных, которые не соответствуют ожидаемым результатам.

### Архитектура ГНС для синтеза телеметрических данных

Архитектура ГНС для синтеза телеметрических данных состоит из двух основных компонентов: генератора и дискриминатора. Генератор будет создавать синтетические телеметрические данные, а дискриминатор – оценивать их достоверность, сравнивая с реальными данными.

Генератор (G) – это нейронная сеть, которая принимает на вход случайный шум (например, из нормального распределения) и генерирует из него телеметрические данные. Архитектура генератора может быть основана на глубоких сверточных нейронных сетях (DCGAN) или других современных архитектурах, таких как StyleGAN или BigGAN [6–10]. Для телеметрических данных, которые часто представляют собой временные ряды, можно использовать рекуррентные нейронные сети (RNN) или их вариации, такие как LSTM или GRU. Входной шум будет преобразован в скрытое представление, которое затем будет декодировано в телеметрические данные.

Вход: случайный шум  $z$  (например, из нормального распределения).

Выход: синтетические телеметрические данные  $G(z)$ .

Дискриминатор (D) – это нейронная сеть, которая принимает на вход как реальные, так и синтетические телеметрические данные и пытается классифицировать их как настоящие или сгенерированные. Дискриминатор также может быть основан на глубоких сверточных нейронных сетях или рекуррентных нейронных сетях, в зависимости от структуры телеметрических данных.

Вход: реальные телеметрические данные ( $x$ ) или синтетические телеметрические данные  $G(z)$ .

Выход: вероятность того, что входные данные являются реальными  $D(x)$  или сгенерированными  $D(G(z))$ .

Обучение GAN происходит путем совместной оптимизации генератора и дискриминатора. Генератор пытается создать синтетические данные, которые дискриминатор не сможет отличить от реальных. Дискриминатор, в свою очередь, пытается улучшить свою способность отличать реальные данные от синтетических. Это можно формализовать следующим образом.

Функция потерь для дискриминатора:

$$L_D = -[\log(D(x)) + \log(1 - D(G(z)))].$$

Функция потерь для генератора:

$$L_G = -\log(D(G(z))).$$

Обучение GAN может быть нестабильным, поэтому рекомендуется использовать различные техники стабилизации, такие как добавление шума к входным данным дискриминатора, использование метода градиентного штрафа или применение более продвинутых архитектур, таких как WGAN или WGAN-GP.

### Эксперименты

Для оценки эффективности ГНС в синтезе телеметрических данных были проведены эксперименты по генерации данных для бортовой системы электроснабжения. Были использованы следующие типы данных:

- температурные данные от датчиков температуры бортовых систем (рис. 1);
- данные о уровне заряда аккумуляторов.




Рис. 1. Реальные значения температуры панелей солнечных батарей

Результаты экспериментов показали, что ГСНС могут генерировать телеметрические данные, которые близки к реальным данным (рис. 2), полученным с борта КА. Было обнаружено, что ГСНС могут учитывать сложные взаимосвязи между различными параметрами бортовых систем, что позволяет получать более адекватные результаты.




Рис. 2. Синтезированные значения температуры панелей солнечных батарей

### Заключение

Была рассмотрена проблема синтеза телеметрических данных для тестирования систем контроля и диагностики бортовых систем КА. Было предложено использовать генеративно-сопоставительные нейронные сети для генерации искусственных телеметрических данных, имитирующих реальные данные, полученные с борта КА. Результаты экспериментов показали эффективность применения ГСНС для синтеза телеметрических данных и перспективы их использования в тестировании систем контроля и диагностики бортовых систем КА.

### Библиографический список

1. *Лекун Я.* Как учится машина: Революция в области нейронных сетей и глубокого обучения. М., 2021. 370 с.
2. *Гудфеллоу Я., Бенджио И., Курвилль А.* Глубокое обучение. М., 2018. 653 с.
3. *Безгачев Ф. В.* Применение нейросетей в искусственной генерации лиц. 2021. URL: <https://cyberleninka.ru/article/n/primenenie-neyrosetey-v-iskusstvennoy-generatsii-lits> (дата обращения: 10.08.2024).
4. *Паттанаяк С.* Генерация изображений с помощью TensorFlow. М., 2022. 698 с.
5. *Редько В. Г.* Эволюция, нейронные сети, интеллект: Модели и концепции эволюционной кибернетики. М.: Ленанд, 2019. 224 с.
6. *Cigiano A.* Generative adversarial networks. 2018. URL: <https://www.linkedin.com/pulse/generative-adversarial-networks-andrea-cigiano> (дата обращения: 10.08.2024).
7. *Ха Д., Шмидхубер Ю.* Модели мира. 2018. 21 с.
8. *Галушкин А. И.* Нейронные сети: основы теории. М.: РиС, 2023. 496 с.
9. *Андреева О. В.* Формирование оптимального алгоритма верификации изображений на основе нейронных сетей // Современные проблемы науки и образования. 2015. № 1-1. С. 268.
10. *Мазуров М. Е.* Распознавание сложных объектов избирательными нейронными // Нейрокомпьютеры и их применение: тез. докл. М., 2022. С. 60–61.

**В. С. Ковтун**

кандидат технических наук

Ракетно-космическая корпорация «Энергия» имени С. П. Королева, Королев, Россия

## КОНЦЕПТУАЛЬНАЯ МОДЕЛЬ СИТУАЦИОННОГО УПРАВЛЕНИЯ ДИНАМИЧЕСКИМИ СИСТЕМАМИ В СИНЕРГЕТИЧЕСКОЙ СРЕДЕ

Представлена концептуальная модель ситуационного управления динамическими системами в синергетической среде, построенная на базе опыта, приобретенного при управлении полетом автоматических космических аппаратов.

**Ключевые слова:** динамические системы, управление полетом, надежность автоматических космических аппаратов, системные исследования, живучесть, синергетическая среда.

**V. S. Kovtun**

PhD, Tech.

S. P. Korolev Rocket and Space Public Corporation Energia, Korolev, Russia

## CONCEPTUAL MODEL OF SITUATION MANAGEMENT OF DYNAMIC SYSTEMS IN SYNERGISTIC ENVIRONMENT

The paper presents a conceptual model of situational control of dynamic systems in synergistic environment, based on experience acquired in the management of automatic spacecraft flight.

**Keywords:** dynamic systems, flight control, reliability of automatic spacecraft, system research, resilience, synergistic environment.

### Введение

Построение концептуальной модели ситуационного управления динамическими системами в синергетической среде производится на базе опыта, приобретенного при управлении полетом автоматических космических аппаратов (АКА). Современные методы управления полетом АКА как сложной технической системой (СТС) базируются на двух методологических подходах – реактивно-событийном и проактивно-ситуационном, – построенных на принципах использования структурно-функциональной избыточности ресурсов бортовых систем (БС), позволяющих гибко реагировать на изменение ситуации, при условии эквивалентности понятий управления полетом АКА и ресурсного обеспечения.

При реактивно-событийном управлении полетом АКА после выработки ресурса или возникновения нештатной ситуации (НШС) производится переход на структурно-функциональные резервы по алгоритмам изменения конфигурации и реконфигурации БС с целью парирования и ликвидации или минимизации последствий НШС.

В проактивно-ситуационном управлении полетом АКА в интеллектуальных информационно-аналитических системах поддержки жизненного цикла путем комплексного моделирования постоянно прогнозируется развитие процессов в БС с целью предотвращения НШС. При расхождении текущей ситуации с заранее подготовленными эталонными сценариями «ситуация → решение» (ситуационными моделями) на основании результатов оценки текущего технического состояния (ТС) БС производится идентификация предполагаемой НШС, разрабатываются и выполняются мероприятия по ее предотвращению или минимизации негативных последствий.

В обоих случаях предусмотрена процедура оперативной идентификации ситуаций для задействования структурно-функциональных резервов. В первом случае в результате отказа происходит частичная или полная потеря ресурса БС, а во втором – при определении причин негативного развития ситуации и их устранения возможно предотвращение отказа.

При реактивно-событийном управлении оптимизация расхода ресурсов осуществляется выбором параметрических характеристик БС, задействованных для выполнения полетных операций. При проактивно-ситуационном управлении за счет ситуационного многовариантного поискового прогнозирования полетных операций (*вариабельного управления*) создается множество вариантов развития фрагмента программы полета. Далее на базе множества производится выбор варианта, удовлетворяющего требованиям рационального расхода ресурсов БС.

Прогноз развития ситуации в БС до наступления критического состояния, если невозможно его предотвратить, позволяет заранее подготовить пути обхода поврежденного в результате аномальной ситуации участка БС (через «байпасы» [1]) либо обеспечить наилучшие условия эксплуатации для уменьшения деградации систем [2]. Подготовка к недопущению аномальных ситуаций и устранению последствий за счет дополнительных структурно-функциональных (байпасных) резервов комплексно повышает структурную устойчивость, адаптируемость и самоорганизуемость бортовых систем аппарата в условиях различного рода возмущающих воздействий по сравнению с альтернативным реактивно-событийным методологическим подходом к управлению полетом АКА.

Перечисленные результаты концептуального сравнительного анализа свидетельствуют о преимуществе проактивно-вариабельного ситуационного управления при обеспечении полетным ресурсом АКА и поддержании устойчивости работы его по сравнению с реактивно-событийным управлением. При этом преимущество обеспечивается решением неформальных творческих задач из области инженерных знаний, характеризуемых большим количеством форм представления данных и, соответственно, типов моделей представления знаний (МПЗ) о БС и их элементах как объектах исследования [2]. То есть решениям предшествуют когнитивная обработка и тиражирование априорной информации с оцениванием ТС систем для последующего прогнозирования и создания вариантов выполнения программы полета. Таким образом, *проактивное вариабельное ситуационное* обеспечение полетным ресурсом АКА, базирующееся на знаниях экспертов, модифицируется в *проактивное когнитивно-вариабельное ситуационное* (КВС-СТ) управление полетом аппаратов.

На основе принципиально нового КВС-СТ подхода разработаны методологические, методические, технологические и теоретические основы решения современных проблем комплексной автоматизации и интеллектуализации проактивного (упреждающего) управления жизненным циклом (ЖЦ) АКА [3].

В статье представлен *частный* (неформальный) *случай развития ситуаций с проявлением синергетического поведения систем на этапе эксплуатации*, которое обусловлено выработкой ресурса и возникновением новых связей при обмене между собой и с внешней средой энергией, веществом и информацией, а также когерентным и кооперативным взаимодействием. То есть рассматривается *когнитивно-вариабельный ситуационно-синергетический подход* (КВС-СН) к управлению ЖЦ АКА. Неформальность развития ситуации определяется невозможностью использования для управления БС заранее подготовленных (формальных) сценариев в виде ситуационных эталонных моделей.

### Обобщенное описание движения динамической системы в синергетической среде

Теория проактивного управления (ТПУ) ЖЦ АКА на базе КВС-СТ подхода внесла существенный вклад в развитие современной информатики. Благодаря ей современная информатика на конструктивном уровне обогатилась методологией и методическим обеспечением, разработанным в классической кибернетической теории управления (КТУ), при создании интеллектуальной информационно-аналитической платформы (ИИАП) проактивного управления ЖЦ АКА [1]. Применяемые методы КТУ основаны на предположении, что при разработке адаптивных систем управления, математическая модель объекта управления (ОУ) является известной и абсолютно точно описывает его поведение [4]. Однако любая модель представляет собой упрощенное (идеализированное) описание ОУ. К основным причинам упрощенного описания относятся: преднамеренное игнорирование при выделении системы из внешней среды в процессе разработки, изготовления и наземных испытаний части факторов управляющих и возмущающих сред, как величин высоких порядков малости, не оказывающих существенного влияния на основной процесс; неизвестные факторы воздействия сред на системы на момент времени их создания; неразрешенность проблемы поиска интегралов движения из-за неголономности связей, т. е. неинтегрируемости нелинейных дифференциальных уравнений, описывающих движение систем; неучитывание фактора неклонируемости свойств материальных средств реализации ОУ. Синергетические механизмы самоорганизации и самоуправления проявляют все неучтенные в математической модели факторы. При этом существуют неопределенности математической модели объекта, основными типами которых являются: параметрическая – неизвестны параметры (свойства ОУ) математической модели; сигнальная – неизвестны функции времени, которые описывают неведомые внешние возмущения, действующие на объект; функциональная – неизвестны функции координат состояния регулируемых переменных или сигналов управления; структурная – неизвестна структура математической модели объекта [5]. Математическую модель, положенную в основу синтеза алгоритма управления, называют номинальной [4].

Номинальная математическая модель классической динамической системы (ДС) задается с использованием четырех основных (базисных) множеств  $\mathbf{X}$ ,  $\mathbf{Y}$ ,  $\mathbf{V}$ ,  $\mathbf{T}$  и двух отображений  $\varphi$ ,  $\psi$  [6], где  $\mathbf{X}$  – множество состояний ДС;  $\mathbf{Y}$  – множество выходов ДС;  $\mathbf{V} = \mathbf{V} = \mathbf{B}(U) \times \mathbf{B}(\Xi)$  – множество входных воздействий,  $\mathbf{B}(U)$  – булеан множества управляющих воздействий  $U = \{u_1, u_2, \dots, u_n\}$  (УВ),  $\mathbf{B}(\Xi)$  – булеан множества внешних возмущающих воздействий  $\Xi = \{\xi_1, \xi_2, \dots, \xi_m\}$  (ВВ) детерминированной среды;  $\mathbf{T}$  – множество моментов времени;  $\varphi: \mathbf{X} \times \mathbf{V} \times \mathbf{T} \rightarrow \mathbf{X}$  – переходное отображение;  $\psi: \mathbf{X} \times \mathbf{V} \times \mathbf{T} \rightarrow \mathbf{Y}$  – выходное отображение.

По номинальной математической модели строится эталонная ситуационная модель квазистационарного движения динамической системы с параметрами неизменных связей, т. е. в условиях детерминированной возмущающей среды, характеризуемой множеством  $\Xi = \{\xi_1, \xi_2, \dots, \xi_m\}$ , возмущения от которой включены в состав множества входных воздействий на систему.

С момента начала функционирования системы условия детерминированности внешней среды нарушаются из-за возникающих синергетических явлений [7]. Элементы ДС формируют, наряду с управляющей средой, свою внутрисистемную синергетическую среду, которая для смежных ДС является внешней. В результате синергетического взаимодействия внешних сред ДС видоизменяется множество ВВ:

$$\Xi^\sigma = \{\xi_1^\sigma \dots, \xi_m^\sigma\}.$$

При этом видоизменяются и факторы воздействия внешней среды по отношению к АКА как сложной технической системе. Например, ионизирующие излучения космического пространства оказывают существенное влияние на электростатические и электромагнитные процессы в бортовых системах (аппаратуре) АКА [8]. В свою очередь, эти процессы создают внутрисистемную синергетическую среду (рис. 1).

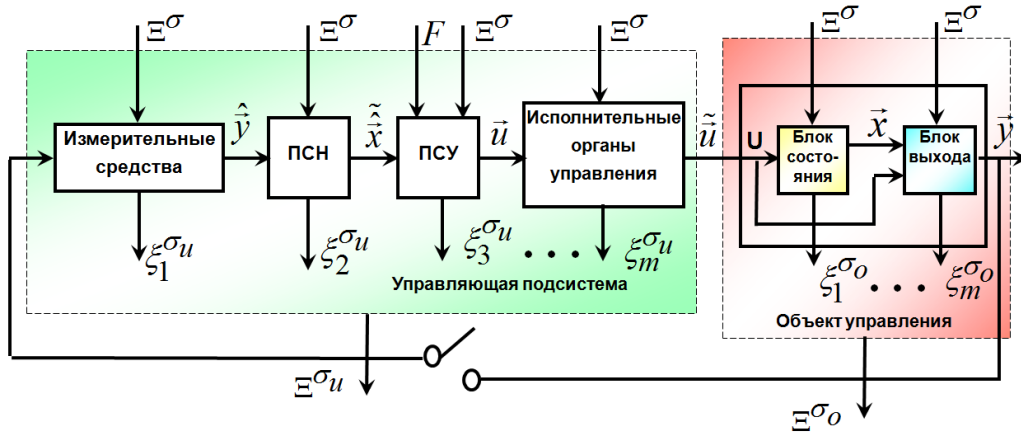


Рис. 1. Схема обобщенного описания движения целенаправленной динамической системы в синергетической среде: ПСН – подсистема наблюдения; ПСУ – подсистема управления;  $F$  – множество целей управления;  $\vec{x}$  – вектор состояния;  $\vec{y}$  – вектор выхода;  $\vec{u}$  – вектор управляющих воздействий;  $\vec{\tilde{u}}$  – преобразованный вектор управляющих воздействий;  $\hat{\vec{y}}$  – оценка вектора (измеряемых параметров) выхода;  $\hat{\vec{x}}$  – оценка вектора состояния;  $\xi_m^{\sigma_u}, \xi_m^{\sigma_o}$  – сформированные внутри системы (в УП и ОУ) синергетические связи для обмена с внешней средой энергией, веществом и информацией

Согласно определению синергетического подхода к управлению динамическими системами ( $s$ ), в общем случае каждый элемент управляющей подсистемы (УП) и ОУ может создавать свои энергетические (силовые), материальные и информационные связи [9]. Определим указанные связи соответствующими множествами с учетом того, что каждый элемент в материальном исполнении может иметь  $m$ -е количество средств реализации:

$$\Xi_s^{\sigma_u} = \{ \xi_1^{\sigma_u} \dots, \xi_m^{\sigma_u} \}_s, \quad \Xi_s^{\sigma_o} = \{ \xi_1^{\sigma_o} \dots, \xi_m^{\sigma_o} \}_s, \quad m = \overline{1, M}.$$

Далее объединим указанные множества:

$$\Xi_s^{\sigma} = \Xi_s^{\sigma_u} \cup \Xi_s^{\sigma_o}.$$

Тогда синергетическую среду  $\Xi^{\sigma}$ , воздействующую на ДС (см. рис. 1), определим покрытием семейством  $i$ -х множеств ВВ, сформированных для каждой ДС:

$$\Xi^{\sigma} \subseteq \bigcup_{i \in I} \Xi_{s_i}^{\sigma}; \Xi_{s_i}^{\sigma} \cap \Xi_{s_j}^{\sigma} \neq \emptyset; \forall_i, \forall_j \in \{1, \dots, M\} = I.$$

### Концептуальная модель адаптивного управления динамической системой в синергетической среде

В сформированной синергетической среде вступает в силу закон единства процессов самоорганизации и управления сложными системами. Физические процессы, создающие силы, действующие на материальные объекты, формируют между ними реакции связей. Причиной движения (изменения состояния) в каждой системе является ее взаимодействие с другими внешними системами, с которыми у нее возникли соответствующие связи.

С точки зрения КТУ, «самоорганизация – процесс организации системы, протекающий при отсутствии целенаправленного действия внешнего субъекта организации и состоящий в выработке у системы рациональной структуры и принципов функционирования в результате взаимодействия ее с окружающей средой» [2]. В КТУ самоорганизация рассматривается как управление реакциями связей между системами, которые возникают в результате взаимодействия физических процессов.

Таким образом, в СТС процессы самоорганизации и управления не могут быть оторваны друг от друга, они едины и нерасторжимы. В [9] отмечается, что «...говоря языком китайской философии, это – системные „инь и янь“, всегда находящиеся в парной взаимодополняемости по отношению друг к другу», т. е. они являются символом созидательного единства противоположностей.

Синергетическая среда принуждает создавать текущие варианты управления динамическими системами, отображающие ранее неопределенные свойства поведения объекта в ходе его нормальной работы, которые учитываются адаптивными системами управления (АдСУ)<sup>1</sup>. Проведем типовую классификацию синергетической среды по отношению к реакции АдСУ на ее воздействие: синергетически управляющую среду ( $\Xi_V^\sigma$ ); синергетически номинальную среду ( $\Xi_N^\sigma$ ) и синергетически возмущающую среду ( $\Xi_W^\sigma$ ):

$$\Xi^\sigma = \Xi_V^\sigma \vee \Xi_N^\sigma \vee \Xi_W^\sigma.$$

Среди множества методов синтеза самоорганизующихся и самонастраивающихся (СНС) АдСУ для примера решения задачи управления динамическими системами в синергетической среде выберем СНС, структура регулятора которых задана (заранее выбрана) и требуется определить лишь алгоритм настройки его коэффициентов (алгоритм адаптации) [4] (рис. 2).

Задача алгоритма адаптации состоит в настройке коэффициентов регулятора таким образом, чтобы свети рассогласования между поведением ОУ и эталонной моделью к нулю. Такое управление называется прямым адаптивным, а системы – адаптивными системами с эталонной моделью [4].




Рис. 2. Структура АдСУ с эталонной моделью: 1 – ОУ; 2 – настраиваемый блок; 3 – эталонная модель; 4 – блок настройки;  $x$  – состояние ОУ;  $y$  – состояние модели объекта;  $g$  – входной задающий сигнал;  $u$  – УВ;  $f$  – внешние возмущения

ОУ 1 и настраиваемый блок 2 совместно образуют обобщенный настраиваемый объект. Блок настройки 4 по выходным сигналам объекта 1 и эталонной модели 3 автоматически настраивает блок 2 так, чтобы основная замкнутая система 1 совпадала по структуре и параметрам с эталонной моделью 3. Так как в эталонной модели заложены желаемые динамические свойства основной системы, то благодаря указанной самонастройке система будет сохранять желаемые динамические свойства.

### Синергетически управляющая среда $\Xi_V^\sigma$

В синергетически управляющей среде решаются задачи поиска путей целевого использования синергетических взаимосвязей при прямом адаптивном управлении. Условия, при которых ведется управление, не выходят за рамки гипотез, положенных в основу построения математических моделей ОУ, а закон управления обладает определенной робастностью, при которой настраиваемый регулятор в составе элементов 2, 3, 4 справляется с неопределенностями, поддерживая квазистационарное движение процессов. Путем параметрической настройки эталонной модели 3 (см. рис. 2) АдСУ обеспечивают получение синергетических ресурсов систем [1; 7]. За счет целенаправленного управления сформировавшимися внутри системы синергетическими связями, в соответствии с эталонной моделью синергетически управляющей среды, создается среда внешних воздействий  $\Xi_V^\sigma$ , которая обеспечивает рациональный расход существующих (ресурсосберегаемость) и получение дополнительных ресурсов средств реализации для смежных АдСУ. Внутрисистемные синергетические взаимосвязи и взаимодействия, формируемые при управлении по заданному эталону модели, создают синергетическую среду, которая воздействует на смежные динамические системы и является для них управляющей. В управлении через синергетическую среду будем различать  $i$ -е системы, формирующие управляющую среду  $\hat{S}_i^\sigma$ , и системы, управляемые

<sup>1</sup> АдСУ – системы, сохраняющие нормальную работоспособность в условиях неопределенности и изменчивости характеристик объекта управления и возмущений, действующих на него [4].

с использованием синергетически сформированной среды  $\hat{S}_{V_i}^\sigma$ . При этом системы, формирующие синергетическую среду, не теряют своей функциональности. Таким образом, целенаправленность управления обеспечивает внутри функциональную (техническую) эффективность управления полетом АКА как СТС. Она определяется набором группы показателей интенсивности и равномерности расходования ресурсов бортовых систем, которые приводятся к единому показателю – располагаемому полетному времени [10].

В динамических системах, формирующих синергетическую среду, регулирование заключается в выработке по определенному закону УВ в УП, обеспечивающих номинальное движение системы в соответствии с эталонной моделью с одновременным формированием управляющей синергетической среды. При этом регулятором основного целевого процесса является УП в составе определенного набора элементов (см. рис. 1), а формирователем синергетической среды может быть один или совокупность элементов из УП и ОУ. В [11] представлен один из типовых примеров динамической модели переменной системы-регулятора процессов в объектах управления ОУ1 и ОУ2.

На рис. 3 представлены две динамические системы управления СУ1 и СУ2, каждая из которых состоит из управляющих подсистем УП1, УП2 и объектов управления ОУ1, ОУ2. В свою очередь, каждый ОУ представлен своими блоками состояния БС1, БС2 и блоками выхода БВ1, БВ2. Кроме указанных, введены обозначения множеств:  $X_1, X_2$  – состояний ОУ1, ОУ2;  $Y_1, Y_2$  – выходов ОУ1, ОУ2;  $\Xi$  – возмущающих воздействий;  $U_1, U_2$  – управляющих воздействий на ОУ1, ОУ2. При этом управление ведется через множества входных воздействий  $V_1$  и  $V_2$ , построенных на бинарных отношениях декартовых произведений,  $V_1 = U_1 \times \Xi, V_2 = U_2 \times \Xi$ .

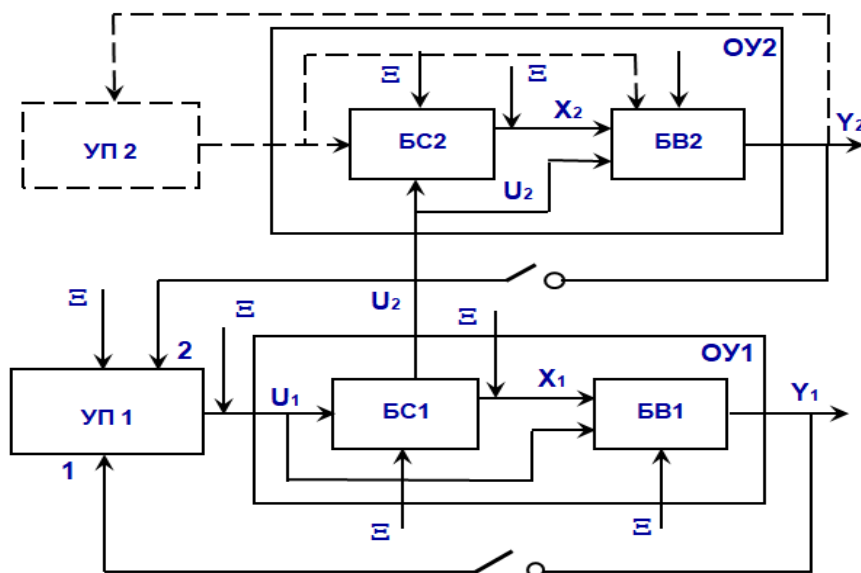


Рис. 3. Структурная схема динамической модели переменной системы-регулятора процессов в объектах управления ОУ1 и ОУ2

Как видно из рис. 3, традиционное управление БС2 в СУ2 через УП2 заменено управлением через БС1 с учетом второй обратной связи между БВ2 и УП1. При этом выход БВ1 соединен с первым входом УП1. Управляющее воздействие  $U_1$  формируется с учетом того, что при выполнении БС1 своих функций процессы одновременно формируют управляющее воздействие  $U_2$  для БС2 через синергетически сформированную среду (связь беспроводная). При этом соблюдается условие сохранения функциональности БС1, в том числе после прекращения управления по линии  $U_2$ . БС1 в составе ОУ1 является исполнительным органом управления для БС2 в ОУ2. Наличие управления по линии  $U_2$  создает функциональный резерв управления ОУ2. Если линию не использовать, то для управления ОУ2 требуется задействовать дополнительную УП2. Система СУ1 обладает «свойством переменной» в виде вариантов управления БС1 или БС1 и БС2, т. е. является одновременно системой – регулятором процессов двух блоков состояния БС1 и БС2 в ОУ1, ОУ2. Таким образом, СУ1 формирует управляющую синергетическую среду, а СУ2 управляется посредством сформированной синергетической среды.

В конкретном примере [11] целенаправленность управления в синергетической среде позволила получить дополнительный функциональный бортовой ресурс АКА за счет использования собственных магнитных моментов контуров питания фазированных антенных решеток (ФАР) для разгрузки силовых гироскопов от накопленного кинетического момента. Управляющие разгрузочные моменты создавались от взаимодействия собственных магнитных моментов с магнитным полем Земли. При этом функциональная эффективность ФАР не ухудшалась.

В управлении полетом АКА неоднократно наблюдались случаи, когда регуляторами синергетической среды являлись элементы управляющей подсистемы. Так, на геостационарном спутнике связи «Ямал-100» при

работе регулятора тока (РТ) в блоке управления системой электропитания синергетически образованная РТ электромагнитная среда оказывала влияние на работу находящегося рядом (на одной приборной панели) измерителя вектора угловой скорости. Причем наблюдалась однозначная корреляционная зависимость между величиной регулируемого тока и точностью показаний измерителя. В свою очередь, от точности показаний измерителя напрямую зависел ресурс работающего с ним в паре звездного датчика (ЗД). Количество включений и продолжительность работы ЗД для коррекции работы бесплатформенной инерциально-навигационной системы спутника зависели от точности показаний измерителя угловой скорости: с увеличением ошибки в измерениях угловой скорости ЗД включался чаще и на более продолжительное время. Через синергетически управляющую среду выбором значений тока РТ обеспечивалась минимальная ошибка измерений. Тем самым уменьшалась интенсивность выработки ресурса ЗД, что обеспечивало повышение функциональной эффективности АКА в целом.

### Синергетически номинальная среда $\Xi_N^\sigma$

Одной из наиболее сложных является проблема управления динамическими системами в условиях неопределенности, когда на ОУ действуют одновременно сигнальные и параметрические возмущения, выходящие за рамки гипотез, положенных в основу построения математических моделей объекта [5]. Параметры ОУ могут изменяться во времени по неизвестным законам, при этом стоит задача выстроить регулирование динамической системы, которое обеспечит ее работоспособность и желаемые свойства в условиях неустрашимой регулятором нестационарности.

Один из методов решения такой задачи – применение непрямого адаптивного управления. Сначала в системе управления проводится идентификация УП и ОУ, формирующих внешние возмущения синергетической среды. Далее осуществляются идентификация и определение характеристик элементов УП и ОУ систем, внешних по отношению к рассматриваемой системе управления. Если устранить эти воздействия невозможно, по результатам идентификации производится уменьшение негативного влияния внешних сигнальных и параметрических возмущений синергетической среды на работу ОУ рассматриваемой системы путем введения синергетического взаимодействия с другими смежными системами. *Компенсация влияния вновь полученной нестационарности в ОУ на динамику системы решается введением в эталон регулятора закона управления коррекции, учитывающей специально организованную синергетическую среду нестационарности, воздействующей на ОУ управляемой системы.* Совокупность нестационарных характеристик регулятора и ОУ обеспечивает стационарность общего процесса в системе управления. Соответствующие коэффициенты регулятора процесса определяются и настраиваются с учетом воздействия на ОУ вновь введенной синергетической нестационарности среды.

Таким образом, за счет воздействия специально организованной синергетической среды на ОУ и введения в регулятор новых настроек, учитывающих введенную нестационарность, производится организация работы систем в синергетически номинальной среде. При этом необходимо отличать системы, формирующие синергетическую нестационарность  $\hat{S}_i^\sigma$ , от систем, в которых указанная нестационарность используется  $\hat{S}_{N_i}^\sigma$ .

Рассмотрим пример построения синергетически номинальной среды в аккумуляторах модуля никель-водородных аккумуляторов (МНВА) геостационарного спутника связи «Ямал-100» [12]. Регулятором температурных процессов в зоне электрохимической реакции никель-водородных аккумуляторов являлся радиационный теплообменник (РТО) в составе МНВА. При внешнем синергетическом воздействии на поверхность РТО переоблученного теплового потока от элементов конструкции спутника мощности холодильника радиатора в полете стало недостаточно для поддержания температур в номинальном диапазоне. Ситуация определяется через параметрическую (температурную) и сигнальную (через неизвестные внешние возмущения) неопределенность тепловой модели МНВА, обеспечивающей работу аккумуляторов. При этом синергетическую структурную нестационарность в процесс терморегулирования внесли элементы конструкции спутника, неудачно расположенные на его поверхности по отношению к РТО МНВА. Устранить негативное воздействие было невозможно. Для перехода к работе аккумуляторов в синергетически номинальной среде были проведены настройки в работе системы обеспечения температурного режима (СОТР) в отсеке, где расположены аккумуляторы. Часть тепловой энергии от аккумуляторов передавалась конструктивным элементам отсека и бортовой аппаратуре (БА) через поверхности их сферических корпусов и приводила к определенной нестационарности процессов терморегулирования БА. При общей нестационарности температуры в отсеке номинальный (стационарный) режим работы БА обеспечивался внутри приборными средствами поддержания температур и электронагревателями приборных панелей.

Таким образом, в зоне электрохимической реакции была создана синергетически номинальная среда поддержания заданного диапазона температур в зоне электрохимической реакции аккумулятора (система класса  $\hat{S}_{N_i}^\sigma$ ). При этом работа РТО-регулятора (его электронагревателей) настраивалась с учетом температуры в отсеке служебных систем спутника. Для формирования эталона процесса использовалось проактивно-синергетическое моделирование работы МНВА [12]. Системой  $\hat{S}_i^\sigma$ , создающей специально организованную синергетическую нестационарность, являлась СОТР.



## Синергетически возмущающая среда $\Xi_w^\sigma$

В случае структурной неопределенности возникает синергетически возмущающая среда, «представляющая собой весьма эффективный инструмент формирования устойчивого неравновесия систем» (А. А. Колесников) [9]. Структурная неопределенность выражается в том, что динамический порядок реального объекта выше порядка его математической модели. В КТУ это состояние динамической системы определяют как наличие немоделируемой (паразитной) динамики, т. е. размерность вектора состояния объекта  $\vec{x}$  больше размерности вектора управления  $\vec{u}$  (см. рис. 1). С точки зрения синергетической теории управления (СТУ), этим создаются условия для спонтанной самоорганизации физических процессов, которая постепенно перерастает в стихийную самоорганизацию.

Для целенаправленного управления вновь образовавшимися процессами не предусмотрены обратные связи в системах управления, т. е. не заложены соответствующие им средства наблюдения, измерения и управления, а также исполнительные органы управления. Тем самым из-за паразитной динамики не обеспечивается важнейшая функция управления – регулирования, заключающаяся в формировании по определенным законам управляющих воздействий в зависимости от наблюдаемых отклонений по отношению к параметрам траекторий движения процессов, заложенных в эталонной модели. Порядок эталонной модели выбирается равным порядку замкнутой динамической системы, а параметры этой модели выбирают так, чтобы эталонный сигнал, вырабатываемый моделью, соответствовал желаемому движению динамической системы. При этом эталонная модель должна удовлетворять двум требованиям: с одной стороны, она должна отражать все требования к выполнению функциональной эффективности динамической системы, с другой – эталонная реакция должна быть достижима для контура, организованного УП.

Невыполнение второго требования означает наличие синергетически возмущающей среды. Контроль (наблюдение с целью проверки) состояния самонастраивающихся киберфизических систем позволяет определить факт наличия такой среды. Далее предпринимаются шаги по переходу от прямого адаптивного управления системой к непрямому адаптивному управлению. Так как самоорганизующиеся регуляторы не рассчитаны на устранение структурной неопределенности [13], требуется видоизменять имеющуюся структуру системы. При этом на время перехода желательно прекратить управление системой с нарушенным прямым адаптивным управлением. В случае невозможности прекращения работы должна обеспечиваться живучесть систем, например с учетом критериальной оценки по показателю Бьесиота [14].

Следующий шаг – идентификация всех факторов синергетически возмущающей среды  $\Xi_w^\sigma$ . Для этого проводятся системно-синергетические исследования поведения АКА в синергетически возмущающей среде [7]. В состав исследований входит подробный анализ факторов, напрямую определяющих устойчивость функционирования АКА, включая солнечную компоненту, метеорные потоки, космический мусор, собственную внешнюю атмосферу, бортовые искусственные плазменные образования, электрофизические процессы на поверхности аппарата и др. Результатом становится установление систем  $\tilde{S}_i^\sigma$ , формирующих синергетически возмущающую среду, и систем, подверженных воздействию этой среды  $\tilde{S}_w^\sigma$ . Априорно известные детерминированные факторы внешней среды, с которыми адаптивная система управления ранее справлялась, могут проявляться в других сочетаниях, что дает «неожиданные» результаты комплексности воздействий [15]. При этом внешние факторы провоцируют системы на формирование собственной синергетической среды.

Следующий шаг – устранение структурной неопределенности модели поведения динамической системы – приведение вектора состояния ОУ и вектора управления к одинаковой размерности. Для этого компоненты вектора состояния ОУ должны быть наблюдаемы через измерения параметров либо через синергетические наблюдения [16]. При формировании вектора управления разрабатывается и закладывается в эталон новая синергетическая структура модели.

Концепт «структура синергетическая» определен для АКА как новый вид технической и информационной структур. В КТУ структурное преобразование (структурная динамика) АКА – это переход структуры из одного макросостояния в другое заданное макросостояние под действием различного рода причин [2]. Управление системами в синергетически возмущающей среде позволяет дополнительно к конфигурированию и реконфигурированию отдельных БС проводить межсистемные технические структурные преобразования (рефакторинг), используя для этого элементы разных систем. Например, использовать в системе управления движением АКА относительно центра масс в качестве датчика внешней информации об угловом положении связанного базиса аппарата бортовой радиомаяк (РМ). При этом РМ является элементом бортового радиотехнического комплекса «космической связи», установленного на борту геостационарного спутника [17].

Таким образом, с использованием синергетической информационной взаимосвязи в рамках управления структурной динамикой АКА производится рефакторинг системы – «процесс частичного или полного преобразования структуры системы в целях улучшения функциональности» [13].

Новый вид информационной структуры формируется с использованием результатов синергетических наблюдений – оценивания недоступных непосредственным измерениям параметров процессов в одних материальных объектах по измерениям параметров процессов, отражающих физические энергетические воздействия и

отображающих информационные взаимодействия в других материальных объектах, связанных с первыми объектами [15].

После устранения структурной неопределенности в киберфизической динамической системе производится перевод ОУ на прямое адаптивное управление с эталонной моделью, сформированной с учетом факторов синергетически возмущающей среды.

Синергетически возмущающая среда по своему истинному смыслу «самоорганизации» несет в себе интегральное сочетание различных видов возмущающих взаимодействий, имеющих глубокое содержание, «суть которого состоит в жесткости самих механизмов самоорганизации и самоуправления, отторгающих все избыточное и лишнее в системе в результате выхода ее на целевые аттракторы. Стихийная самоорганизация уничтожает все возможные химеры системы» (А.А. Колесников) [9].

В естественных природных системах эффекты самоорганизации возникают в результате изменения так называемых «управляющих параметров порядка», которые управляют поведением каждой компоненты системы. При этом структурной неопределенности в динамике реального объекта быть не может по определению, она компенсируется природными факторами.

В искусственных системах (ИС), к которым относятся АдСУ, эффекты самоорганизации формируются посредством конструирования обратных связей, которые образуют желаемые подсистемы, взаимодействующие между собой. В ИС формирование лестничных цепочек иерархии (рис. 4) кооперативных процессов по типу «система в системе» приводит в конечном итоге к коллективной функциональной эволюции подсистем, входящих в общую систему [2].

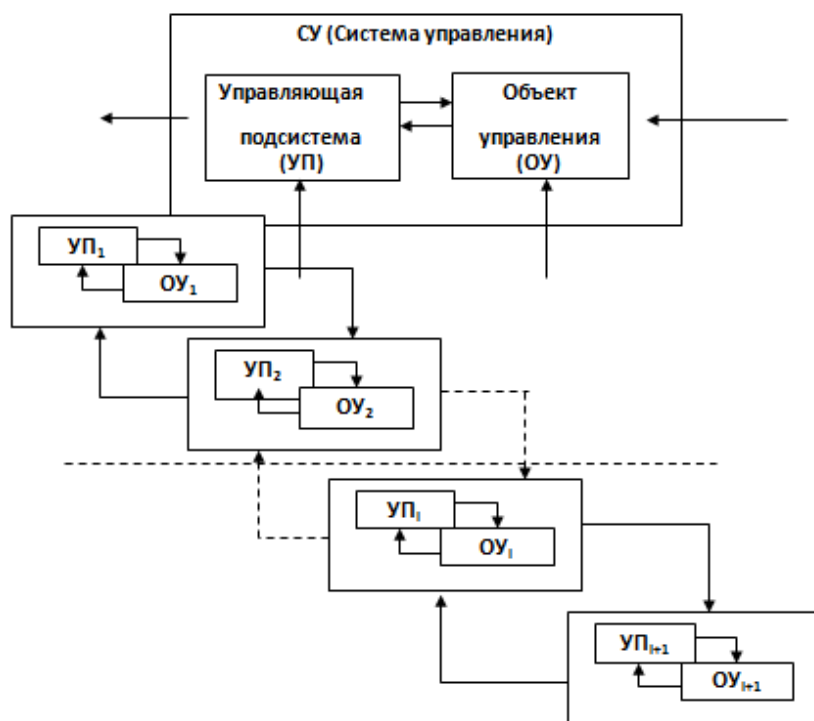


Рис. 4. Иерархическое построение системы управления

Если в результате паразитной динамики в одной из систем управления нижнего уровня по причине синергетически возмущающей среды управляющая подсистема не обеспечивает функциональность системы, то рушится управление во всех верхних звеньях иерархической лестничной цепочки (см. рис. 4). Происходят так называемые «неидентифицированные лавинные» отказы систем. Указанная нештатная ситуация на борту аппарата – одна из наиболее опасных. Опасность заключается в том, что структурные резервы систем на ситуацию повлиять кардинальным образом не могут по причине идентичности происходящих процессов, т. е. при вводе нового (резервного) комплекта системы в управление он также теряет свою работоспособность, так как не устранены первопричины, приведшие к отказу предыдущего аналогично выстроенного комплекта.

Воздействие синергетически возмущающей среды определяется как воздействие среды катастрофического характера.

Примером может служить отказ реле тока накала катода электроракетных двигателей на борту геостационарного спутника связи «Ямал-100» [18]. В результате отказа перестала функционировать вся вышестоящая цепочка систем управления, приведшая к отказу работы системы электроракетных двигателей (СЭРД) в целом. Отказавший элемент был 4-кратно резервирован при показателе надежности системы по вероятности безотказ-

ной работы 0,998. Синергетическое электромагнитное возмущение, которое формировал разрядный электрический процесс в двигателе, обуславливало наличие электрической дуги между контактами реле, приводящей к их выгоранию. Устранить указанную ситуацию удалось после ее идентификации. При этом система СЭРД и спутник в целом понесли значительные ресурсные потери, так как система управления движением центра масс не могла осуществлять свои функции без исполнительных органов.

Таким образом, распознавание синергетически возмущающих сред на борту АКА в полете – одна из первых задач вновь создаваемых интеллектуальных информационно аналитических платформ поддержки жизненного цикла [3]. Они должны являться инструментом, позволяющим обеспечить живучесть аппарата в условиях ранее неопределенных отказов, отнесенных к категории «неидентифицированных». Это достигается управлением структурной динамикой АКА [2], которое включает распознавание синергетически возмущающих сред и позволяет перейти от вероятностно-статистических методов управления в условиях стохастической и нестохастической природной неопределенности к целенаправленному управлению, устраняющему паразитную динамику, формируемую указанными средами. Природа естественного самоструктурирования управления динамическими системами проявляет все факторы, приводящие к нарушению динамического порядка в реальном объекте управления, не учитываемые на этапе создания адаптивных систем. Тем самым раскрывается природная неопределенность сред, что позволяет осуществлять дальнейший переход от непрямого адаптивного управления к прямому адаптивному управлению, в эталонной модели которого учитываются ранее неизвестные факторы природной среды.

### Выводы

1. Существует научно-техническая проблема управления полетом АКА в синергетически возмущающей среде: невозможность применением заранее разработанного сценария управления динамической системой достичь желаемой цели из-за изменения заложенных условий ее достижения по причине появившихся новых синергетических связей между элементами системы. Представлен классический случай появления слабо структурированной проблемы – недостаточность системности при наличии паразитной динамики в динамической системе. Решение проблемы – повышение системности за счет приведения вектора состояния объекта управления и вектора управления к единому порядку.

2. Изначально заложенная надежность систем, базирующаяся на структурно-функциональном ресурсном обеспечении БС, не дает полной гарантии выполнения программы полета АКА. Показатели надежности АКА отражают его системные свойства для оценки его качества заказчиком. В такой трактовке вероятность безотказной работы АКА и его систем – это статическая характеристика готового АКА перед его запуском.

3. Показатель функциональной устойчивости АКА в процессе эксплуатации характеризуется возможностью обеспечения его живучести на основе потенциальных характеристик его надежности, построенной на структурно-функциональных ресурсах, в условиях синергетически возмущающей среды. Живучесть является основным показателем устойчивости, определяющим динамические характеристики свойств АКА и его бортовых систем в процессе полета.

4. Синергетически управляющая среда привлекательна для управления динамическими системами, так как позволяет значительно (на 15–20%) дополнить структурно-функциональные ресурсы синергетическими ресурсами [1; 7].

5. Синергетически номинальная среда позволяет получить паспортизированные условия эксплуатации бортовых систем, обеспечивающие показатели надежности систем, обусловленные структурно-функциональными ресурсами [12].

### Библиографический список

1. Ахметов Р. Н., Макаров В. П., Соллогуб А. В. Байпасность как атрибут живучести автоматических космических аппаратов в аномальных полётных ситуациях // Вестник Самарского государственного аэрокосмического университета. 2015. Т. 14, № 4 С. 17–37.
2. Охтилев М. Ю., Соколов Б. В., Юсупов Р. М. Интеллектуальные технологии мониторинга состояния и управления структурной динамикой сложных технических объектов. М. 2005. 291 с.
3. Искусственный интеллект в космической технике. Состояние. Перспективы применения / под ред. д-ра. техн. наук А. Н. Балухто. М.: Радиотехника. 2021. 436 с.
4. Методы классической и современной теории автоматического управления: учебник: в 5 т. / под ред. К. А. Пупкова и Н. Д. Егупова. М.: МГТУ, 2004.
5. Никифоров В. О. Адаптивное и робастное управление с компенсацией возмущений. СПб.: Наука, 2003. 282 с.
6. Калман Р., Фалб П., Арбиб М. Очерки по математической теории систем. М.: Мир, 1971. 400 с.
7. Ковтун В. С. Морфологический анализ системных исследований автоматических космических аппаратов в синергетически возмущающей среде // Вест. Самар. гос. ун-та. Сер. Технические науки. 2024. Т. 32, № 2. С. 48–75.
8. Ионизирующие излучения космического пространства и их воздействие на бортовую аппаратуру космических аппаратов / под ред. д-ра техн. наук, проф. Г. Г. Райкунова. М.: Физматлит. 2013. 256 с.

9. Колесников А. А. Синергетические методы управления сложными системами: теория системного синтеза. М.: КомКнига, 2006. 308 с.
10. Методика оперативной оценки интенсивности и равномерности расходования ресурсов бортовых систем автоматических космических аппаратов / В. С. Ковтун, А. Н. Павлов, Б. В. Соколов [и др.] // Вестник НПО им. С. А. Лавочкина. 2020. № 4. С. 62–68.
11. Ковтун В. С., Павлов А. Н. Когнитивно-синергетический подход к проектированию автоматических космических аппаратов с бортовыми системами, обладающими свойствами variability // MMRIST 2020. Модели и методы исследования информационных систем на транспорте 2020 / С.-Петербург. гос. ун-т путей сообщения им. Императора Александра I. СПб., 11–12 дек. 2020 г. (Сборник материалов семинара опубликован в CEUR под номером 2803 (urn:nbn:de:0074-2803-0)).
12. Ковтун В. С., Лобанов В. Б., Городецкий А. А. Моделирование тепловых процессов, протекающих в никель-водородных аккумуляторных батареях с общим корпусом при эксплуатации космического аппарата на геостационарной орбите // Известия РАН. Энергетика. 2007. № 4. С. 22–40.
13. Красовский А. А. Адаптивный оптимальный регулятор с переменным порядком наблюдателя и временем экстраполяции // Автоматика и телемеханика. 1994. № 11. С. 97–112.
14. Методы обеспечения живучести низкоорбитальных автоматических КА зондирования Земли / А. Н. Кирилин, Р. Н. Ахметов, А. В. Соллогуб, В. П. Макаров. М.: Машиностроение, 2010. 379 с.
15. Иванов В. А. Функциональная устойчивость систем. Перспективы повышения их надежности // Космонавтика и ракетостроение. 2000. № 19. С. 181–189.
16. Ковтун В. С. Метод проведения синергетических наблюдений процессов на борту космического аппарата // Изв. вузов. Приборостроение. 2020. Т. 63, № 11. С. 995–1002.
17. Патент RU 2354590 C2. МПК В64 G 1/36, G05D/ 1/08 / Севастьянов Н. Н., Верхотуров В. И., Орлов А. Г., Блинов В. А., Ковтун В. С. Способ управления геостационарного космического аппарата, оснащённого радиомаяком // Изобретения 2009. № 13.
18. Ковтун В. С., Фролов И. В. Методы variability анализа и синтеза сложного процесса управления системой электроракетных двигателей космических аппаратов // Космическая техника и технологии. 2016. № 4(15). С. 47–67.

*К. Д. Коновалов\**

аспирант

*С. В. Кулешов\**

доктор технических наук – научный руководитель

\*Санкт-Петербургский Федеральный исследовательский центр Российской академии наук

## ВАРИАНТЫ АЛГОРИТМОВ ПЛАНИРОВАНИЯ МАРШРУТОВ ДЛЯ ВИЗУАЛЬНОЙ НАВИГАЦИИ

Проведен обзор методов планирования маршрута БПЛА при использовании системы видеонавигации. Описаны три основных подхода к решению данной задачи: методы, использующие математические модели; методы ИИ; графовые алгоритмы. Для каждого подхода рассмотрены примеры алгоритмов решения задачи планирования маршрута, а также выделены их преимущества и недостатки.

**Ключевые слова:** маршрут, беспилотный летательный аппарат, математические модели, методы ИИ, графовые алгоритмы.

*K. D. Konovalov\**

PhD Student

*S. V. Kuleshov\**

Dr. Sc., Tech. – Scientific Adviser

\*St. Petersburg Federal Research Center of the Russian Academy of Sciences

## OPTIONS OF ROUTE PLANNING ALGORITHMS FOR VISUAL NAVIGATION

The paper included a review of methods for planning the UAV route when using video navigation systems. Three main approaches to solving this problem are considered: methods using mathematical models; AI methods; graph algorithms. For each approach, examples of algorithms to solve the route planning task are considered, and their advantages and disadvantages are highlighted.

**Keywords:** route, unmanned aerial vehicle, mathematical models, AI methods, graph algorithms.

Сегодня беспилотные летательные аппараты (БПЛА) – быстро развивающаяся отрасль робототехнических систем. Подобные аппараты применяются в различных областях: от авиапочты до картографирования местности. Одним из классов БПЛА, исследования в области разработки которых ведутся на сегодняшний день наиболее активно, являются автономные и условно-автономные БПЛА. БПЛА такого типа отличаются системой управления, позволяющей выполнять поставленные задачи без участия оператора (автономные) или с его участием только в случае возникновения нештатной ситуации (условно-автономные). Далее будут рассматриваться системы управления БПЛА автономного типа.

Важный компонент систем управления таких БПЛА – система навигации. Она позволяет определять местоположение БПЛА и выполнять полученное полетное задание. Сегодня существует большое количество различных систем навигации БПЛА. Их можно разделить на несколько групп по принципу функционирования и типу используемых данных и измерительных приборов: инерциальные навигационные системы, спутниковые системы навигации, системы визуальной навигации или видеонавигации, радионавигационные системы и т. д. Далее будут рассматриваться только решения, использующие системы визуальной навигации. Подобные системы в качестве основного источника информации используют изображения или видеоданные, получаемые с бортовых камер БПЛА.

Системы визуальной навигации БПЛА представляют собой сложные программные продукты, состоящие из отдельных модулей, каждый из которых решает определенную задачу. Одна из таких задач – планирование маршрута, когда необходимо, имея стартовую точку (текущее местоположение БПЛА), финишную точку и некоторый набор данных о местности, в которой производится полет, построить маршрут от стартовой точки до финишной. При этом следует учитывать ряд факторов: протяженность итогового маршрута, наличие препятствий (например, высоких зданий), особенности работы системы навигации и т. д. В этой работе будет выполнен обзор существующих на сегодняшний день алгоритмов построения маршрута, используемых в системах визуальной навигации.

Сегодня разработки в области методов построения маршрута БПЛА ведутся в нескольких направлениях. Первый тип – методы, использующие математические модели БПЛА и местности, в которой производится полет. Примером подобного алгоритма служит алгоритм управления с прогнозирующими моделями (УМП). Суть его состоит в следующем: сначала разрабатывается динамическая модель БПЛА, которая описывает его движение в виде движения материальной точки с ограничениями, накладываемыми на скорость и ускорение движения, а также на изменение ускорения [1]. Далее на основе анализа данных о местности (карты высот, 3D-модели и т. п.) выводится ряд дополнительных ограничений, которые описывают требования к облету препятствий. Затем по-

лученная динамическая модель системы используется для построения маршрута. В каждый момент времени вычисляется состояние системы с учетом управляющих сигналов, на его основе вычисляется состояние системы в следующий момент. Затем процесс повторяется. Таким образом, результатом работы алгоритма является последовательность опорных точек, соединив которые можно получить предпочитаемую траекторию полета. Для получения финального маршрута необходимо выполнить сглаживание полученной кривой. При этом оптимизация набора опорных точек выполняется на протяжении всего полета. Преимущества такого подхода: высокая эффективность вычислений; корректное выполнение облета препятствий [1]; возможность быстрой корректировки маршрута в процессе полета. К недостаткам алгоритма можно отнести отсутствие возможности добавления весовых коэффициентов для препятствий – каждая точка пространства рассматривается как бинарное значение: либо это препятствие, входящее в ограничение, либо нет. Поэтому подобные алгоритмы предпочтительно использовать при полете в местности с большим количеством визуальных ориентиров, например в городах. При этом существуют вариации данного метода, позволяющие избегать не только статические, но и динамические препятствия (например, столкновения с другими БПЛА). Пример подобной системы можно найти в [2].

Также для планирования маршрута могут быть применены современные методы искусственного интеллекта (ИИ), в первую очередь искусственные нейронные сети. Подобные решения работают схожим образом: вначале подбирается структура нейронной сети, затем она обучается на некоторой выборке. Сам процесс работы состоит в загрузке в нейронную сеть данных о местности (например, 3D-карты), а также стартовой и финишной точек. Нейронная сеть составляет маршрут полета на основе полученных данных. При этом в зависимости от решаемых БПЛА задач структура нейронной сети может варьироваться: например, могут применяться несколько нейронных сетей последовательного распространения [3], директивные и иерархические нейросетевые структуры [4], генетические алгоритмы [5] и т. д. Такой подход приносит ряд преимуществ: широкие возможности настройки (используя разные типы нейронных сетей, можно добиваться различных результатов, и выбирать наиболее подходящий для конкретной задачи); достаточно высокая скорость работы, потому что на сегодняшний день существуют высокоэффективные программные реализации большинства разработанных нейросетевых моделей; возможность дообучения по результатам экспериментальных проверок и реальных полетов. Однако у использования нейронных сетей существует и ряд недостатков. Во-первых, недостаточно высокая детерминированность результата. В случае использования нейросетевых моделей, в отличие от классических, при полете в местности, значительно отличающейся от примеров, используемых во время обучения нейронной сети, предсказать получаемую траекторию полета практически невозможно. Во-вторых, повышение сложности процесса разработки. Подбор подходящей структуры нейронной сети и ее гиперпараметров требует больших временных затрат. Сам процесс обучения также занимает длительное время. Кроме того, присутствует проблема подбора обучающих данных, поскольку для обучения нейронной сети необходимо собрать большую обучающую выборку входных данных и считающихся оптимальными в этих условиях маршрутов, что также может потребовать большого количества времени. В целях экономии времени возможно вместо обучения с учителем использовать обучение с подкреплением, которое не требует разметки данных. Однако обучение с подкреплением в большинстве случаев демонстрирует худшие итоговые результаты по сравнению с обучением с учителем, кроме того, при этом еще больше снижается уровень детерминированности.

Третья и наиболее популярная на сегодняшний день группа – графовые алгоритмы. Они подразумевают представление местности в виде графа. Как правило, каждая вершина графа соответствует определенным координатам на местности. Затем в полученном графе выполняется поиск маршрута одним из известных алгоритмов либо разрабатывается новый алгоритм поиска пути. При этом графовые алгоритмы применяются и в более широком круге задач, для построения маршрута РТС других типов [6]. Глобально такие алгоритмы делятся на два этапа – построение графа, исходя из имеющихся данных о местности, и поиск пути в построенном графе. При этом графовые алгоритмы обладают широкими возможностями модификации, поскольку для построения графа могут быть использованы различные данные: цифровые снимки местности, координаты характерных ориентиров [7], инфракрасные снимки местности [8] и т. д. Также для создания графа могут быть разработаны специальные математические преобразования, например метрика разнообразия подстилающей поверхности, описанная в работе [9]. На втором этапе могут использоваться как известные алгоритмы поиска пути в графе, например алгоритм Дейкстры [7], так и создаваться специальные алгоритмы, например в работе [9] описан алгоритм поиска, который находит маршрут, максимизируя минимальное значение веса узлов, входящих в итоговый маршрут. Однако подобные методы также не лишены недостатков. Одна из их проблем – производительность. Несмотря на то, что графовые алгоритмы – одна из основных областей алгоритмизации и разработано большое количество высокоэффективных алгоритмов поиска пути, время их работы линейно зависит от количества узлов и вершин графа. При этом если рассматривать стандартный вариант с прямоугольной координатной сеткой, то увеличение площади местности, в которой производится полет, влечет за собой квадратичное увеличение количества узлов в графе. Поэтому графовые алгоритмы могут показывать недостаточно высокую скорость работы при обработке карт больших размеров. Также при использовании графов более сложной становится задача облета препятствий, поскольку добавление третьего измерения – высоты – также влечет за собой увеличение количества узлов графа. Таким образом, при наличии данной задачи следует комбинировать графовый алгоритм с алгоритмом, использующим математические модели.

## Заключение

Был проведен обзор методов планирования маршрута БПЛА при использовании системы видеонавигации. Были рассмотрены три основных подхода к решению данной задачи: методы, использующие математические модели; методы ИИ; графовые алгоритмы. Для каждого подхода представлены примеры алгоритмов решения задачи планирования маршрута, а также выделены их преимущества и недостатки.

## Библиографический список

1. *Тань Л., Фомичев А. В., Лю Я.* Решение задачи планирования полета малогабаритного беспилотного летательного аппарата в условиях городской среды // Автоматизация. Современные технологии. 2015. № 7. С. 19–24.
2. Modified constrained wavefront expansion path planning algorithm for Tilt-Wing UAV / L. Danielmeier, S. Seitz, I. Barz [et al.] // 2022 International Conference on Unmanned Aircraft Systems. 2022. P. 200–207.
3. Нейросетевое решение задачи оперативного планирования маршрутного полета беспилотных летательных аппаратов и назначение времени наблюдения наземных объектов с помощью нечеткой логики при отображении этих результатов на экране компьютера до вылета / Н. Д. Ивашова, Д. А. Михайлин, М. Е. Чернякова, С. В. Шаныгин // Труды МАИ. 2019. № 104. 17 с.
4. *Лебедев Г. Н., Мирзоян Л. А.* Иерархические нейросетевые структуры в задаче управления групповым полетом // Мехатроника, автоматизация, управление. 2006. № 59. С. 2–5.
5. *He P., Dai S.* Stealth real-time paths planning for heterogeneous UAV formation based on parallel niche genetic algorithm // Journal of Computational Information Systems. 2014. № 10. P. 6731–6740.
6. *Яковлев К. С., Баскин Е. С.* Графовые модели в задаче планирования траектории на плоскости // Искусственный интеллект и принятие решений. 2013. № 1. С. 5–12.
7. *Гришин В. А.* Системы технического зрения в решении задач управления беспилотными летательными аппаратами // Датчики и системы. 2009. № 2. С. 46–52.
8. *Ищук И. Н., Лихачев М. А.* Моделирование оптимального маршрута полета беспилотных летательных аппаратов по данным инфракрасной видеонавигации на основе модернизированного алгоритма Дейкстры // Журнал Сибирского федерального университета. Серия: Техника и технологии. 2021. № 7(14). С. 788–802.
9. *Коновалов К. Д.* Алгоритм планирования маршрута БПЛА в условиях недостатка визуальных ориентиров // Системы анализа и обработки данных. 2022. № 2. С. 37–54.

*О. П. Куркова*

доктор технических наук

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## АЛГОРИТМ МОДЕЛИРОВАНИЯ ПОСЛЕДОВАТЕЛЬНОСТИ СБОРКИ СВАРКОЙ НЕСУЩИХ КОНСТРУКЦИЙ БОРТОВОГО ПРИБОРНОГО КОМПЛЕКСА КОСМИЧЕСКОГО АППАРАТА

Представлена разработка аналитического алгоритма моделирования и оптимизации процесса формирования сварной сборочной единицы для несущих конструкций бортового приборного комплекса космических аппаратов. Опыт внедрения разработанного алгоритма на предприятии ОАО «МЗ „Арсенал“» демонстрирует его преимущества по сравнению с традиционными программными комплексами, такими как SESWELD.

**Ключевые слова:** алгоритм, сварные конструкции, космические аппараты, графовые методы, САПР, технологичность.

*O. P. Kurkova*

Dr. Sc., Tech.

St. Petersburg State University of Aerospace Instrumentation

## THE MODELING ALGORITHM OF THE BEARING STRUCTURES WELDING ASSEMBLY SEQUENCE FOR THE INSTRUMENT CLUSTER OF A SPACECRAFT

The study presents development of analytical algorithm for modeling and optimization of process of formation of welded assembly unit for bearing structures of on-board instrument complex of spacecraft. The experience of implementation of developed algorithm in the enterprise JSC «M3 «Arsenal» demonstrates its advantages compared to traditional software complexes, such as SESWELD.

**Keywords:** algorithm, welding structures, spacecraft, graphing methods, CAD, technological capability.

Для выполнения космическим аппаратом (КА) целевых задач и создания условий для штатного функционирования ряда его систем из состава бортового комплекса управления (БКУ) и бортовой целевой аппаратуры (БЦА) в процессе его проектирования и изготовления необходимо обеспечить определенную ориентацию их элементов с требуемой точностью относительно орбитальной ориентации [1]. Причина отклонений осей посадочных плоскостей или осей элементов бортовой аппаратуры (БА) прежде всего кроется в погрешности изготовления несущих конструкций. Плоскости сварных корпусных конструкций являются основными базовыми рабочими плоскостями для установки БА, поэтому точность их расположения во многом оказывается определяющей в создании условий для штатного функционирования БА и выполнения КА требований целевых задач [2; 3]. В сварных конструкциях материалы, конструктивные формы и технологические процессы тесно взаимосвязаны. Рациональное использование возможностей самого процесса сварки и сварных конструкций в КА невозможно без наличия в распоряжении разработчиков (конструкторов и технологов) мобильного, точного и простого в использовании «инструмента» моделирования конструкций, позволяющего оперативно осуществлять оптимальный выбор последовательности сборки сваркой, размерный конструкторско-технологический анализ в процессе проектирования и разработку технологии изготовления, прогнозирования поведения сварной конструкции в процессе эксплуатации [4].

Указанная проблема может быть решена путем создания аналитического алгоритма моделирования и оптимизации процесса формирования сварной сборочной единицы, построенного на основе графового метода представления самой сварной сборочной единицы и ее анализа с использованием теории графов. Алгоритм при этом должен учитывать не только требования конструкторской документации, но и некоторые критерии, исходя из требований технологичности, особенностей физических и металлургических основ сварочного процесса. Как показывает опыт производства, описание и анализ сварных сборочных единиц строятся на основе логики рассуждений и допущений, поэтому использование теории графов как «математического инструмента» для решения поставленной задачи позволит значительно снизить влияние человеческого фактора на процесс технологической подготовки. В настоящей статье представлены результаты исследований и разработки такого алгоритма. Алгоритм разрабатывался для введения в состав САПР ТП сварочного производства в качестве интеллектуальной компоненты с целью расширения ее функциональных возможностей при проверке конструкторской документации на технологичность и технологической подготовке производства изделий космической техники.

Исходя из иерархической системы технологичности сварной сборочной единицы несущих корпусных конструкций КА разработанный алгоритм выбора последовательности сварки и размерного анализа представляет собой многоуровневую алгоритмическую модель [5]:

- 1-й уровень предназначен для описания и анализа конструкции сборочной единицы;
- 2-й – для описания и анализа комплектующих деталей;



3-й – для описания и анализа взаимосвязей сопряжений комплектующих деталей в сборочной единице и сопряжений образующих плоскостей деталей;

4-й – для описания и анализа критериев по формообразованию и размерным цепям сварочного процесса до сварки (на этапе сборки под сварку) на базе сопряжений комплектующих деталей;

5-й – для описания и анализа критериев по формообразованию и размерным цепям сварочного процесса после сварки на базе сопряжений комплектующих деталей, сопряжения образующих плоскостей по базовому контуру деталей;

6-й уровень предназначен для описания и анализа конструкции самой сварной сборочной единицы, комплектующих деталей с учетом параметров сварочного процесса.

Как видно из приведенной иерархии подзадач, концепция моделирования сварной сборочной единицы существенно отличается от концепции моделирования технологических процессов механической обработки, когда «объектом» описания является «деталь» – монолитная неподвижная структура. Именно это отличие не позволяет полностью применить принципы технологических САПР мехобработки для создания САПР сварных конструкций.

Для построения алгоритмической модели последовательности сборки сваркой и ее оптимизации использовались основные положения теории графов, известные методы и критерии их анализа и оценки [6]. Алгоритмическая модель выбора оптимальной последовательности сборки сваркой, ее размерного конструкторско-технологического анализа на проектно-конструкторском этапе включает:

1) описание ККС КА в целом, корпусной сварной сборочной единицы, комплектующих ее деталей на основе построения взаимосвязанных направленных графов сопряжений и математического описания составляющих их элементов (вершин, ребер, ветвей), позволяющее моделировать и оптимизировать процесс последовательности сборки сваркой на основе результатов анализа структуры построения графов и свойств составляющих элементов;

2) описание ККС КА, корпусной сварной сборочной единицы, комплектующих ее деталей путем построения на основе графов сопряжений взаимосвязанных направленных графов размерных связей относительно трехмерной декартовой системы координат, включая:

2.1) трехуровневое математическое функционально-алгебраическое параметрическое описание ребер графов размерных связей с учетом:

2.1.1) последовательности выполнения переходов сборочно-сварочной операции:

2.1.1.1) исходные конструктивные размерные связи;

2.1.1.2) размерные связи, описываемые с учетом требований и условий сборки под сварку (до сварки с учетом технологических припусков);

2.1.1.3) размерные связи, описываемые с учетом воздействия на них сварочного процесса (после сварки с учетом усадки в сварном шве и остаточных деформаций);

2.1.2) нормативные требования, определяющие составляющие параметры требований сборки под сварку (требования по допустимому зазору в сварном стыке, допустимому смещению кромок сварного стыка);

2.1.3) нормативные данные, определяющие диапазон усадки в сварном шве;

3) анализ графов сопряжений и графов размерных связей путем анализа общей схемы построения и сопоставления свойств составляющих их элементов (вершин, ребер, ветвей);

4) математический расчет значений функций, описывающих размерные звенья, значения составляющих их аргументов.

Основные положения предлагаемого решения задачи определения и оптимизации последовательности сборки сваркой заключаются в следующем [7].

1. Объект проектирования и исследования представляется в виде связанного направленного графа сопряжений – условного изображения совокупности комплектующих и формообразующих элементов, взаимосвязей между ними, в котором принято, что:

1.1) для конструкции КА:

1.1.1) вершины графа – составные элементы декомпозиции конструкции КА – корпусные конструкции КА (отсеки, панели АС, панели СБ и т. д.);

1.1.2) ребра графа – плоскости сопряжения составных элементов конструкции КА по плоскостям корпусных конструкций, соединяемых с помощью разъемных соединений;

1.2) для сварной сборочной единицы:

1.2.1) вершины графа – составные элементы сборочной единицы – комплектующие детали;

1.2.2) ребра графа – плоскости сопряжения комплектующих деталей с помощью сварных соединений;

1.3) для комплектующих сварную сборочную единицу деталей:

1.3.1) вершины графа – формообразующие плоскости;

1.3.2) ребра графа – пересечения формообразующих плоскостей.

2. Решение задачи определения и оптимизации последовательности сборки сваркой и расчета конструкторских и технологических размерных цепей, включая необходимые и допустимые величины технологических припусков, является решением прямой задачи.

3. Решение задачи корректировки проектных величин значений замыкающих размерных звеньев (полей допусков) и схемы их построения (задания основных и вспомогательных баз) является решением обратной задачи.

4. Исходными данными при решении прямой задачи определения последовательности сборки сваркой и расчета размерных цепей являются:

4.1) проектная конструкция корпусного элемента КА, включая типы сварных соединений, вид сварки, степень автоматизации, вид и толщину конструкционного материала, проектные данные о номинальных значениях и требованиях по точности замыкающих размерных звеньев, требования по точности формообразования плоскостей сопряжения конструкции с другими корпусными конструкциями в соответствии с декомпозицией;

4.2) схема задания основной системы координат КА, место расположения базовой точки ориентации и отсчета;

4.3) условное изображение совокупности комплектующих и формообразующих элементов конструкции сборочной единицы и взаимосвязей между ними в виде связанного направленного графа сопряжения;

4.3.1) описание графа сопряжения и его составляющих элементов в условно-табличной форме;

4.4) условное изображение размерных связей между комплектующими элементами конструкции сборочной единицы в виде связанного направленного графа размерных связей;

4.4.1) параметрическое описание графа размерных связей в условно-табличной форме.

5. Исходными требованиями и допущениями являются:

5.1) одному графу сопряжений соответствует только один граф размерных связей;

5.2) по своей структуре граф размерных связей должен строго соответствовать графу сопряжений;

5.3) граф размерных связей может иметь в качестве замыкающего звена размерную связь, не обеспечиваемую в ходе непосредственного сопряжения вершин.

6. Выходными параметрами решения задачи являются:

6.1) выбор основных и вспомогательных базовых комплектующих сборочную единицу деталей;

6.2) выбор последовательности сборки сваркой;

6.3) выбор основных и вспомогательных базовых плоскостей;

6.4) расчет диапазона полей допусков размерных связей;

6.5) расчет диапазона технологических припусков.

7. Критериями оптимизации являются:

7.1) при решении подзадачи определения базовых деталей и базовых плоскостей (вершин графов):

7.1.1) величина показателя степени и полу-степени вершины графа;

7.1.2) местоположение вершины в общей структуре графа;

7.2) при решении подзадачи определения последовательности сварки:

7.2.1) вид сопряжения (ребра) и местоположение в общей структуре графа относительно других сопряжений;

7.2.2) степень автоматизации процесса сварки;

7.2.3) тип сварного соединения;

7.3) при решении подзадачи выбора основных и вспомогательных базовых плоскостей:

7.3.1) величина показателя степени и полустепени вершины графа;

7.3.2) местоположение вершины в общей структуре графа;

7.4) при решении подзадачи выбора диапазона полей допусков размерных связей:  $ES \rightarrow 0$ ;  $EI \rightarrow 0$ ;

7.5) при решении подзадачи выбора диапазона технологических припусков:  $ZM \leq \{Z_i\} \leq ZB$ , где  $Z_i \rightarrow 0$ .

Структурная блок-схема алгоритмической модели «Последовательность сборки сваркой» представлена на рис. 1.

Согласно алгоритмической модели, последовательность сборки сварки выбирается следующим образом:

1) сборка начинается со сборки деталей, сопряжения которых представляют собой контуры графа;

2) находится базовая вершина (деталь):

– либо одна из вершин (деталей) одного из контуров;

– либо одна из вершин (деталей) графа, не входящих в состав контуров;

3) осуществляется сборка вершин (деталей), представляющих собой маршрутные ветви:

3.1) в первую очередь собираются маршрутные ветви, имеющие связь с базовой вершиной (деталью), в следующей последовательности:

– маршрутные ветви, в состав которых входят вершины (детали) из состава контура, имеющие с базовой вершиной связь, представляющее собой ребро;

– маршрутные ветви, в состав которых входят ребра контура;

– маршрутные ветви, представляющие собой подузлы, с предварительной сборкой этих подузлов;

– остальные маршрутные ветви в порядке убывания количества ребер в своем составе;

3.2) во вторую очередь собираются маршрутные ветви, не имеющие связи с базовой вершиной (деталью), а имеющие связь с ранее установленными вершинами (детальями), в следующей последовательности:

– маршрутные ветви, представляющие собой подузлы, с предварительной сборкой этих подузлов;

– остальные маршрутные ветви в порядке убывания количества ребер в своем составе;

4) осуществляется сборка вершин (деталей), представляющих собой простые ветви:

– простые ветви, имеющие связь с базовой вершиной (деталью);

– простые ветви, не имеющие связи с базовой вершиной (деталью).

Для реализации алгоритма технолог при проработке конструкторской документации на технологичность разрабатывает граф сопряжений и описание графа в виде матрицы (результат проработки – табл. 1 на рис. 1),

отражающей все комплектующие детали и сопрягаемые с ними детали. Анализ матрицы позволяет выделить корень графа и направленность ребер (результат преобразований – табл. 2 на рис. 1). Далее выделяются контуры и ветви графа (результат преобразований – табл. 3 и 4 на рис. 1), входные и выходные связи (результат преобразований – табл. 2 на рис. 1).

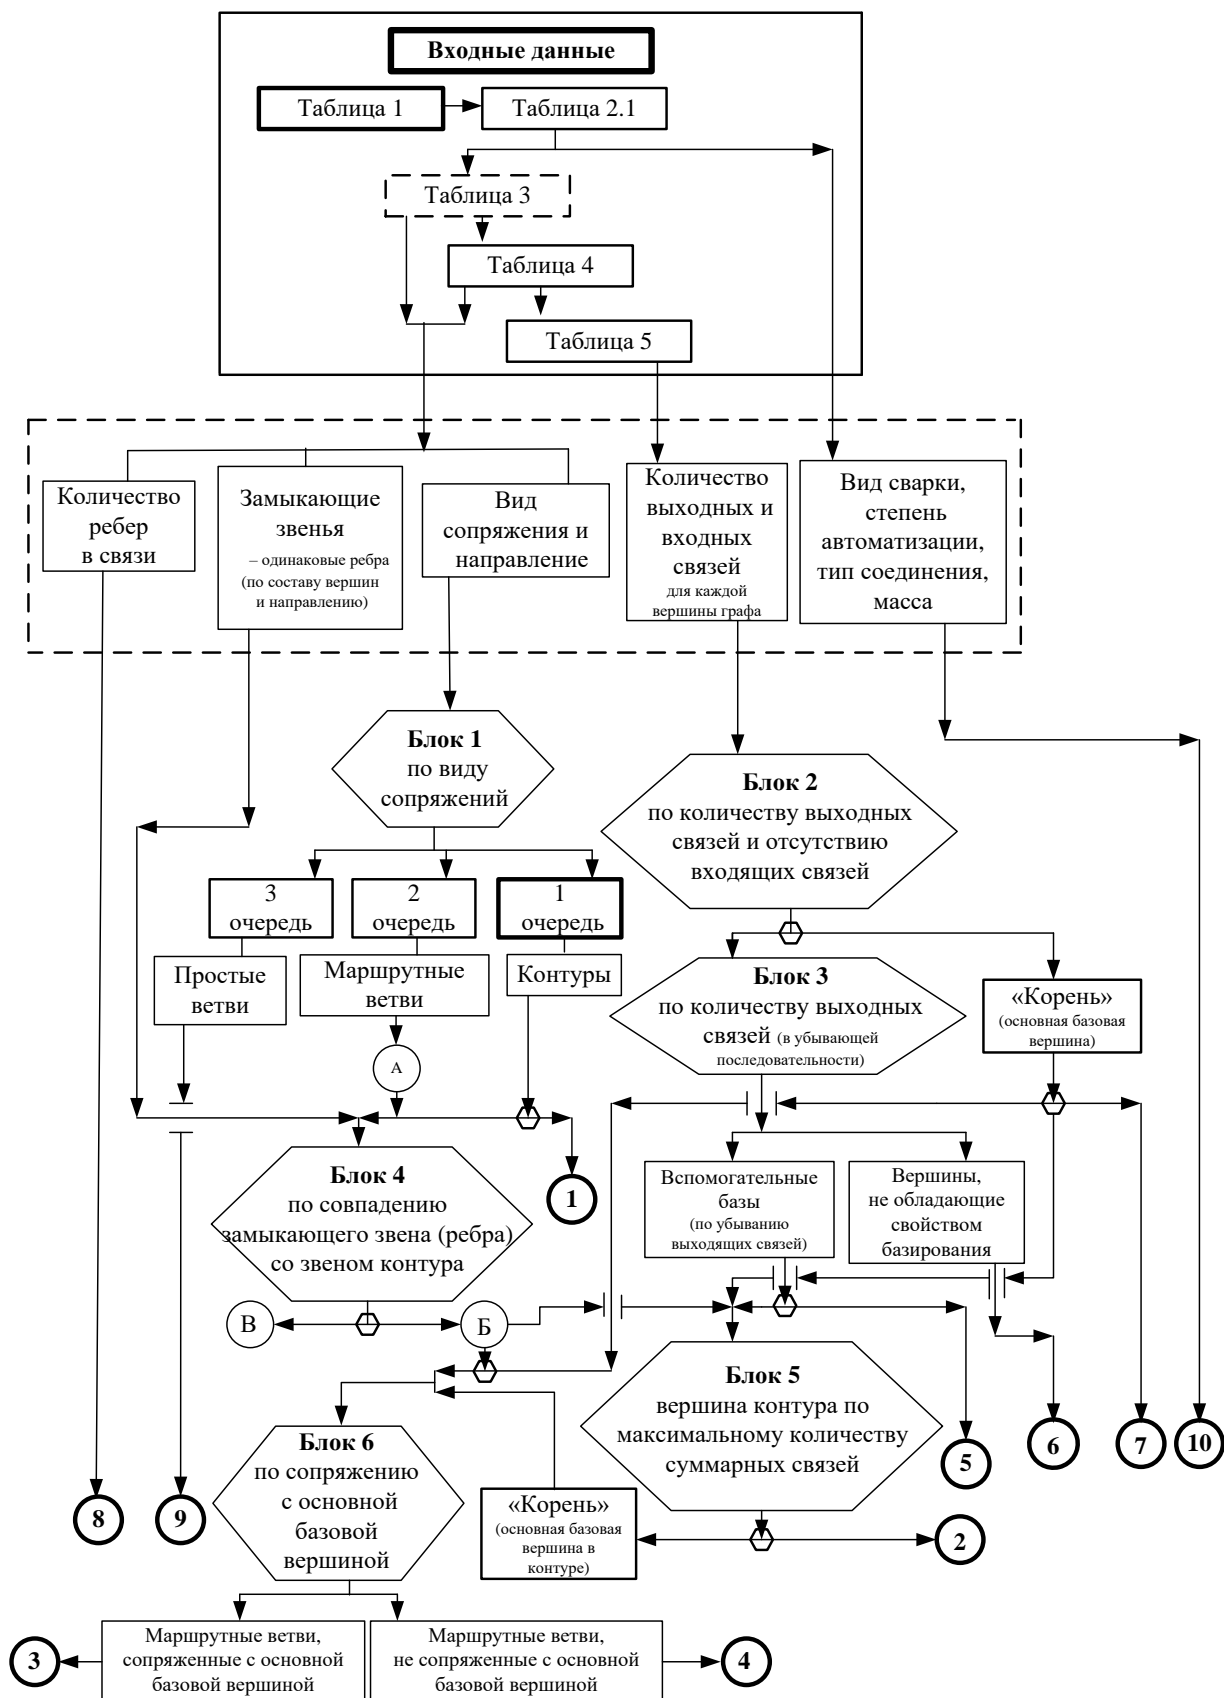


Рис. 1. Структурная блок-схема алгоритмической модели «Последовательность сборки сваркой» (начало)

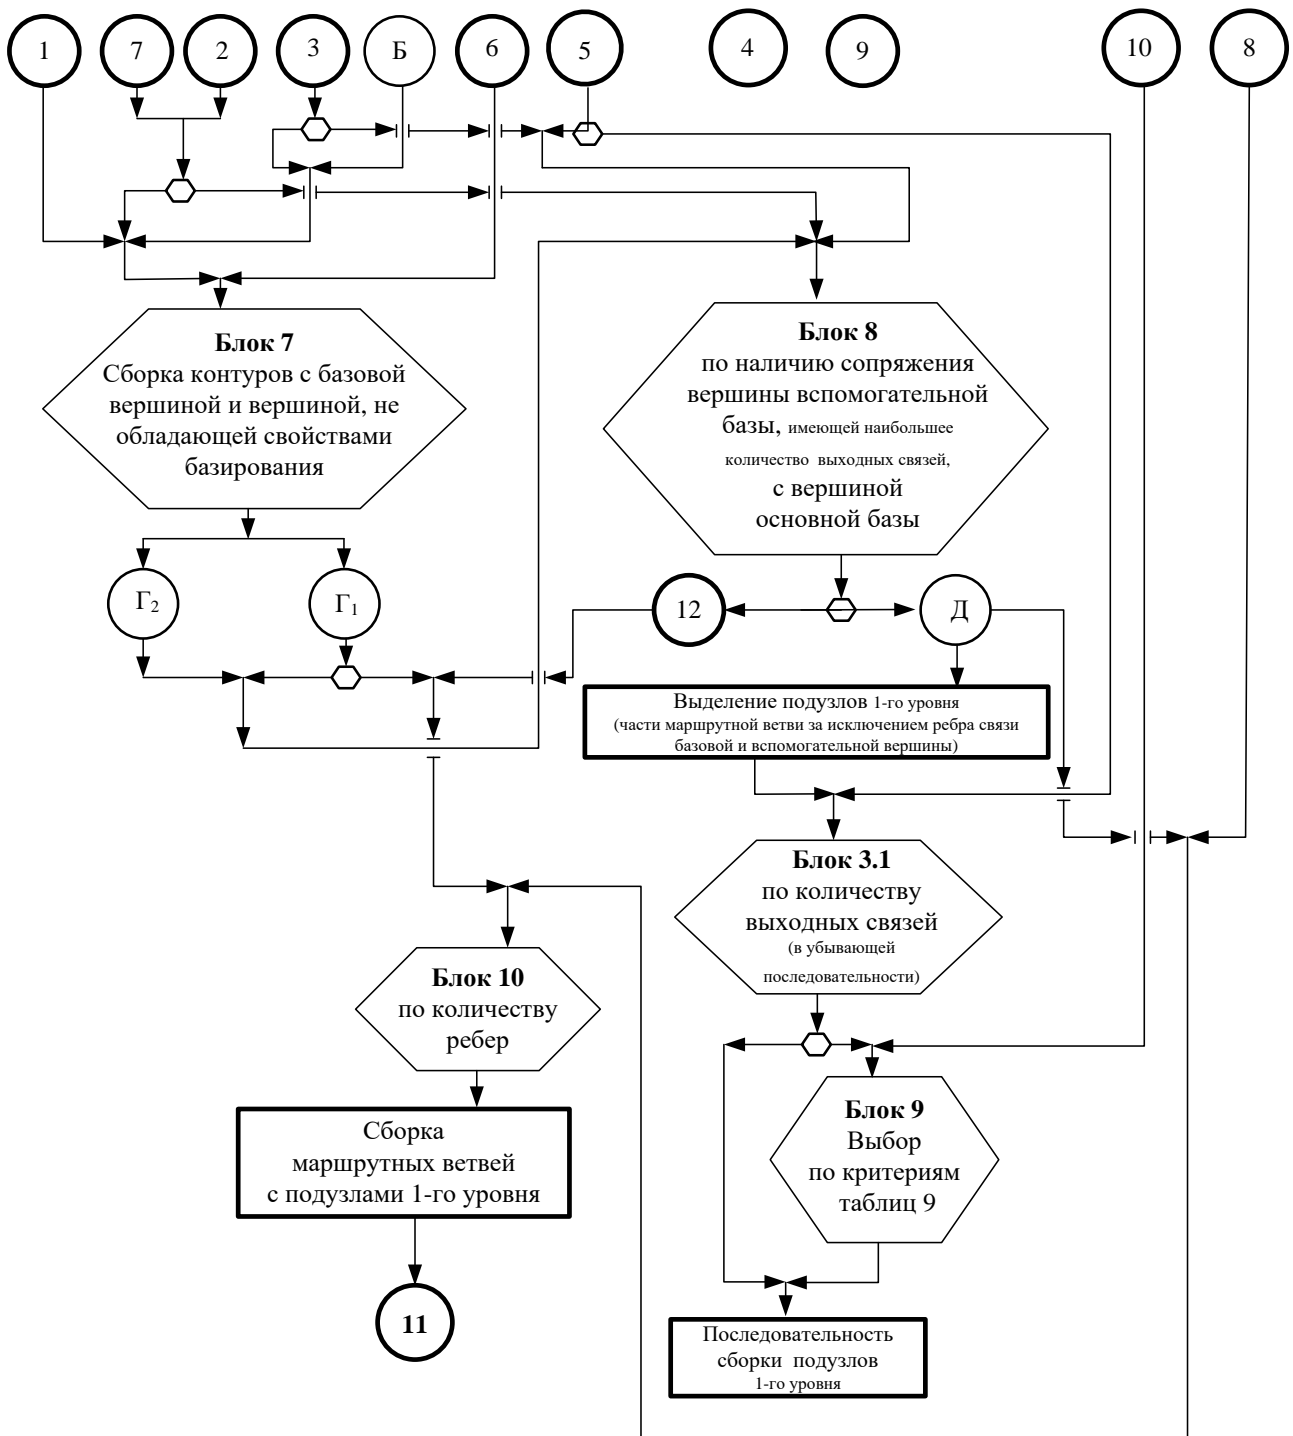


Рис. 1. Продолжение

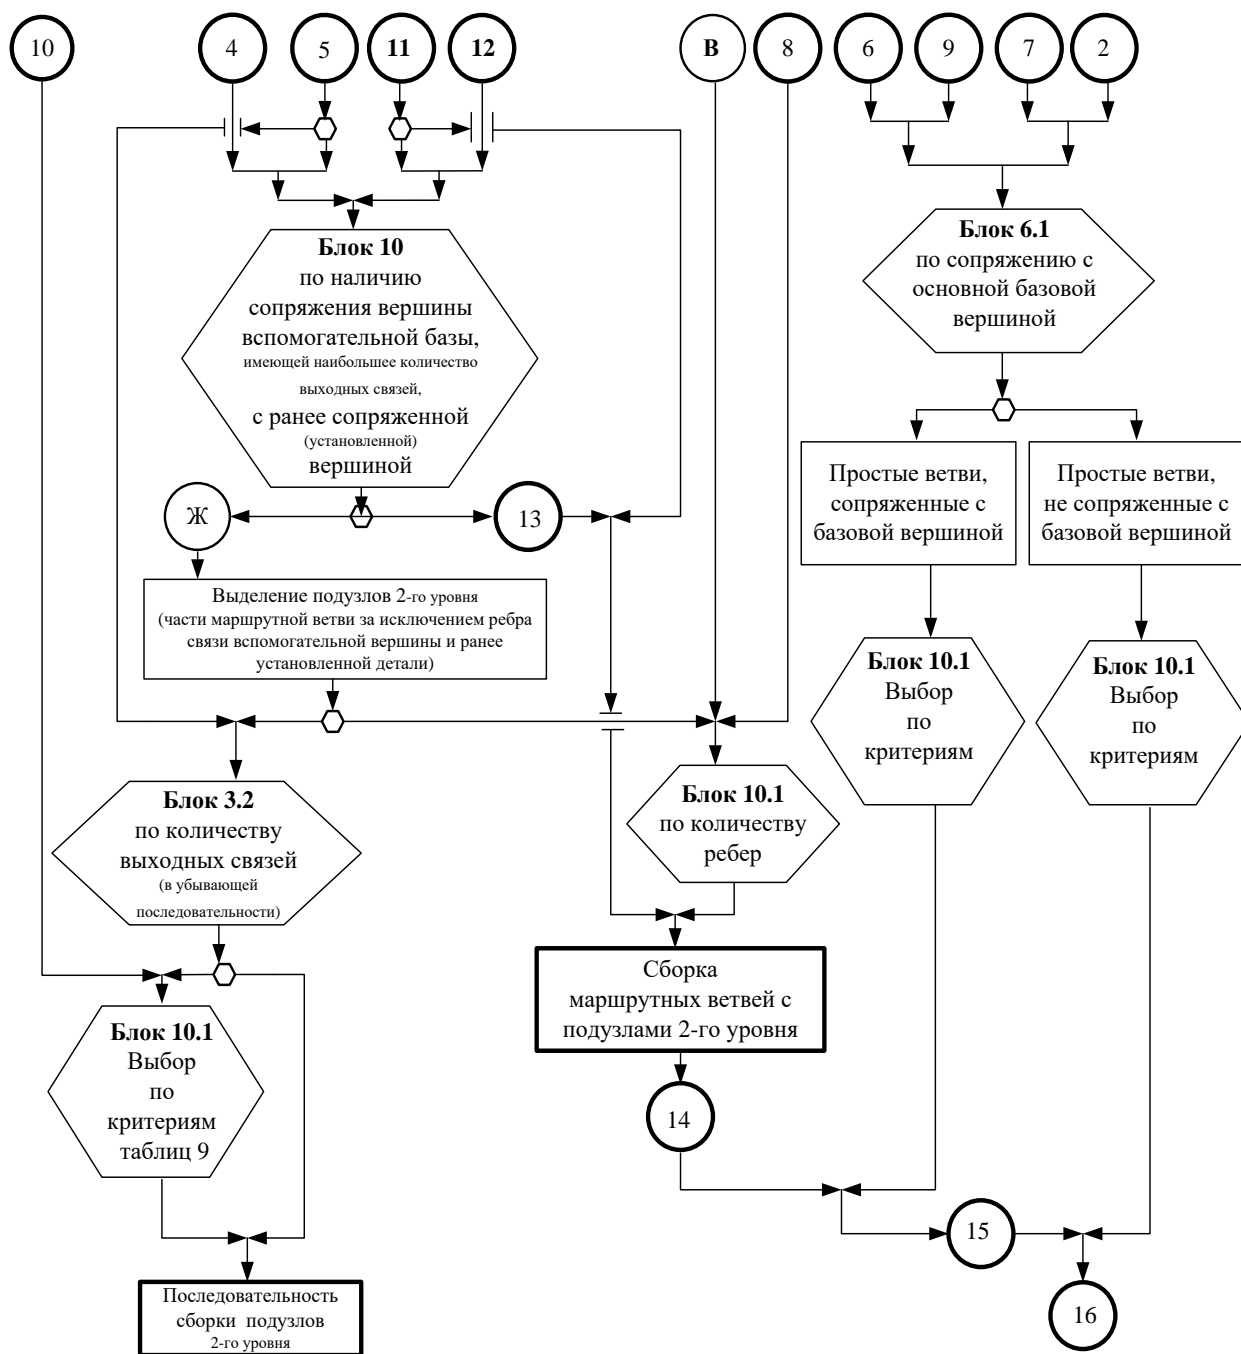


Рис. 1. Окончание

Каждый из блоков алгоритма, представленного на рис. 1, можно раскрыть более детально. Для примера на рис. 2 представлен блок 1 «Анализ по виду сопряжений», а на рис. 3 – блок 4 «Анализ по совпадению замыкающего звена с ребрами контура».

При этом надо иметь в виду, что все блоки «алгоритма» записаны на «содержательном», как и принято в теории графов, а не на «программном» уровне. Для решения поставленной задачи нет необходимости преобразования матрицы исходных данных в единичную матрицу смежности, так как комбинаторные задачи в каждом отдельном блоке данной модели решаются с помощью метода «ветвей и границ», когда предусматривается наличие априорных критериев, с помощью которых отбрасываются множества решений, выходящих за выбранный интервал этих критериев, путем операций «расчленения», «перечисления» и «элементарной склейки».

Размерный анализ осуществляется на основе графов размерных связей, которые составляются по отношению к осям выбранной системы координат. Размерные графы должны строго соответствовать графам сопряжений. Несоответствие структуры построения размерных графов графам сопряжений является первым признаком нетехнологичности конструкции, которая приводит к нарушениям требований точности формообразования конструкции [8]. В отличие от графов исходных сопряжений графы размерных связей могут иметь в качестве

замыкающего звена размерную связь, не обеспечиваемую в ходе прямого непосредственного сопряжения вершин, а являющуюся функцией других размерных связей. Алгоритм размерного анализа предусматривает возможность решения как прямой, так и обратной задачи. Первоначальный расчет размерных цепей выполняется как прямая задача. Сопоставление результатов расчета с заданными проектными величинами замыкающих звеньев, а также задачи моделирования величин полей допусков замыкающих звеньев с целью обеспечения условий ( $ES \rightarrow 0$ ,  $EI \rightarrow 0$ ) за счет изменения переменных аргументов, определения величин необходимых технологических припусков являются задачами обратного характера.

№№ столбца (m) \ №№ строки (n)	Вершины графа (комплектующие детали ( $X_i$ - №детали)				Примечание	Код вида сопряжения (w)	
	1	2	3	4			
1	1	3 <sub>1</sub>	3 <sub>2</sub>	2	Маршрутная ветвь	1	3
2	1	3 <sub>2</sub>	3 <sub>1</sub>	2	Маршрутная ветвь	1	3
3	1	4			Простая ветвь	2	1
4	1	5			Простая ветвь	2	1
5	3 <sub>1</sub>	3 <sub>2</sub>	3 <sub>1</sub>		Контур	0	

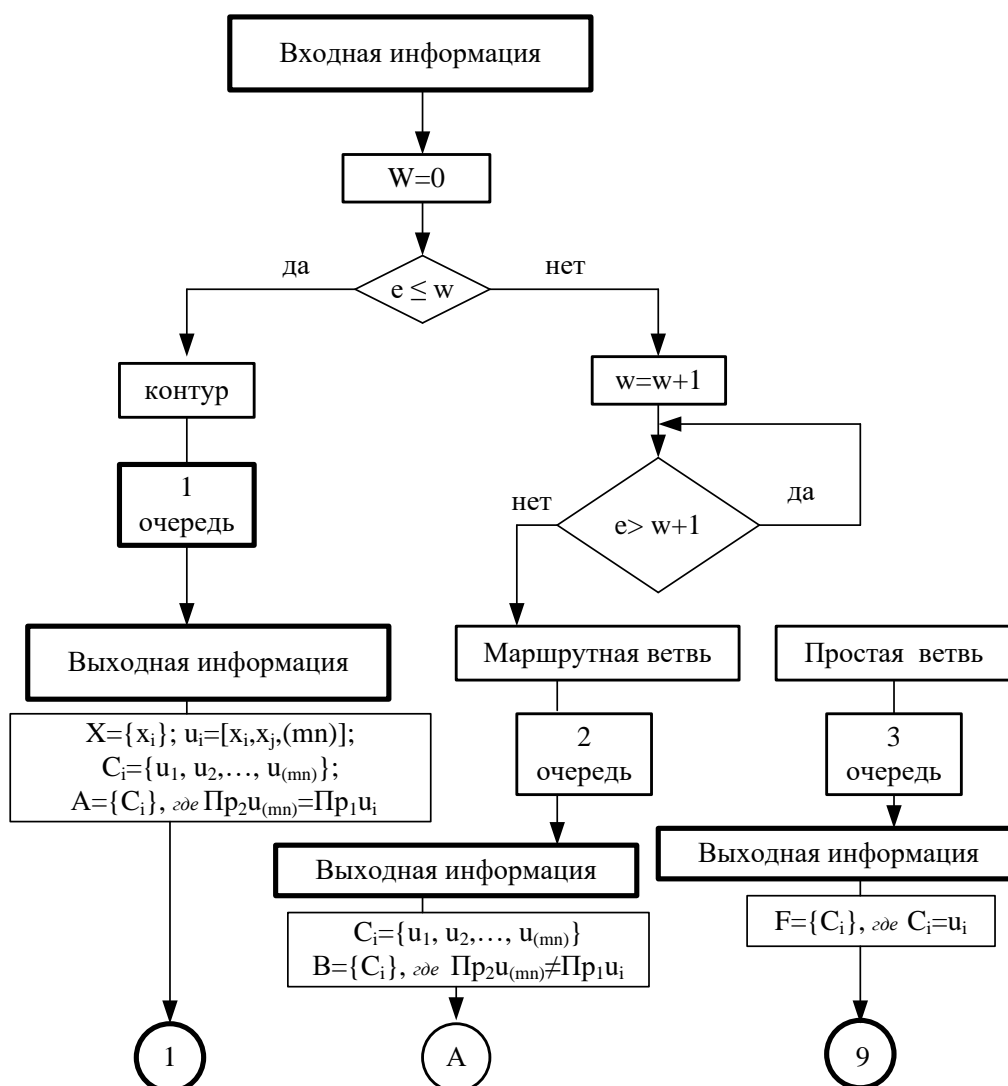


Рис. 2. Блок 1 «Анализ по виду сопряжений»

	Вершины графа (комплектующие детали)				Примечание	
	1	2	3	4		
1	1	3 <sub>1</sub>	3 <sub>2</sub>	2	Маршрутная ветвь	1
2	1	3 <sub>2</sub>	3 <sub>1</sub>	2	Маршрутная ветвь	1
3	1	4			Простая ветвь	
4	1	5			Простая ветвь	
5	3 <sub>1</sub>	3 <sub>2</sub>	3 <sub>1</sub>		Контур	

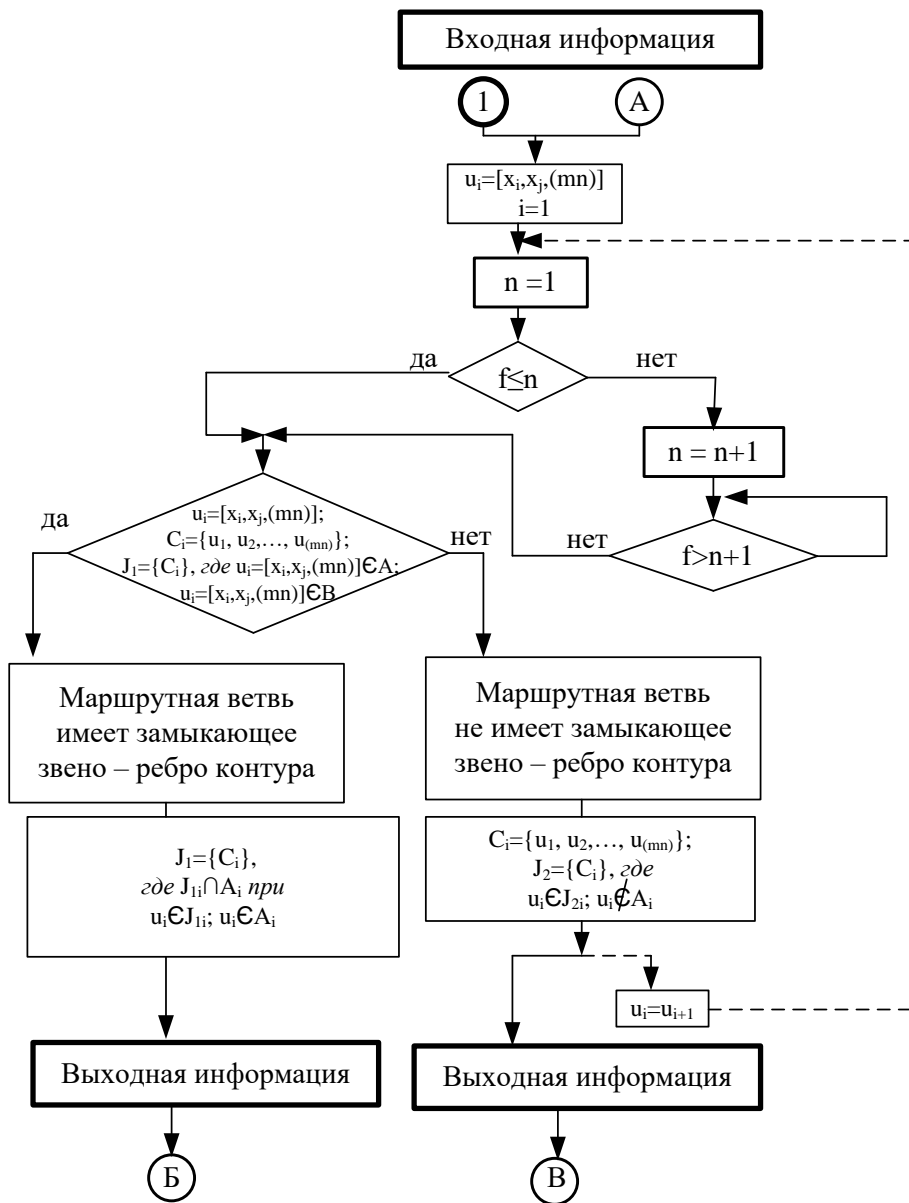


Рис. 3. Блок 4 «Анализ по совпадению замыкающего звена с ребрами контура»

На рис. 4 представлена блок-схема алгоритмической подмодели размерного анализа сварной сборочной единицы.

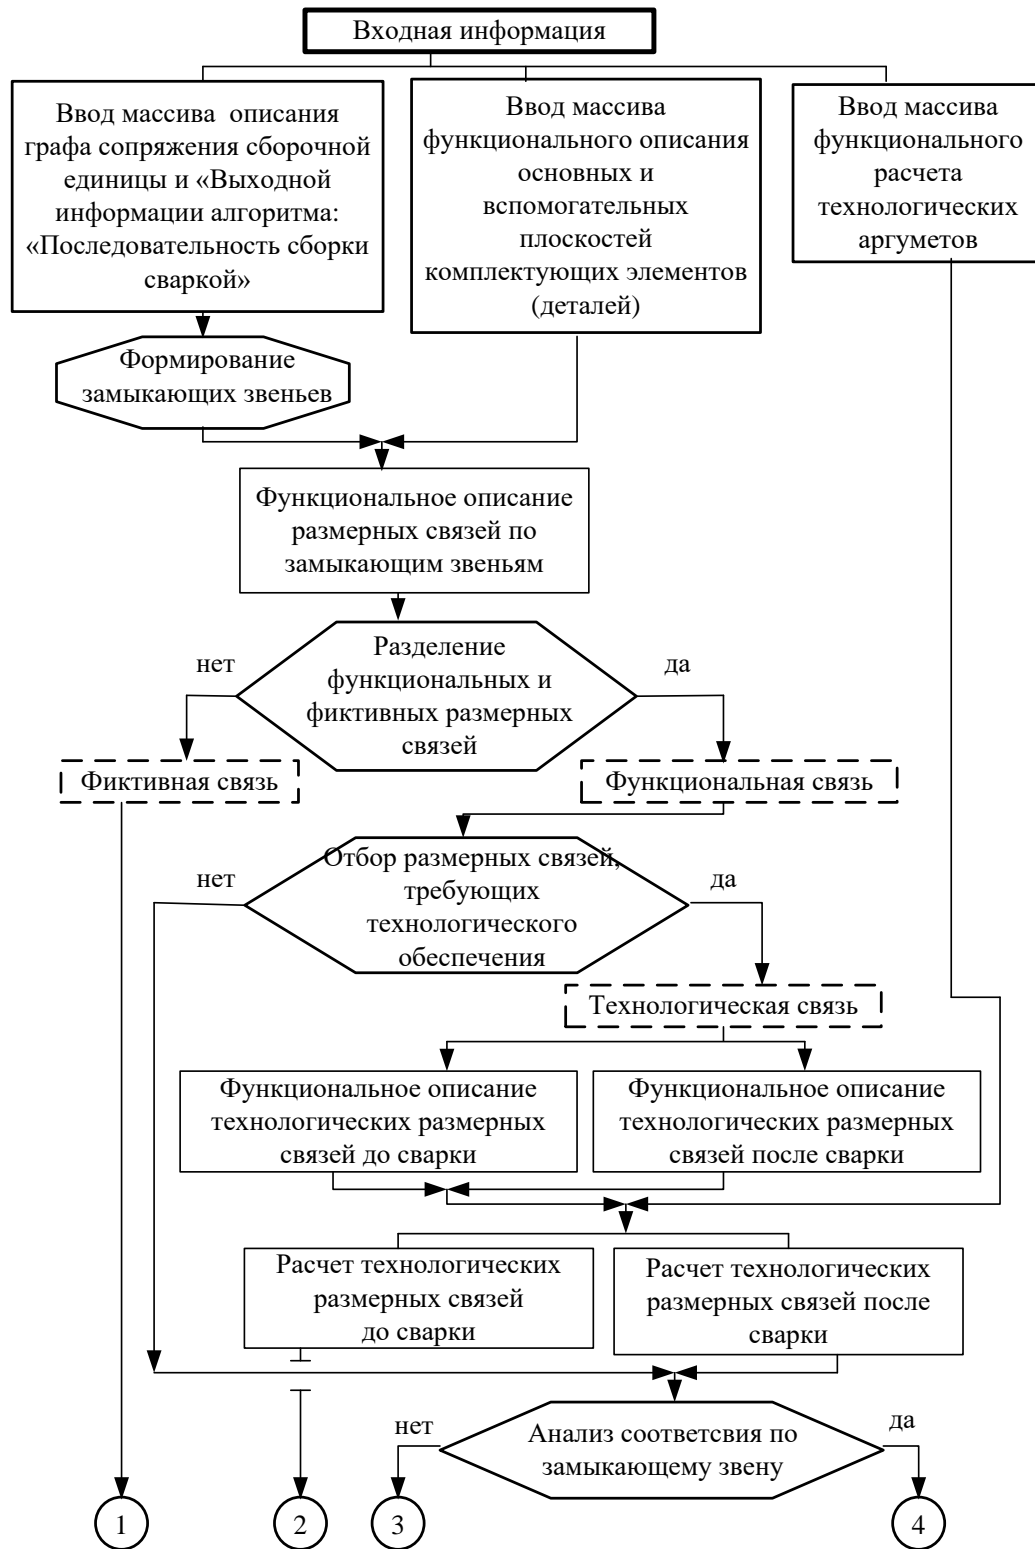


Рис. 4. Структурная блок-схема алгоритмической модели размерного анализа сварной сборочной единицы (начало)



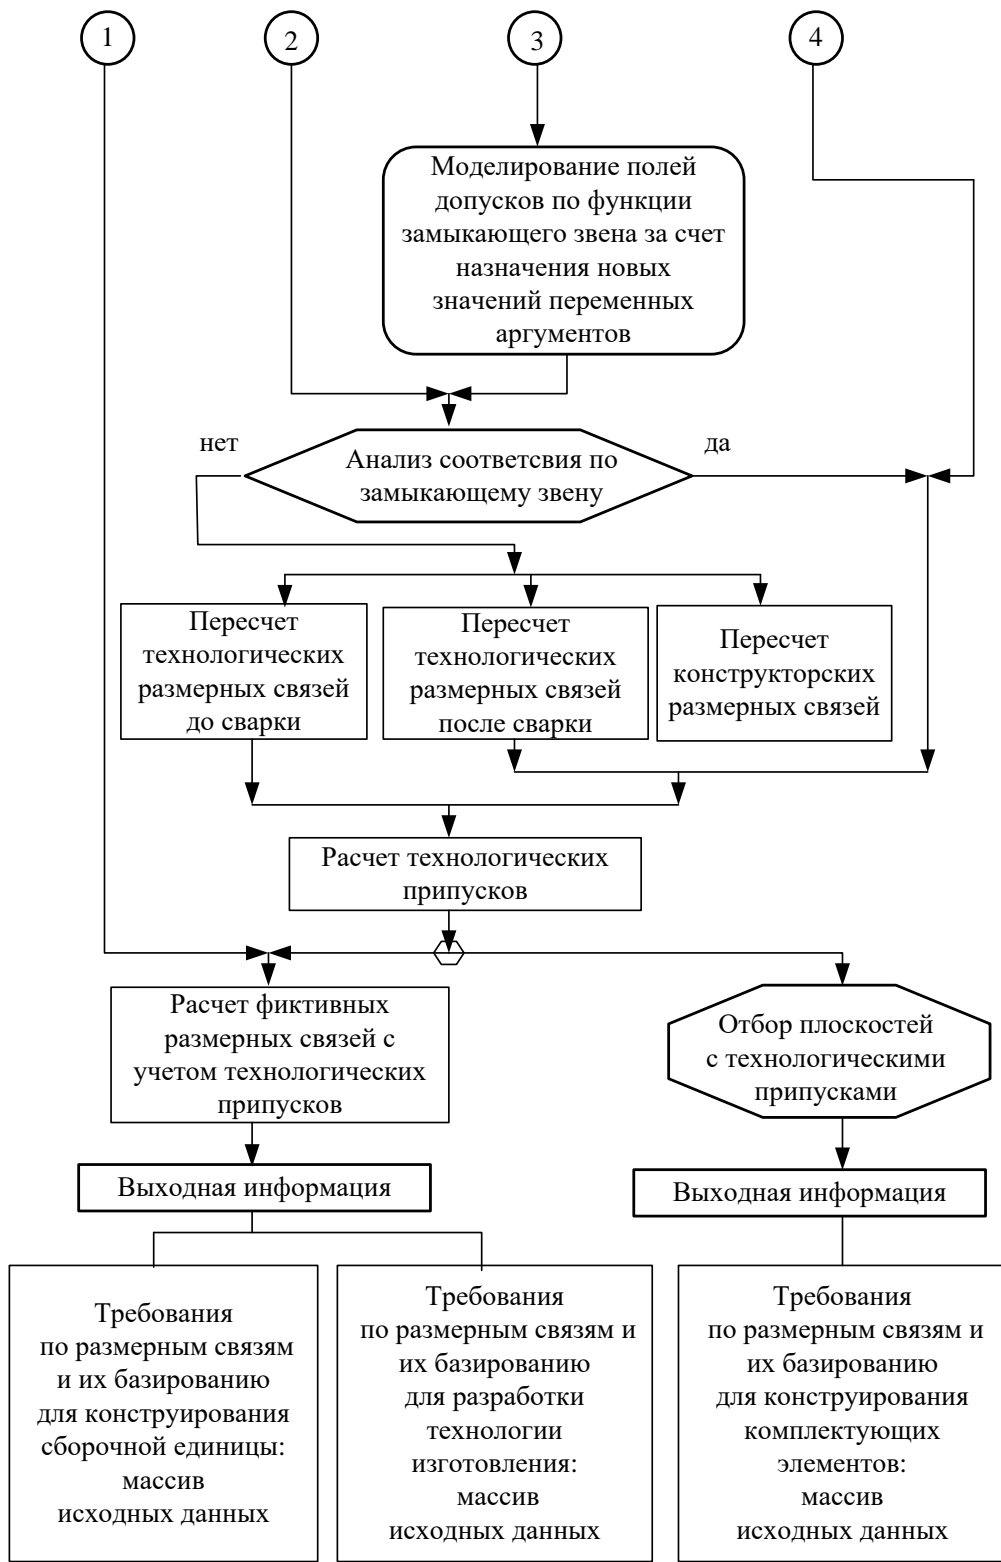


Рис. 4. Окончание

При построении и анализе графовых моделей использовался программный комплекс Graph Theory Toolbox//MATLAB Intel®MKL 10.1 (Math Kernel Library) [9].

Как показал опыт использования предложенного алгоритма в составе САПР при постановке на производство изделий космической техники на ОАО «МЗ «Арсенал», его применение позволяет значительно сократить временные и материальные потери в процессе освоения производства. При этом предложенный алгоритм обладает рядом преимуществ по отношению к программным комплексам инженерного моделирования сварочных процессов, таких как: SESWELD, разработанному компанией ESI Group (Франция) [10], или BAZIS, разработанному группой специалистов из Екатеринбурга (Россия), основной направленностью которых является исследование металлургических и прочностных аспектов сварных соединений и конструкций [11].

### Библиографический список

1. Конструирование автоматических космических аппаратов / Д. И. Козлов, Г. П. Аншаков, Ю. Г. Агарков [и др.]; под ред. Д. И. Козлова. М.: Машиностроение, 1996. 448 с.
2. *Гаврилов В.Н.* Автоматизированная компоновка приборных отсеков летательных аппаратов. М.: Машиностроение, 1988. 10 с.
3. *Соллогуб А. В., Аншаков Г. П., Данилов В. В.* Космические аппараты систем зондирования поверхности Земли: Математические модели повышения эффективности КА. М.: Машиностроение, 1993. 368 с.
4. *Куркова О. П.* Новый подход к проектированию и конструированию размеростабильных корпусных сварных конструкций космических летательных аппаратов. СПб.: Борей-АРТ, 2008. 128 с.
5. *Куркова О.П.* Модель оптимизации параметров размеростабильных сварных корпусных конструкций космических аппаратов в процессе проектирования с учетом технологических факторов // Актуальные проблемы защиты и безопасности: сб. тр. 11-й Всерос. науч.-практи. конф. Т. 6. 2008. С. 201–220.
6. *Кристофидес Н.* Теория графов. Алгоритмический подход. М.: Мир, 1978. 415 с.
7. *Куркова О. П.* Моделирование сварных корпусных конструкций космических летательных аппаратов на этапе конструирования и технологической подготовки процесса изготовления // Синергия образования, науки, промышленности: тр. Междунар. науч.- практ. конф. (16–20 июня 2008 г.) / Балт. гос. техн. ун-т; под общ. ред. С. М. Стажкова и О. А. Толпегина. СПб., 2008. С.152–158.
8. *Солонин И. С., Солонин С. И.* Расчет сборочных и технологических размерных цепей. М.: Машиностроение, 1980.110 с.
9. *Иглин С. П.* Graph Theory Toolbox: дополнение к пакету MATLAB Intel®MKL 10.1 (Math Kernel Library). URL: <https://www.mathworks.com/matlabcentral/fileexchange/4266-grtheory-graph-theory-toolbox> (дата обращения: 31.08.2024).
10. ESI Group: офиц. сайт. URL: <https://www.esi-group.com/products/sysweld> (дата обращения: 03.09.2024).
11. BAZIS: офиц. сайт. URL: <https://bazisnet.ru/> (дата обращения: 03.09.2024).

**С. В. Микони\***

доктор технических наук, профессор

**С. С. Семёнов\*\***

кандидат технических наук

\*Санкт-Петербургский Федеральный исследовательский центр Российской академии наук

\*\*Государственное научно-производственное предприятие «Регион», Москва, Россия

## ВЫБОР ВАРИАНТА БЕСПИЛОТНОГО ЛЕТАТЕЛЬНОГО АППАРАТА НА ОСНОВЕ ЗАДАННЫХ ТРЕБОВАНИЙ К ЕГО ПОКАЗАТЕЛЯМ

Рассматривается подход, заключающийся в упорядочении оцениваемых вариантов технической системы относительно требований, предъявляемых к характеризующим их показателям применительно к созданию перспективных беспилотных летательных аппаратов (БЛА) и выбору предпочтительного варианта БЛА для выполнения поставленной задачи.

**Ключевые слова:** беспилотный летательный аппарат, показатель.

Исследования, выполненные по данной тематике, проводились в рамках бюджетной темы FFZF-2022-0004.

**S. V. Mikoni\***

Dr. Sc., Tech., Professor

**S. S. Semyonov\*\***

PhD, Tech.

\*St. Petersburg Federal Research Center of the Russian Academy of Sciences

\*\*State Research and Production Enterprise «Region», Moscow, Russia

## CHOICE OF UNMANNED AERIAL VEHICLES BASED ON THE GIVEN REQUIREMENTS FOR ITS INDICATORS

The study considers an approach that consists in streamlining the evaluated technical system options with respect to the requirements of their characteristics for the development of future unmanned aerial vehicles (UAV) and the choice of preferred UAV for the task.

**Keywords:** unmanned aerial vehicle, indicator.

### Введение

На этапах проектирования и применения технических систем востребован поиск лучшего варианта. В качестве исходных данных для этого используются, как правило, существующие образцы технической системы. Обычным подходом к выбору лучшего варианта системы является сопоставление образцов по значениям характеризующих их показателей [1; 2]. Этот подход ориентирован на достигнутый технический уровень, не учитывающий перспективных требований к создаваемой системе. Альтернативой ему является упорядочение оцениваемых вариантов системы относительно требований, предъявляемых к характеризующим их показателям. В работе рассматривается этот подход применительно к созданию перспективных беспилотных летательных аппаратов (БЛА) и выбору предпочтительного варианта БЛА для выполнения поставленной задачи.

### Показатели БЛА

Любое изделие, предназначенное что-то производить, характеризуется *производительностью, надежностью и экономичностью* (в потреблении ресурсов). Со стороны воздействия внешней среды оно характеризуется *устойчивостью и безопасностью*. По отношению к степени участия человека в функционировании изделия отличается уровнем *автономности* (самостоятельности в принятии решений). С точки зрения его создания и развития изделие характеризуется уровнем *унификации*. По отношению к окружающей среде оно характеризуется уровнем ее *загрязнения* собой (при утилизации) и своими отходами. С точки зрения взаимодействия с человеком изделие характеризуется *эргономичностью и эстетичностью*. Каждая из перечисленных характеристик изделия реализуется своими техническими средствами.

В публикациях предлагаются различные варианты характеристик БЛА [3; 4]. Они детализируются различным составом: от единиц до десятков первичных показателей. Для предметного анализа рекомендуемого состава первичных показателей примем за основу состав, опубликованный в работе [5] (таблица). В ней использованы следующие обозначения показателей:

- $M_{взл}$  – взлетная масса БЛА (кг);
- $M_{бн}$  – масса боевой нагрузки (кг);
- $D_{п}$  – дальность полета (км);
- $T_{п}$  – продолжительность полета (км);
- $H_{п}$  – высота полета – практический потолок (м);

- $V_{\text{МАКС}}$  – максимальная скорость полета (км/ч);
- $n$  – количество точек подвески УР, УАБ (ед.);
- $C_{\text{БЛА}}$  – стоимость БЛА (млн долл.).

### Перечень основных характеристик разведывательных и ударных БЛА с взлетной массой 0,3–2,0 т

БЛА	Страна	$M_{\text{ВЗЛ}}$	$M_{\text{БН}}$	$D_{\text{П}}$	$T_{\text{П}}$	$H_{\text{П}}$	$V_{\text{МАКС}}$	$n$	$C_{\text{БЛА}}$
Форпост-М	Россия	454	100	500	17,5	5000	200	2	7,5
Дозор-600	Россия	640	220	3700	30	7500	210	2	6
Байрактар ТВ2	Турция	650	150	300	24	7000	220	4	8
Гермес 900	Израиль	1180	350	4000	36	9145	220	2*	12*
Орион-1 (Э)	Россия	1200	200	600	24	8000	200	2	6
Импакт 1300	Израиль	1300	400	1500	30	9000	250	2*	9*
СН-4В	Китай	1350	345	1600	14	7000	250	4	4
Вин Лун-1D	Китай	1500	400	2000	35	7500	280	4	8*
MQ-1C Грэй Игл	США	1634	478	8000	36	8840	280	4	17*
Рустом-2	Индия	1800	350	900	24	10 660	300	2	10

\* Экспертные оценки показателей.

Производительность БЛА характеризуется скоростью, высотой и продолжительностью полета. Последняя косвенно характеризует энергоёмкость БЛА. Она оценивается объемом затраченной электроэнергии либо топлива на длину полета. В [5] эти показатели названы тактическими.

Взлетная масса является классификационным показателем, поскольку она в значительной степени определяет объем полезной нагрузки БЛА. Согласно утверждению [6] о границах значений показателей, первые три БЛА по взлетной массе не сопоставимы с остальными и должны быть выделены в отдельную группу. Под полезной нагрузкой БЛА здесь понимается масса боевой нагрузки. Для разведывательных БЛА к ней относится целевая аппаратура, такая как приборы наблюдения за местностью.

К производительности, отражающей назначение БЛА, и его полезной нагрузке добавляются показатели, характеризующие качество его функционирования. Обычно они задаются в форме наличия некоторых свойств, таких, например, как «оборудован ли БЛА средствами радиоэлектронного противодействия?» и пр. Эти показатели относят к логическому типу с значениями: «да», «нет». Этот тип показателей не может быть использован для количественных оценок БЛА. Выходом из положения может быть переход к обобщающему показателю, чьими значениями являются логические показатели, а им самим сопоставлять количественную оценку.

Рассмотрим эту проблему на примере автономности функционирования БЛА. Поскольку для ее реализации используют в том числе модели искусственного интеллекта, это свойство БЛА называют интеллектуальностью, смешивая свойство и средство его реализации. Автономность полета характеризуется способностью БЛА реагировать на изменение состояния внутренней и внешней среды.

По способу реагирования на эти изменения различают следующие виды поведения БЛА: *реактивное, адаптивное, проактивное, целеустремленное и прагматичное* [7].

Под реактивным типом поведения понимается безусловная реакция объекта на оказанное на него воздействие. Адаптивное поведение предполагает учет текущего, а проактивное – будущего состояния внутренней и окружающей среды. Целеустремленное поведение предполагает выбор альтернативы на каждом шаге достижения цели. Прагматичное поведение предполагает оптимизацию расходования ресурсов, привлекаемых для достижения цели. К этому виду поведения может быть отнесена и самодиагностика БЛА.

Реализация каждого типа поведения в порядке их перечисления сопряжена с увеличением объема анализируемой информации. Это позволяет сопоставить каждому уровню управления количественную оценку, в простейшем случае в баллах. Например, если реактивный тип поведения оценить одним баллом, то в линейном случае (+1 балл) прагматичное поведение будет оценено пятью баллами.

Для ударных БЛА классические показатели надежности не являются критическими. На устойчивость функционирования БЛА влияет состояние атмосферы, а на безопасность – внешние воздействия. Из природных факторов к ним следует отнести удар молнии, из искусственных – раннее обнаружение противником. Для их парирования используются кодовые («свой-чужой») и физические (обнаружение облучения) методы. Эти свойства относят к безопасности БЛА, названной в [4] выживаемостью. Таким образом, безопасность БЛА может быть охарактеризована значениями: «молниеотвод», «свой-чужой», «облучение». Они также могут быть охарактеризованы количественно в соответствии со своей мерой влияния на безопасность БЛА.


Примем рассмотренные количественные показатели за минимальный состав показателей, характеризующих БЛА, и рассмотрим предъявляемые к ним требования.

### Задание требований к показателям

Требования задаются в виде норм на шкалах показателей [8]. Исходя из нечеткости нормы, она выражается отрезком  $[c_{nj}, c_{vj}]$  на шкале  $j$ -го показателя,  $j = \overline{1, n}$ . Отсюда исходными данными для создания модели отклонений  $j$ -го показателя от нормы являются:

- нижняя  $c_{nj}$  и верхняя  $c_{vj}$  границы интервальной нормы  $[c_{nj}, c_{vj}]$ ;
- допустимые отклонения от нормы к меньшим (ДОМ) и большим (ДОБ) значениям:  $c_{домj}$  и  $c_{добj}$ .
- предельные отклонения от нормы к меньшим (ПОМ) и большим (ПОБ) значениям:  $c_{помj}$  и  $c_{побj}$ .

Графическое представление на шкале  $j$ -го показателя интервальной нормы и отклонений от неё приведено на рисунке.



Графическая модель отклонений от нормы

Предельные отклонения от нормы  $c_{j\text{ пом}}$  и  $c_{j\text{ поб}}$  принимаются за границы шкалы  $j$ -го показателя  $[y_{j\text{ min}}, y_{j\text{ max}}]$ :  $c_{j\text{ пом}} = y_{j\text{ min}}$ ,  $c_{j\text{ поб}} = y_{j\text{ max}}$ .

### Классификация вариантов БЛА относительно норм показателей

Отрезки шкалы показателя, находящиеся слева и справа от отрезка «Норма», относятся к классам «меньше нормы» (МН) и «больше нормы» (БН). Функции принадлежности  $\mu_k(y_j)$  классов Н, МН, БН строятся автоматически относительно границ нормы.

Классифицируемый образец БЛА по значению любого показателя относится к одному из трех классов: МН, Н, БН. Принадлежность значения показателя классу МН или БН позволяет оценить направление и относительную величину его отклонения от нормы.

При непересекающихся функциях принадлежности классам значение показателя может принадлежать только одному классу и двум классам в противоположном случае. Принадлежность образца БЛА классу по многим показателям вычисляется как средневзвешенная функция частных принадлежностей этому классу по формуле:

$$\mu_k(x) = \sum_{j=1}^n w_j \cdot \mu_{jk}(x), k = \text{Н, МН, БН}.$$

Для общей характеристики образца БЛА представляет интерес не только мера его принадлежности норме и классам МН и БН, но и отношения ЛПР к этим отклонениям. Для представления этого отношения вводятся два дополнительных класса «хуже нормы» (ХН) и «лучше нормы» (ЛН). Нежелательность отклонения значения нейтрального показателя в любую сторону от границ нормы выражается через делегирование принадлежностей классам МН и БН в класс ХН.

Функции принадлежности классам позволяют не только относить образец БЛА к одному из трех классов, но и упорядочивать образцы БЛА по величине функции принадлежности  $\mu_k(x)$  каждому из трех классов. В связи с этим появляется возможность не только упорядочивать образцы БЛА относительно заданных требований к показателям (класс «Норма»), но и учитывать меру отклонения показателей от предъявляемых к ним требований.

Задача решается в следующей последовательности.

1. Задаются шкалы и нормы количественных показателей.
2. Задается важность (веса) показателей.
3. Выполняется классификация каждого образца относительно нормы.
4. Образцы упорядочиваются относительно принадлежности норме.
5. Образцы упорядочиваются относительно степени несоответствия норме.
6. По результатам анализа выбирается предпочтительный образец.

### Заключение

Предлагаемый подход, основанный на совмещении классификации и упорядочения объектов, позволяет выявлять лучший вариант относительно требований к показателям, а не относительно соотношения их значений в выборке. Он рассчитан не только на упорядочение вариантов БЛА относительно требований к значениям показателей, но и относительно отклонений от этих требований, как в лучшую, так и в худшую сторону.

### Библиографический список

1. Семенов С. С., Харчев В. Н., Иоффин А. И. Оценка технического уровня образцов вооружения и военной техники. М.: Радио и связь, 2004. 552 с.
2. Ерохин Б. Т., Богословский В. Н., Куликовский А. Ю. Методы проектирования сложных систем по комплексному критерию качества // Известия РАРАН. 2010. № 2(64). С. 33–38.
3. Кошкин Р. П. Беспилотные авиационные системы. М.: Стратегические приоритеты, 2016. 676 с.
4. Наумов Р. С., Благодаряцев И. В., Дрозд Н. С. Возможный подход к оценке технического уровня перспективных беспилотных авиационных систем // Гражданская авиация на современном этапе развития науки, техники и общества: сб. тез. докл. Междунар. науч.-техн. конф., посв. 100-летию отечеств. Граждан. авиации. Москва, 18–19 мая 2023. М.: ИД Акад. им. Н. Е. Жуковского. С. 139–141.
5. Микони С. В., Семенов С. С. Оценивание рейтинга разведывательно-ударных и ударных беспилотных летательных аппаратов // Полет. 2021. № 6. С. 28–40.
6. Микони С. В., Полтавский А. В., Семенов С. С. Методология проектирования модели многомерного оценивания привязных высотных платформ на базе мультикоптеров // Надежность. 2022. № 2. С. 55–63.
7. Russel S., Norvig P. Artificial Intelligence. Modern Approach. Prentice Hall, Englewood Cliffs. New Jersey. 1995. 932 p.
8. Микони С. В. Моделирование отклонений показателей качества объекта от нормы // Онтология проектирования. 2024. Т. 14, № 2(52). С. 167–180.

*С. С. Митогуз\**

студент

*А. В. Аюева\**

студент

*Е. Ю. Ватаева\**

старший преподаватель – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ПЕРСПЕКТИВЫ РАЗВИТИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ПРОМЫШЛЕННЫХ ПРЕДПРИЯТИЯХ РОССИЙСКОЙ ФЕДЕРАЦИИ

Приведен обзор такого широкого понятия, как искусственный интеллект, а именно модели машинного обучения; объясняется, какие функции выполняют эти модели и как их можно использовать в промышленности. Рассказывается про первый известный случай попытки внедрения искусственного интеллекта в работу предприятия, а также про то, как повлияло это внедрение на производительность и безопасность производства. Приводятся примеры того, как искусственному интеллекту нашли применение в сборе данных в нефтепереработке, контроле качества продукции, обнаружении дефектов, отслеживании качества водоснабжающих труб, мониторинга работы двигателей и всего предприятия. Раскрываются понятие цифрового двойника и его возможности. Представлен ряд проблем, выявленных в ходе анализа внедрения искусственного интеллекта в производство, с которыми столкнется производитель.

**Ключевые слова:** искусственный интеллект, машинное обучение, производство, предиктивная аналитика, KPI, HMI, цифровые двойники.

*S. S. Mitoguz\**

Student

*A. V. Ayueva\**

Student

*E. Yu. Vataeva\**

Senior Lecturer – Scientific Adviser

\*St. Petersburg State University of Aerospace Instrumentation

## PROSPECTS FOR THE DEVELOPMENT OF ARTIFICIAL INTELLIGENCE AT INDUSTRIAL ENTERPRISES OF THE RUSSIAN FEDERATION

The article gives an overview of such a broad concept as artificial intelligence, namely machine learning models, explains what functions these models perform and how they can be used in industry. The article talks about the first known case of an attempt to introduce artificial intelligence into the work of an enterprise, as well as about the impact of this introduction on the productivity and safety of production. Examples are given of how artificial intelligence has been applied to data collection in oil refining, product quality control, defect detection, water pipe quality monitoring, engine and plant-wide monitoring. The concept of digital twin and its capabilities are explained. A number of challenges identified by analyzing the implementation of artificial intelligence in production that a manufacturer will face are presented.

**Keywords:** artificial intelligence, machine learning, manufacturing, predictive analytics, KPI, HMI, digital twins.

Искусственный интеллект (ИИ) включает системы и сервисы, которые используют модели машинного обучения. Машинное обучение представляет собой набор технологий, которые автоматически разрабатывают правила для принятия решений на основе анализа данных в рамках предварительно установленной структуры системы. Такие модели машинного обучения создаются для решения четко определенных задач, таких как прогнозирование числовых данных, классификация информации и подобные.

ИИ охватывает широкий спектр человеческой деятельности, и в этом контексте полезно рассмотреть его применение в промышленности, в автоматизированных системах управления технологическими процессами для предиктивной аналитики как в дискретном, так и в непрерывном производстве. В этих системах ИИ позволяет прогнозировать поведение оборудования и технологических процессов, предоставляя возможность предвидеть их развитие на несколько шагов вперед [1].

Первый пример использования ИИ в промышленности можно увидеть на заводе «Русский продукт» (рис. 1) [2]. Это предприятие, производящее разнообразные пищевые продукты, ставило перед собой задачи получения аналитики работы производственной линии в реальном времени, устранения непредсказуемых остановок и снижения уровня дефектов.



*Рис. 1. Завод «Русский продукт»*

Внедренная система автоматизации на основе программного обеспечения SuperSCADA позволила интегрировать исполнительные механизмы, датчики и программируемые логические контроллеры от различных производителей. Более того, она обеспечила предиктивную аналитику, включая сигнализацию о сбоях в работе отдельных узлов и агрегатов и предоставление рекомендаций по их обслуживанию. В результате модернизации удалось существенно уменьшить влияние человеческого фактора на производственный процесс.

Предиктивная аналитика и виртуальные датчики находят активное применение в нефтепереработке, особенно при работе с данными, которые обновляются не так часто, например раз в смену. Такие данные, поступающие из химических лабораторий, предоставляют информацию о составе фракций в ректификационной колонне. Даже при таком интервале обновления анализа можно эффективно отслеживать динамику инерционных процессов до следующей пробы. Когда новые данные становятся доступны, модель автоматически обновляется для учета актуальной информации.

Еще одним примером применения ИИ служит использование машинного зрения для сортировки продукции. На заводе по производству алюминиевых банок искусственный интеллект оценивает качество припоя на крышках и обнаруживает вмятины на банках, анализируя их по шести точкам. Высокая скорость конвейера, который подает банки, не является проблемой для системы распознавания – она эффективно и быстро выявляет дефекты с высокой точностью [3].

Также искусственный интеллект успешно справился с задачей выявления участков трубопроводов в системе водоснабжения, где происходит несанкционированный отбор воды, оказав помощь предприятию «Калугаоблводоканал» по уменьшению сверхнормативных технических потерь и избыточного расхода электроэнергии.

Существуют примеры, когда искусственный интеллект отслеживает определенные КРІ (ключевые показатели эффективности). Например, для мониторинга работы частотно регулируемого привода. Если параметры вращения двигателя отклоняются от нормы, ИИ способен определить, является ли это аварийным режимом, и скорректировать алгоритм работы. Кроме того, компьютерная аналитика может прогнозировать срок службы двигателя и при необходимости выдавать предупреждение диспетчеру. Мониторинг ключевых показателей может применяться ко всем элементам технологической цепочки.

КРІ могут быть определены не только для отдельных агрегатов, но и для всего производства в целом. Это позволяет акцентировать внимание на таких аспектах, как максимальная производительность, безопасность, надежность, экономия ресурсов и экологическая эффективность. Таким образом, ИИ в сочетании с современными НМИ (человеко-машинными интерфейсами) дает возможность оператору не только следить за состоянием конкретного узла, но и ставить более общие задачи, например поддерживать температуру в зависимости от запасов топлива и погодного прогноза или продлевать срок службы оборудования за счет более бережного режима работы.

Во всех упомянутых случаях искусственный интеллект использует концепцию цифрового двойника – математическую модель отдельного узла, цеха, технологической линии или всего предприятия, которая позволяет рассчитать различные сценарии работы системы (рис. 2). Затем ИИ помогает выбрать наиболее оптимальные варианты и выявить потенциальные узкие места, чтобы предотвратить возможные остановки или аварии на производстве [4].





Рис. 2. Цифровой двойник

Искусственный интеллект, используя обширные данные, собранные заранее и постоянно обновляемые в процессе машинного обучения во время действующего производства, способен:

- оптимизировать производственный процесс в зависимости от ключевых задач;
- корректировать алгоритмы при появлении новых данных или возникновении нестандартных ситуаций;
- контролировать качество продукции и точность соблюдения технологических процессов;
- предупреждать о возможных сбоях и необходимости проведения профилактического обслуживания;
- на стадии разработки продукта или производственного процесса определить наиболее эффективные сценарии работы системы.

При внедрении технологий на основе искусственного интеллекта производитель может столкнуться с рядом проблем.

1. Высокие затраты на внедрение ИИ. Первоначальные расходы на внедрение ИИ могут быть значительными, особенно для малых компаний и стартапов, из-за затрат на сбор данных и разработку. Однако стоимость может варьироваться в зависимости от решаемой задачи. Если требуется разработка ИИ с нуля внутренней командой, расходы будут выше по сравнению с привлечением узкоспециализированных консультантов.

2. Недостаток квалифицированных специалистов. Несмотря на рост интереса к робототехнике и автоматизации, технологии машинного обучения продолжают развиваться. Наличие опытных дата-саентистов в команде значительно упрощает задачу. В противном случае потребуется найти специалистов с необходимыми навыками и опытом в области ИИ.

3. Качество данных. В производстве данные часто бывают устаревшими, искаженными или ненадежными. Эффективность применения ИИ во многом зависит от качества данных. Например, на заводах данные могут собираться в различных изолированных системах, что затрудняет проведение комплексного анализа и применения ИИ.

Таким образом, хотя ИИ предлагает значительные преимущества для промышленности, его успешное внедрение требует тщательного подхода к решению связанных с ним проблем и вызовов.

#### Библиографический список

1. Эндрю Л. Искусственный интеллект: пер. с англ. / под ред. и с предисл. Д. А. Поспелова. М.: Мир, 1985. 264 с.
2. Русский продукт. URL: <https://www.rusprod.ru/> (дата обращения: 01.09.2024).
3. Бураков М. В. Нейронные сети и нейроконтроллеры: учеб. пособие. СПб.: ГУАП, 2013. 284 с.
4. Кораблев А. В. Ключевые функциональность и преимущества цифровых двойников в промышленности // Цифровая экономика. 2019. № 2(6).

*Д. А. Павленко\**

аспирант

*Э. В. Снежко\**

кандидат технических наук

*В. А. Ковалев\**

кандидат технических наук

\*Объединенный институт проблем информатики Национальной академии наук Беларуси, Минск, Республика Беларусь

## ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ БЮДЖЕТНОГО ТЕНЗОРНОГО ПРОЦЕССОРА GOOGLE CORAL ДЛЯ РЕШЕНИЯ ПРАКТИЧЕСКИХ ЗАДАЧ КЛАССИФИКАЦИИ ИЗОБРАЖЕНИЙ

Интеграция аэрокосмического приборостроения с технологиями искусственного интеллекта требует использования современных нейронных сетей на компактных вычислительных устройствах, таких как мобильные вычислительные устройства, одноплатные компьютеры, ускорители нейронных сетей. В данном исследовании проводится оценка эффективности бюджетного тензорного процессора Google Coral, а также одноплатных компьютеров Cool Pi 4 Model B и Raspberry Pi 4 Model B для решения практических задач классификации изображений с помощью стандартных нейронных сетей TensorFlow.

**Ключевые слова:** обработка изображений, одноплатные компьютеры, нейронные сети, нейронные процессоры, ускорители нейронных сетей, ИИ-ускорители, тестирование производительности.

Работа выполнена при финансовой поддержке научно-технической программы Союзного государства «Комплекс-СГ» в рамках НИР № 9СГ2.1-225 от 24.02.2023.

*D. A. Pavlenko\**

PhD Student

*E. V. Snezhko\**

PhD, Tech.

*V. A. Kovalev\**

PhD, Tech.

\*The United Institute of Informatics Problems of the National Academy of Sciences of Belarus, Minsk, Republic of Belarus

## RESEARCH OF THE GOOGLE CORAL BUDGET TENSOR PROCESSOR EFFICIENCY TO SOLVE PRACTICAL PROBLEMS OF IMAGE CLASSIFICATION

Integration of aerospace instrumentation with artificial intelligence technologies requires the use of modern neural networks on compact computing devices, such as mobile computers, single-payment computers, neural network accelerators. This study evaluates the efficiency of a budget-priced Google Coral tensor processor, as well as the Cool Pi 4 Model B and Raspberry Pi 4 Model B single-payment computers for solving practical problems of classifying images using standard TensorFlow neural networks.

**Keywords:** image processing, single-payment computers, neural networks, neural processors, neural network accelerators, AI accelerators, performance testing.

### Выбор инструментов для проведения исследования

Исследование необходимо для подбора оптимальной конфигурации бортового микроархитектурного вычислительного комплекса для детектирования аномальных ситуаций на территории Республики Беларусь из космоса на основе методов искусственного интеллекта (далее – МВК «БортВК»). Устройство будет реализовано на основе компактного одноплатного компьютера и будет использовать современные нейронные сети для автоматического обнаружения на многоспектральных спутниковых снимках Земли различных аномальных ситуаций, таких как последствия пожаров и буреломов в природных экосистемах, последствия затопления территорий, засухи. МВК «БортВК» будет выполнен на базе формфактора 1U CubeSat для малых космических аппаратов. Таким образом, в проекте будет произведена интеграция аэрокосмического приборостроения с технологиями искусственного интеллекта.

Данное исследование проводится с целью выяснить следующие характеристики:

- точность классификации различных нейронных сетей (моделей);
- скорость обработки изображений нейросетевыми моделями;
- скорость обработки изображений одноплатными компьютерами Cool Pi 4 Model B (далее – CoolPi) [1] и Raspberry Pi 4 Model B (далее – Pi4) [2];
- скорость обработки изображений нейросетевым ускорителем (тензорным процессором) Google Coral USB Accelerator with Google Edge TPU (далее – Coral) [3].

Исследуемые устройства Pi4, CoolPi и Coral показаны на рис. 1.



Рис. 1. Исследуемые устройства: Raspberry Pi 4 Model B (а), Cool Pi 4 Model B (б) и Google Coral USB Accelerator (в)

Для проведения исследования выбраны следующие инструменты. Среда разработки: Jupyter Notebook. Фреймворки машинного обучения: TensorFlow (TF), TensorFlow Lite (TFLite) и Keras. Вспомогательные библиотеки языка программирования Python: NumPy, Matplotlib, Pillow, IPython. Исследуются стандартные архитектуры нейронных сетей из хранилища TF [4]. Все модели нейронных сетей предварительно обучены на наборе данных ImageNet для задачи классификации изображений. *Архитектуры нейронных сетей не меняются в процессе исследования.* Для конвертации модели из TF в TFLite применяется библиотека `tf.lite.TFLiteConverter` [5]. Для конвертации модели из формата TFLite в совместимый с устройством Coral файл используется инструмент командной строки «Edge TPU Compiler» [6].

Для нахождения точности и скорости классификации применяется база изображения ImageNet-v2 [7]. ImageNet-v2 представляет собой тестовый набор ImageNet по десять изображений для каждого класса, всего 10 000 изображений, который собран в строгом соответствии с исходным протоколом маркировки. В связи с тем, что полный прогон всех тестов по десяти тысячам изображений для одноплатного компьютера Pi4 занимает несколько суток, было принято решение сократить базу изображений ImageNet-v2 в десять раз и оставить лишь 1000 случайно выбранных изображений, по одному на каждый класс объектов. То есть тестовый датасет был сокращен в десять раз ради экономии времени, но это не отразилось значительно на численных результатах испытаний.

Чтобы полностью квантовать модель, необходимо выполнить пост-тренировочное квантование (post-training quantization) [8] на репрезентативном наборе данных, что требует от 100 до 500 изображений из базы ImageNet. Так как база изображений ImageNet слишком большая, чтобы загрузить ее целиком, то для посттренировочного квантования была выбрана маленькая база изображений «imagenet-sample-images» [9], которая состоит из 1000 случайных изображений из большой базы изображений ImageNet по одному случайному изображению на каждый класс.

Все программное обеспечение (ПО) для исследования эффективности бюджетного тензорного процессора Coral находится в директории с проектом репозитория GitHub [10].

ПО находится в следующих файлах Jupyter Notebook «\*.ipynb»:

- «get\_data\_for\_tests.ipynb» [11] – процесс получения и сохранения нейросетевых моделей для тестирования;
- «run\_tf\_on\_cpu\_gpu\_tpu.ipynb» [12] – дополнительные тесты для проверки различных гипотез;
- «additional\_test\_diff\_options.ipynb» [13] – дополнительные тесты для проверки различных входных параметров нейросетевых моделей;
- «performance\_tests.ipynb» – тесты производительности и точности классификации нейросетевых моделей на одноплатных компьютерах, кроме теста для Coral;
- «coral\_tpu\_tests.ipynb» – поскольку библиотеки TF и TFLite не могут работать в одной и той же среде одновременно, то тесты для Coral были вынесены в данный отдельный файл.

### Получение данных для исследования

Для проведения тестов точности классификации и скорости обработки изображений были отобраны семнадцать нейросетевых моделей [4]: MobileNet, MobileNetV2, MobileNetV3Large minimalistic, MobileNetV3Small minimalistic, EfficientNetB0, EfficientNetV2B0, EfficientNetV2S, ConvNeXtTiny, ConvNeXtBase, DenseNet121, InceptionV3, ResNet50, ResNet101, ResNet50V2, ResNet101V2, Xception, VGG16.

Так как протестировать все нейросетевые модели не представляется возможным, то из хранилища [4] были отобраны по две-три штуки из каждого семейства нейросетевых моделей, а именно архитектуры: MobileNet, EfficientNet, ConvNeXt, DenseNet, Inception, ResNet, VGG и Xception. Выбирались самые маленькие архитектуры из семейства для того, чтобы тестирование не было слишком долгим, и нейронная сеть могла работать на компактном одноплатном компьютере.

Для совместимости с нейросетевым ускорителем Coral Edge TPU нейросетевая модель должна быть предварительно конвертирована и скомпилирована, как показано на рис. 2.




Рис. 2. Преобразования нейросетевой модели для совместимости с Coral

Нейросетевые модели скачиваются из хранилища TF [4] и конвертируются в формат целочисленный TFLite. После конвертации веса моделей должны быть в формате uint8 (целые числа в диапазоне [0, 255]) или int8 (целые числа в диапазоне [-127, 127]). Затем модель TFLite компилируется при помощи инструмента командной строки «Edge TPU Compiler» [6] в файл, совместимый с устройством Edge TPU. В конце совместимый с Edge TPU файл разворачивается (выполняется) на нейросетевом процессоре Coral.

Для выполнения нейросетевой модели на устройстве Coral она должна удовлетворять следующим требованиям:

- все тензоры нейросетевой модели должны быть квантованы в восьмибитные целые числа (uint8 или int8);
- размеры тензоров должны быть постоянны во время компиляции, т. е. не иметь динамических размеров;
- параметры модели (например, тензоры смещения) должны быть постоянны во время компиляции;
- тензоры могут быть одно-, двух- или трехмерными, если тензор имеет более трех размерностей, то только три самых внутренних размерности могут иметь размер больше единицы, а остальные размерности должны быть равны единице (например, тензоры размерности (1, 224, 224, 3) поддерживаются, а тензоры (2, 224, 224, 3) – нет);
- в модели используются только те операции, которые поддерживаются процессором Edge TPU в таблице [14] (остальные операции не поддерживаются).

Если нейросетевая модель не удовлетворяет всем перечисленным требованиям, то она может скомпилироваться, *но только часть модели будет выполняться на Edge TPU*, а остальная часть выполнится на CPU.

Выбранные нейросетевые модели были сконвертированы в следующие форматы для сравнения и анализа их точности и производительности:

- «TF» – неоптимизированный формат TensorFlow, нейросетевая модель, как она есть, без конвертаций;
- «float32» – неоптимизированный формат TFLite, где веса сети являются числами с плавающей запятой в формате float32;
- «float16» – оптимизированный формат TFLite, где веса сети являются числами с плавающей запятой в формате float16;
- «dynamic» – оптимизированный формат TFLite, где веса сети являются целочисленными значениями в формате int8, при этом *конвертация осуществляется без представительной выборки*;
- «uint8» – оптимизированный формат TFLite, где веса сети являются целочисленными значениями в формате uint8, при этом *конвертация осуществляется с представительной выборкой*, данный формат TFLite uint8 необходим для последующей компиляции в совместимый с устройствами Edge TPU формат;
- «coral» – формат, совместимый с устройствами Edge TPU и, в частности, с нейросетевым ускорителем Coral.

Для каждой из выбранных семнадцати моделей была выполнена попытка компиляции файла «uint8» в совместимый с устройствами Edge TPU формат («coral»). Результаты компиляции представлены в табл. 1.

Таблица 1

#### Результаты компиляции в совместимый с устройствами Edge TPU формат

Полностью совместимы с Edge TPU	Не совместимы с Edge TPU
MobileNetV2, MobileNetV3Large minimalistic, MobileNetV3Small minimalistic, DenseNet121, InceptionV3, ResNet50, ResNet101, ResNet50V2, ResNet101V2, Xception, VGG16	MobileNet, EfficientNetB0, EfficientNetV2B0, EfficientNetV2S, ConvNeXtTiny, ConvNeXtBase

Результаты компиляции в совместимый с Edge TPU формат («coral») показали, что в следующих моделях есть тензоры с динамическими размерами, которые не поддерживаются устройством Coral: MobileNet, EfficientNetB0, EfficientNetV2B0, EfficientNetV2S.

Модели, которые содержат неподдерживаемые устройством Coral операции: ConvNeXtTiny, ConvNeXtBase. Возможно вручную изменить модель, чтобы в ней использовались только операции, поддерживаемые устройством Edge TPU, но такие модификации архитектур нейронных сетей выходят за рамки данного исследования.

Предварительные исследования для *не* минималистичных моделей MobileNetV3Large и MobileNetV3Small показали, что они успешно скомпилировались, но не все операции поддерживались Edge TPU. По этой причине только часть модели выполнялась на устройстве Coral, а часть модели выполнялась на CPU, что медленнее. При этом точность классификации значительно снизилась для формата TFLite «uint8». С учетом предварительных исследований были отобраны минималистичные модели без нормализации, которые дали приемлемый результат классификации для TFLite «uint8», который оказался лучше, чем у не минималистичных.

Остальные модели оказались полностью совместимы с устройствами Edge TPU.

Разработанное ПО получения данных для тестирования находится в файле «get\_data\_for\_tests.ipynb» [11], а также в GitHub-директории с проектом [10].

### Проведение исследования

Для проверки эффективности работы тензорного процессора Coral были отобраны семнадцать нейросетевых моделей, но только одиннадцать из них скомпилировались в совместимый с устройствами Edge TPU формат (см. табл. 1). По этой причине дальнейшее исследование эффективности бюджетного тензорного процессора Google Coral для решения практических задач классификации изображений проводилось для одиннадцати скомпилированных в совместимый с Edge TPU формат моделей.

При этом нейросетевые модели MobileNetV3Large и MobileNetV3Small были заменены на минималистичные варианты MobileNetV3LargeMin и MobileNetV3SmallMin без нормализации входных изображений. Только в этом случае стандартная архитектура MobileNetV3 дала приемлемые результаты классификации для Coral без модификаций внутренней архитектуры нейронной сети, а только оперируя входными параметрами модели.

По возможности все изображения сжимались до размера 224×224 пикселей, но некоторые нейросетевые модели (InceptionV3, Xception) принимают только изображения 299×299 пикселей. В этом случае изображения сжимались до требуемого размера 299×299. Размеры нейросетевых моделей показаны в табл. 2.

Таблица 2

Размеры нейросетевых моделей

Имя модели	TF директория с моделью, Мб	TFLite файл				
		float32, Мб	float16, Мб	dynamic, Мб	uint8, Мб	coral, Мб
1	2	3	4	5	6	7
MobileNetV2	16,4	13,3	6,7	3,6	3,8	4,1
MobileNetV3LargeMin	17,8	15,0	7,5	4,0	4,1	4,4
MobileNetV3SmallMin	9,9	7,8	3,9	2,1	2,2	2,4
DenseNet121	37,9	30,5	15,3	9,1	8,0	9,3
InceptionV3	96,0	90,9	45,5	23,0	23,2	24,0
ResNet50	101,1	97,4	48,7	24,8	25,1	24,9
ResNet101	177,0	169,8	85,0	43,3	43,9	43,4
ResNet50V2	100,9	97,6	48,8	26,9	25,1	25,4
ResNet101V2	176,7	170,1	85,1	43,6	43,9	44,4
Xception	90,0	87,1	43,6	22,5	23,1	24,2
VGG16	528,1	527,8	263,9	132,0	132,1	132,3

Из табл. 2 видно, что «float32» файлы (столбец 3) немного меньше, чем директория TF с моделью (столбец 2). Размеры файлов с весами «float16» (столбец 4) приблизительно в два раза меньше, чем с весами «float32». Размеры файлов с целочисленными весами «dynamic», «uint8» и «coral» (столбцы 5–7) приблизительно в 3,2–4,0 раза меньше, чем размеры файлов с весами «float32».

Точность классификации нейросетевых моделей измерена на тысяче случайно выбранных тестовых изображений по одному изображению на класс из набора данных ImageNet-v2. Она полностью совпадает для одноплатных компьютеров CoolPi и Pi4. Точность классификации нейросетевых моделей показана в табл. 3.

Таблица 3

Точность классификации нейросетевых моделей

Имя модели	TF, %	TFLite				
		float32, %	float16, %	dynamic, %	uint8, %	coral, %
1	2	3	4	5	6	7
MobileNetV2	56,6	56,6	56,4	56,5	55,5	55,1
MobileNetV3LargeMin	55,4	55,4	55,4	55,3	49,5	49,5
MobileNetV3SmallMin	44,2	44,2	44,2	43	31,6	31,6
DenseNet121	56,3	56,3	56,3	55,8	13,6	12,7
InceptionV3	64,3	64,3	64,3	64,5	64,4	65,2
ResNet50	35,9	35,9	35,6	35,4	35,7	35,4
ResNet101	40,7	40,7	40,6	40,2	40,2	39
ResNet50V2	55,6	55,6	55,6	54,8	55,5	54,5
ResNet101V2	57,3	57,3	57,3	57,5	56,4	57,1
Xception	66,4	66,4	66,5	66,1	15,5	15,2
VGG16	31,9	31,9	31,9	31,9	32,3	32,2

Для сконвертированных в форматы «float32», «float16» и «dynamic» моделей точность классификации не изменяется либо незначительно снижается. Для сконвертированных в форматы «uint8» и «coral» моделей точность классификации может *значительно* уменьшиться.

Точность классификации для нейросетевых моделей DenseNet121 и Xception в форматах «uint8» и «coral» уменьшилась более чем в четыре раза, что неприемлемо для реального их использования совместно с устройством Coral. Точность классификации для минималистических моделей MobileNetV3LargeMin и MobileNetV3SmallMin лучше, чем для не минималистических (в данной работе эти данные не приведены), однако точность классификации для них также снизилась после преобразования в «uint8» формат.

Точность классификации для моделей InceptionV3 и VGG16 в «uint8» формате незначительно возросла на 1 %. Незначительный рост точности связан с тем, что тестовая выборка из 1000 изображений является слишком маленькой, что приводит к значительным флуктуациям в измерениях. Дополнительные тесты на полной тестовой выборке из 10 000 изображений показали, что точность *всегда* снижается при упрощении модели.

Как видно из табл. 3, значительное снижение точности классификации модели происходит на этапе конвертации из TF в «uint8»-формат с использованием представительной выборки, а последующая компиляция в совместимый с Edge TPU формат не приводит к дополнительному значительному снижению точности.

Причины, по которым происходит значительное уменьшение точности при конвертации в «uint8»-формат с использованием представительной выборки, в данном исследовании не рассматриваются. Предположительно, некоторые математические операции не поддерживаются библиотекой TFLite. По этой причине следует изменить архитектуру нейронной сети для поддержки ее библиотекой TFLite и, как следствие, устройством Coral.

Скорость классификации моделей измерена на тех же 1000 изображениях из набора данных ImageNet-v2. Время классификации состоит:

- из предобработки входных изображений (нормализации и квантования);
- обработки (изменения) полученных из изображений тензоров;
- времени работы нейросетевой модели (интерпретатора);
- времени получения результатов и оценки точности классификации;
- удаления нейросетевой модели из оперативной памяти.

Для сравнения, в предыдущем исследовании [15] измерялось только время работы нейросетевой модели (интерпретатора), т. е. только время работы одной команды «interpreter.invoke()». В данных тестах измеряется полное время обработки изображений, кроме подготовительных инициализаций переменных среды и интерпретатора. Такое измерение скорости работы ближе к реальному времени работы всего ПО и лучше характеризует общую производительность одноплатного компьютера.

Скорость классификации нейросетевых моделей для одноплатных компьютеров CoolPi и Pi4 показана в табл. 4 и 5.

Таблица 4

Скорость классификации нейросетевых моделей для CoolPi

Имя модели	TF, мс	TFLite				
		float32, мс	float16, мс	dynamic, мс	uint8, мс	coral, мс
1	2	3	4	5	6	7
MobileNetV2	217	28,7	28,7	26,9	18,5	12,6
MobileNetV3LargeMin	159,6	21,7	21,7	20,1	15,4	10,1
MobileNetV3SmallMin	93,5	10,7	10,7	10,7	9,6	8,5
DenseNet121	521,5	187,5	187,3	103,4	74	22,5
InceptionV3	542,4	342,8	342,5	134,7	107	57,5
ResNet50	425,4	245,9	245,3	101,3	77,1	54
ResNet101	817	456,5	455,6	171,1	135,6	101,7
ResNet50V2	404,8	229,9	228,7	96,8	79,2	56
ResNet101V2	799,9	444,1	444,1	171,1	142,8	104,6
Xception	551,4	508,7	510,2	229,8	186	70,4
VGG16	490,3	976,2	974,2	307,2	246	340,3

Таблица 5

Скорость классификации нейросетевых моделей для Pi4

Имя модели	TF, мс	TFLite				
		float32, мс	float16, мс	dynamic, мс	uint8, мс	coral, мс
1	2	3	4	5	6	7
MobileNetV2	559,2	92,4	92,3	101	65,6	27,1
MobileNetV3LargeMin	482,4	67,8	67,6	72,7	50,9	20,2
MobileNetV3SmallMin	314,2	29,2	27,7	29,2	26,8	18,6
DenseNet121	1540	631,1	630	525,5	376,7	34,8
InceptionV3	1450,7	1209,8	1206,3	747,5	624,8	85,2
ResNet50	1009,5	911	928,2	550,4	474,8	77,1
ResNet101	1967,6	1874,2	1862,1	1004,7	841,7	139,3
ResNet50V2	1004,1	889,9	889	516,2	448,7	81
ResNet101V2	1936,8	1838,5	1850,7	976,5	822,5	143,7
Xception	1401,4	2212	2216,6	1158,2	953,1	97,4
VGG16	1462,9	3854,5	3855,9	1807	1760,1	452,5

В табл. 4 и 5 указана средняя скорость обработки одного изображения в миллисекундах. Чтобы получить полное время обработки тысячи изображений на тестовом наборе данных, среднее время следует умножить на тысячу. Полное время прохождения всех тестов для CoolPi на уменьшенной до тысячи штук базе изображений составило приблизительно 4,5 часа. Полное время прохождения всех тестов для Pi4 составило почти шестнадцать часов.

Для анализа и сравнения производительности, а также точности классификации Pi4, CoolPi и Coral для различных архитектур нейронных сетей и с различными параметрами конвертации для TFLite на основе табл. 4 и 5 были составлены тепловые карты.

На рис. 3 показана тепловая карта соотношения скоростей Pi4 к CoolPi. Для ее получения время каждой ячейки из табл. 5 разделено на время соответствующей ячейки из табл. 4. Из тепловой карты видно, что одноплатный компьютер CoolPi опережает Pi4 по скорости вычислений в несколько раз. Для отличных от MobileNet моделей и форматов «dynamic», «uint8» разница скоростей вычислений увеличивается еще больше – от 5,0 до 7,2 раза.

Model name	TF, times	TFLite				
		f32, times	f16, times	dyn, times	uint8, times	coral, times
MobileNetV2	2,6	3,2	3,2	3,8	3,5	2,2
MobileNetV3LargeMin	3,0	3,1	3,1	3,6	3,3	2,0
MobileNetV3SmallMin	3,4	2,7	2,6	2,7	2,8	2,2
DenseNet121	3,0	3,4	3,4	5,1	5,1	1,5
InceptionV3	2,7	3,5	3,5	5,5	5,8	1,5
ResNet50	2,4	3,7	3,8	5,4	6,2	1,4
ResNet101	2,4	4,1	4,1	5,9	6,2	1,4
ResNet50V2	2,5	3,9	3,9	5,3	5,7	1,4
ResNet101V2	2,4	4,1	4,2	5,7	5,8	1,4
Xception	2,5	4,3	4,3	5,0	5,1	1,4
VGG16	3,0	3,9	4,0	5,9	7,2	1,3

Рис. 3. Тепловая карта соотношения скоростей классификации Pi4 к CoolPi

При вычислениях на устройстве Coral (см. последнюю колонку тепловой карты на рис. 3 соотношение скоростей между CoolPi и Pi4 не так значительно и составляет от 1,3 до 2,2 раза. При вычислениях с использованием Coral часть расчетов выполняется нейросетевым ускорителем Coral, что разгружает центральный процессор CPU одноплатного компьютера и делает разницу скоростей между одноплатными компьютерами не столь значительной.

На рис. 4 и 5 показаны тепловые карты соотношений различных колонок табл. 4 и 5. Например, колонка 2/3 на рис. 4 означает соотношение значения времени в колонке два табл. 4, поделенное на значение из третьей колонки этой же таблицы. Как видно из тепловых карт на рис. 4 и 5, дополнительная оптимизация из «float32» в «float16» не дала прироста к скорости, потому что соотношение 3/4 третьей и четвертой колонок равно 1,0 почти во всех случаях.

Model name	2/3	2/4	2/5	2/6	2/7		3/4	3/5	3/6	3/7		6/7
MobileNetV2	7,6	7,6	8,1	11,7	17,2		1,0	1,1	1,6	2,3		1,5
MobileNetV3LargeMin	7,4	7,4	7,9	10,4	15,8		1,0	1,1	1,4	2,1		1,5
MobileNetV3SmallMin	8,7	8,7	8,7	9,7	11,0		1,0	1,0	1,1	1,3		1,1
DenseNet121	2,8	2,8	5,0	7,0	23,2		1,0	1,8	2,5	8,3		3,3
InceptionV3	1,6	1,6	4,0	5,1	9,4		1,0	2,5	3,2	6,0		1,9
ResNet50	1,7	1,7	4,2	5,5	7,9		1,0	2,4	3,2	4,6		1,4
ResNet101	1,8	1,8	4,8	6,0	8,0		1,0	2,7	3,4	4,5		1,3
ResNet50V2	1,8	1,8	4,2	5,1	7,2		1,0	2,4	2,9	4,1		1,4
ResNet101V2	1,8	1,8	4,7	5,6	7,6		1,0	2,6	3,1	4,2		1,4
Xception	1,1	1,1	2,4	3,0	7,8		1,0	2,2	2,7	7,2		2,6
VGG16	0,5	0,5	1,6	2,0	1,4		1,0	3,2	4,0	2,9		0,7

Рис. 4. Тепловая карта соотношения столбцов CoolPi



Model name	2/3	2/4	2/5	2/6	2/7		3/4	3/5	3/6	3/7		6/7
MobileNetV2	6,1	6,1	5,5	8,5	20,6		1,0	0,9	1,4	3,4		2,4
MobileNetV3LargeMin	7,1	7,1	6,6	9,5	23,9		1,0	0,9	1,3	3,4		2,5
MobileNetV3SmallMin	10,8	11,3	10,8	11,7	16,9		1,1	1,0	1,1	1,6		1,4
DenseNet121	2,4	2,4	2,9	4,1	44,3		1,0	1,2	1,7	18,1		10,8
InceptionV3	1,2	1,2	1,9	2,3	17,0		1,0	1,6	1,9	14,2		7,3
ResNet50	1,1	1,1	1,8	2,1	13,1		1,0	1,7	1,9	11,8		6,2
ResNet101	1,0	1,1	2,0	2,3	14,1		1,0	1,9	2,2	13,5		6,0
ResNet50V2	1,1	1,1	1,9	2,2	12,4		1,0	1,7	2,0	11,0		5,5
ResNet101V2	1,1	1,0	2,0	2,4	13,5		1,0	1,9	2,2	12,8		5,7
Xception	0,6	0,6	1,2	1,5	14,4		1,0	1,9	2,3	22,7		9,8
VGG16	0,4	0,4	0,8	0,8	3,2		1,0	2,1	2,2	8,5		3,9

Рис. 5. Тепловая карта соотношения столбцов Pi4

Дополнительные оптимизации «dynamic» и «uint8» не дали значительного ускорения работы для архитектур MobileNet (см. колонки 3/5 и 3/6 на рис. 4 и 5). Однако для других архитектур наблюдается значительное ускорение в работе примерно от 1,2 до 4,0 раза, что соответствует официально заявленному [8] двух-трехкратному приросту в скорости при вычислениях на CPU.

Для архитектур MobileNet преобразование в формат TFLite «float32» без дополнительных оптимизаций дает значительное ускорение в скорости вычислений без потери точности (см. колонку 2/3 на рис. 4 и 5). Для остальных архитектур требуются дополнительные оптимизации («dynamic» и «uint8») для того, чтобы значительно ускорить скорость вычислений.

Что касается вычислений на устройстве Coral (см. колонки 2/7, 3/7 и 6/7 на рис. 4 и 5), то наилучшие показатели для моделей DenseNet121 и Xception следует исключить из рассмотрения, поскольку точность классификации для них после конвертации в формат «uint8» (см. табл. 3) снизилась до неприемлемого в использовании на практике уровня.

### Обсуждение полученных результатов

Самыми точными из выбранных одиннадцати моделей являются Xception (66,4%) и InceptionV3 (64,3%), которые опережают остальные девять моделей (см. табл. 3). К сожалению, для Xception требуется модификация архитектуры в процессе использования на устройстве Coral, так как точность модели значительно снижается при конвертации в необходимый формат «uint8» (см. табл. 3).

Самыми быстрыми из выбранных моделей являются три архитектуры MobileNet (см. табл. 4 и 5), которые с большим отрывом опережают остальные модели по скорости работы как до, так и после конвертации в форматы TFLite. К сожалению, для третьей версии MobileNetV3 требуется модификация для использования на устройстве Coral, так как точность модели существенно снижается при конвертации в необходимый формат «uint8» (см. табл. 3).

Из выбранных моделей выделяется модель с архитектурой ResNet50V2, которая обладает приемлемым соотношением «точность – скорость» и поддерживается устройством Coral без дополнительных модификаций. ResNet50V2 уступает MobileNetV2 значительно по скорости и незначительно уступает по точности. ResNet50V2 уступает InceptionV3 значительно по точности и незначительно превосходит InceptionV3 по скорости.

Таким образом, если важна скорость, то следует выбрать модель с архитектурой MobileNetV2, а если важна точность, то следует выбрать модель с архитектурой InceptionV3. Этот выбор верен как с использованием устройства Coral, так и без его использования.

Использование тензорного процессора Coral позволяет ускорить скорость классификации от 1,5 (CoolPi) до 2,4 (Pi4) раза для модели MobileNetV2 (см. колонку 6/7 на рис. 4 и 5) и от 1,9 (CoolPi) до 7,3 (Pi4) раза для модели InceptionV3 (см. колонку 6/7 на рис. 4 и 5).

Рекомендуется использование Coral в составе одноплатного компьютера Pi4, иначе скорость работы разрабатываемого бортового микроархитектурного вычислительного комплекса МВК «БортВК», в основе которого будет использоваться одноплатный компьютер, может оказаться весьма медленной.

### Заключение

Тесты производительности и точности классификации стандартных архитектур нейронных сетей без их дополнительных модификаций показали, что если важна скорость вычислений, то следует выбрать модель нейронной сети с архитектурой MobileNetV2, а если важна точность вычислений, то следует выбрать модель нейронной сети с архитектурой InceptionV3. Этот выбор верен как с использованием устройства Google Coral USB Accelerator, так и без него. Использование тензорного процессора Google Coral USB Accelerator позволяет увеличить общую скорость классификации от 1,5 раза для одноплатного компьютера Cool Pi 4 Model B до 2,4 раза для одноплатного компьютера Raspberry Pi 4 Model B при использовании модели нейронной сети MobileNetV2 и от 1,9 до 7,3 раза соответственно при использовании модели нейронной сети InceptionV3.

### Библиографический список

1. CoolPi 4 Model B. URL: [https://wiki.cool-pi.com/4b/coolpi\\_4\\_model\\_b\\_spec\\_v1.0.pdf](https://wiki.cool-pi.com/4b/coolpi_4_model_b_spec_v1.0.pdf) (дата обращения: 11.07.2024).
2. Raspberry Pi 4. URL: <https://www.raspberrypi.com/products/raspberry-pi-4-model-b> (дата обращения: 11.07.2024).
3. USB Accelerator. URL: <https://coral.ai/products/accelerator> (дата обращения: 11.07.2024).
4. Module: tf.keras.applications. URL: [https://www.tensorflow.org/api\\_docs/python/tf/keras/applications](https://www.tensorflow.org/api_docs/python/tf/keras/applications) (дата обращения: 31.07.2024).
5. tf.lite.TFLite Converter. URL: [https://www.tensorflow.org/api\\_docs/python/tf/lite/TFLiteConverter](https://www.tensorflow.org/api_docs/python/tf/lite/TFLiteConverter) (дата обращения: 11.07.2024).
6. Edge TPU Compiler. URL: <https://coral.ai/docs/edgetpu/compiler> (дата обращения: 11.07.2024).
7. imagenet\_v2. URL: [https://www.tensorflow.org/datasets/catalog/imagenet\\_v2](https://www.tensorflow.org/datasets/catalog/imagenet_v2) (дата обращения: 11.07.2024).
8. Post-training quantization. URL: [https://www.tensorflow.org/lite/performance/post\\_training\\_quantization](https://www.tensorflow.org/lite/performance/post_training_quantization) (дата обращения: 11.07.2024).
9. Gallery of ImageNet Sample Images. URL: <https://github.com/EliSchwartz/imagenet-sample-images/blob/master/gallery.md> (дата обращения: 11.07.2024).
10. Coral TPU project. URL: [https://github.com/foobar167/junkyard/tree/master/coral\\_tpu](https://github.com/foobar167/junkyard/tree/master/coral_tpu) (дата обращения: 11.07.2024).
11. Get data for tests. URL: [https://colab.research.google.com/drive/1YLFMUxzHETA\\_uOK69X\\_YQ\\_ei913W5cTMo](https://colab.research.google.com/drive/1YLFMUxzHETA_uOK69X_YQ_ei913W5cTMo) (дата обращения: 11.07.2024).
12. Run TensorFlow on CPU, GPU and TPU. URL: <https://colab.research.google.com/drive/1fRB3-xYYJt6n2yDAysDxpwzifiAIAbNq> (дата обращения: 11.07.2024).
13. Additional test to run different options. URL: [https://colab.research.google.com/drive/18yocNI6P7xIFq3MIYJ\\_ET-SzYMUv9uPd](https://colab.research.google.com/drive/18yocNI6P7xIFq3MIYJ_ET-SzYMUv9uPd) (дата обращения: 11.07.2024).
14. TensorFlow models on the Edge TPU. Supported operations. URL: <https://coral.ai/docs/edgetpu/models-intro/#supported-operations> (дата обращения: 12.07.2024).
15. Павленко Д. А. Сравнительный анализ производительности одноплатных компьютеров для разработки микроархитектурного вычислительного комплекса обнаружения возгораний // Информатика. 2024. Т. 21, № 2. С. 73–85.

*А. А. Сенцов\**

кандидат технических наук, доцент

*С. А. Иванов\*\**

кандидат технических наук

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

\*\*Санкт-Петербургский государственный экономический университет

## РЕАЛИЗАЦИЯ ГЕНЕРАТИВНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ РЕШЕНИЯ ЗАДАЧИ ВЫДЕЛЕНИЯ ТЕХНОГЕННЫХ ВОЗДУШНЫХ ОБЪЕКТОВ ПРИ РАДИОЛОКАЦИОННОМ ОБЗОРЕ

Освещены вопросы обнаружения малоразмерных воздушных объектов с применением алгоритмов распознавания объектов на радиолокационных портретах, сформированных при помощи радиолокационных мобильных станций. Результатом разработки являются создание методики и программного-аппаратного модуля на базе малабаритного мобильного интеллектуального радиолокационного комплекса, оценка реализации на современной отечественной элементной базе и определение его характеристик. Предложен способ распознавания малоразмерных объектов на основе применения алгоритмов нейронных сетей.

**Ключевые слова:** радиолокационная станция, нейронные сети, объект техногенного происхождения, распознавание воздушных объектов.

*A. A. Sentsov\**

PhD, Tech., Associate Professor

*S. A. Ivanov\*\**

PhD, Tech.

\*St. Petersburg State University of Aerospace Instrumentation

\*\*St. Petersburg State University of Economics

## IMPLEMENTATION OF GENERATIVE NEURAL NETWORK TO SOLVE THE TASK OF IDENTIFICATION OF TECHNOLOGICAL AERIAL OBJECTS IN RADAR SURVEY

The issues of detection of small air objects by using object recognition algorithms on radar portraits formed with the help of mobile radar stations are covered. The result of development is creation of methodology and software-hardware module on the basis of small mobile intelligent radar complex, evaluation of implementation on modern domestic elemental base and determination of its characteristics. The method of recognition of small objects based on the application of algorithms of neural networks is proposed.

**Keywords:** radar station, neural networks, object of man-made origin, recognition of aerial objects.

Применение радиолокационных станций (РЛС) обзора воздушного пространства за время их развития получило широкое распространение. Сферы применения не ограничиваются только военной или космической областями. РЛС широко применяются и в гражданской области, как средства обнаружения и предотвращения техногенных катастроф, причинами которых может являться отсутствие оперативной информации о движении техногенного объекта [1; 2].

Само применение радиолокации дает такие преимущества по отношению к другим средствам обзора, как широкий охват пространства вплоть до реализации кругового обзора, значительные дальности обнаружения за счет изменения энергопотенциала и характеристик РЛС, всепогодность и круглосуточность функционирования. Несмотря на перечисленные достоинства, у современных РЛС есть недостатки, которые не позволяют расширить область их применения. К ним можно отнести: значительные размеры и массу, сложность при конструировании, разработке, изготовлении и обслуживании, высокие требования к подготовке специалиста-оператора [3–5]. С развитием науки и технологий производственные недостатки со временем могут быть нивелированы, а для упрощения работы оператора РЛС достаточно осуществить внедрение современных математических алгоритмов обработки информации, реализованных в программных модулях на рабочем месте обработки информации, что является одной из групп методов повышения эффективности существующих радиолокационных средств [6].

В классической радиолокации принято выделять первичную, вторичную и третичную обработку информации. При первичной обработке решается задача о наличии в принятом сигнале полезной составляющей, отразившейся от объекта наблюдения. При этом оператор РЛС должен подобрать параметры излучения, которые снизят вероятность ложной тревоги. Реализация алгоритмов адаптивной фильтрации, построение оптимального приемника РЛС позволяют решать задачу первичной обработки информации в автоматическом режиме, снижая нагрузку на оператора.

Задача вторичной обработки информации заключается в получении координат обнаруженного объекта. Так как РЛС являются активными и направленными средствами обзора пространства, то по обнаруженному объекту в автоматическом режиме фиксируются два пространственных угла положения и дальность от точки стояния РЛС. Участие оператора при решении данной задачи минимально, сводится лишь к возможности получения дополнительной информации от объекта, такой как скорость или высота движения.

При третичной обработке информации должно быть принято решение о принадлежности обнаруженного объекта к определенному классу: техногенных объектов или объектов природного происхождения. Данная задача распознавания и отождествления объекта полностью находится в области знаний и компетенций оператора РЛС. Именно она выдвигает повышенные требования к уровню его подготовки. В качестве примера на рис. 1 представлен экран рабочего места оператора с обнаруженными объектами при обзоре пространства в секторе, полученный в результате инициативной разработки совместно с ПАО «ЦНПО „Ленинец“» [7]. При этом формируемые на экране траектории не имеют принадлежности к классам распознаваемых объектов, а номер присваивается в порядке очередности и заносится в статистическую таблицу обнаруженных объектов.




Рис. 1. Экран рабочего места оператора

Решение о принадлежности объекта к определенному классу оператор осуществляет на основе анализа траекторных признаков: скорость и направление движения, вид траектории, а также используя в большей степени свой накопленный опыт при решении подобной задачи. Для повышения вероятности правильного распознавания объекта дополнительно к траекторным признакам можно использовать сигнальные признаки, к которым относятся амплитуда и спектр отраженного сигнала [8; 9]. Более информативен для оператора спектр сигнала, так как амплитуда отраженного сигнала в большей степени зависит от энергopotенциала станции. Алгоритмически построение спектра отраженного сигнала не представляет большой сложности, несмотря на значительный объем необходимых вычислений. На рис. 2 представлены спектральные портреты, полученные от объектов природного и техногенного происхождения [10].

а)



б)




Рис. 2. Спектральный портрет от природного (а) и техногенного (б) объектов

Наличие дополнительных боковых составляющих в спектре сигнала позволяет оператору решить задачу с большей вероятностью правильного распознавания. Для автоматизации данного процесса возможны внедрение и реализация нейронной сети, у которой на вход будет поступать оцифрованный спектр сигнала, а на выходе будет формироваться решение о принадлежности объекта к определенному классу.

Для решения задачи обучения нейронной сети в данном случае предлагается реализация генеративной нейронной сети (ГНС). ГНС способна провести имитацию распределения составляющих в спектре отраженного сигнала от объекта природного происхождения, тем самым становится возможным значительное повышение количества записей в базе для обучения нейронной сети. Алгоритм генеративной сети относится к классу алгоритмов машинного обучения без учителя. Принцип функционирования заключается в использовании комбинации из двух нейронных сетей. Задача первой нейронной сети заключается в генерации образцов записей на основе имеющейся реальной записи из базы знаний. Вторая нейронная сеть получает на вход сгенерированное изображение и истинный образец записи, в результате ее функционирования принимается решение об истинности или ложности сгенерированного образца записи. В случае принятия изображения как истинного он добавляется в базу знаний нейронной сети. Схематично алгоритм функционирования генеративной сети представлен на рис. 3.



Рис. 3. Алгоритм функционирования генеративной сети для повышения количества записей в базе знаний

Реализация данного алгоритма становится возможным за счет представления записи спектра сигнала, как изображения с размерами 115 на 30 пикселей. На рис. 4 представлена схема функционирования первой нейронной сети (генератора) ГНС [11; 12].




Рис. 4. Схема функционирования генератора ГНС

Принцип работы генератора ГНС заключается в том, что на его первом слое проводится отражение полученного изображения спектра сигнала по краям для использования информации о граничных пикселях. В результате добавляются пиксели симметрично с краев изображения. Далее в слоях со второго по девятый повторяются стандартные процедуры для нейронных сетей. Применяется сверточный слой, в котором реализуется функция свертки с ядром размером  $14 \times 14$  для извлечения признаков из входного изображения. Далее осуществляется операция нормализации по экземпляру с целью нормализации активаций между слоями. В результате калибруется каждый канал входного изображения независимо от других каналов. После этого поэлементно к выходу предыдущего слоя применяется функция активации  $ReLU(x) = \max(0, x)$ , которая удаляет полученные отрицательные значения и применяет пороговую функцию активации, оставляя положительные значения без изменений.

Функция транспонирования свертки реализуется в слоях с десятого по пятнадцатый и позволяет увеличить изображение с последующим применением функции нормализации активации. В 16-м слое генератора ГНС реализуется отражение изображения, и в последнем 18-м слое используется функция гиперболического тангенса в качестве функции активации. В результате осуществляется масштабирование значений пикселей изображения в диапазоне значений от  $-1$  до  $1$ , что является достаточным для представления изображения спектра сигнала.

Функционирование второй нейронной сети (дискриминатора) ГНС можно представить в виде схемы, представленной на рис. 5 [13].

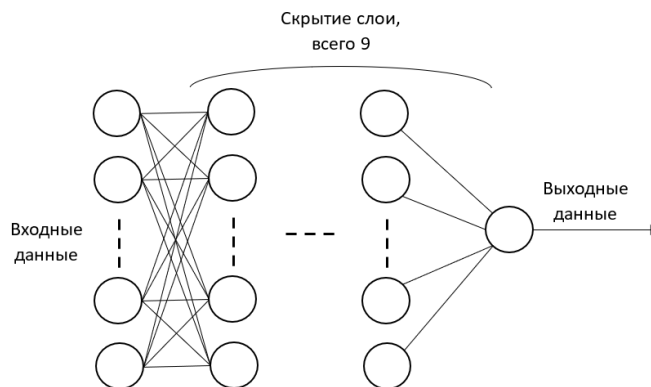


Рис. 5. Схема функционирования дискриминатора ГНС

Дискриминатор представляет собой нейронную сеть со входным, девятью скрытыми и выходным слоями. Задача дискриминатора заключается в сравнении выходных данных, полученных от генератора ГНС с реальным размеченным изображением спектра сигнала от объекта природного происхождения. Для этого сначала сверточный слой выполняет операцию свертки на входных данных. Далее применяется функция активации LeakyReLU поэлементно к выходу предыдущего слоя. Ее применение обусловлено тем, что функция возвращает само значение при положительном входном значении, а при отрицательном возвращает линейную функцию от входного значения, умноженную на коэффициент. В результате у каждого нейрона слоя есть возможность влиять на выходную функцию, даже если выходные величины отрицательные. Математически это можно представить следующим образом:  $\text{LeakyReLU}(x) = \max(a \cdot x, x)$ . Применение коэффициента в функции активации LeakyReLU позволяет сохранить информацию о небольших отрицательных значениях.

Для нормализации каждого канала изображения независимо от других каналов применяется функция нормализации InstanceNorm2D. Она предназначена для улучшения качества выходного изображения путем нормализации экземпляра за счет определения среднего значения и стандартного отклонения для каждого значения в слое. Для извлечения признаков изображений спектрального портрета слои повторяются с различными параметрами, образуя девять скрытых слоев дискриминатора ГНС. Последний сверточный слой является выходным, принимает 512 входных каналов и выдает один канал с решением об истинности или ложности сгенерированного изображения спектра сигнала. Результат работы ГНС представлен на рис. 6.

а)



б)




Рис. 6. Спектр сигнала от объекта природного происхождения (а) и спектр сигнала, полученный с помощью ГНС (б)

В результате применения генеративной нейронной сети стало возможным наполнение базы знаний нейронной сети распознавания качественными записями, не отличающимися от реальных спектров сигналов. Таким образом решение задачи распознавания объекта наблюдения может выполняться автоматически с большой

степень достоверности. Задача оператора РЛС сводится лишь к выбору объекта наблюдения, по которому необходимо осуществить распознавание.

На рис. 7 показан экран рабочего места оператора с реализацией распознавания по спектральному портрету, полученный в результате инициативной разработки совместно с ПАО «ЦНПО „Ленинец“» [10; 14]. Для получения координат по обнаруженному объекту необходимо навести курсор на яркостную отметку и нажать левой клавишей мыши. При этом курсор изменит вид на перекрестие с отображением текущих координат объекта: дирекционного угла, дальности, высоты, скорости и направления движения. Классификация объектов отображается в виде символов: \* – объект типа «техногенный»; ^ – объект типа «птица».




Рис. 7. Экран рабочего места оператора с реализацией распознавания по спектральному портрету

На рис. 8 представлен результат распознавания обнаруженного объекта с отнесением к классу «техногенного происхождения», полученный в результате инициативной разработки совместно с ПАО «ЦНПО „Ленинец“» [10; 14].




Рис. 8. Результат распознавания обнаруженного объекта с отнесением к классу «техногенного происхождения»

Реализованная генеративная нейронная сеть позволила сформировать полноценную базу знаний для обучения разрабатываемого нейросетевого модуля распознавания техногенных воздушных объектов, который применяется в мобильном интеллектуальном радиолокационном комплексе, спроектированном на базе технологии построения перспективных РЛС [15; 16].

#### Библиографический список

1. Макаренко С. И. Противодействие беспилотным летательным аппаратам: монография. СПб.: Научные технологии, 2020. 204 с.
2. Проскурин В. И., Ягольников С. В., Шевчук В. И. Радиолокационное наблюдение. Методы, модели, алгоритмы. М.: Радиотехника, 2016. 368 с.
3. Ерошенков М. Г. Радиолокационный мониторинг. М.: МАКСПресс, 2004. 452 с.
4. Integrated Tracking, Classification, and Sensor Management: Theory and Applications / M. Mallick, V. Krishnamurthy, B. N. Vo [et al.]. N. Y.: Wiley-IEEE, 2012. 736 p.
5. Toro G. F., Tsourdos A. UAV sensors for environmental monitoring. Belgrade: MDPI, 2018. 661 p.
6. Сенцов А. А. Методы повышения эффективности радиолокационных средств обнаружения воздушных объектов // Метрологическое обеспечение инновационных технологий: V Междунар. форум: сб. ст. / под ред. акад. РАН В. В. Окрепилова. – СПб.: ГУАП, 2023. С. 193–195.
7. Сенцов А. А., Поляков В. Б., Дмитриев В. Ф. Комплекс мобильных радиолокационных станций внешнетракторных измерений // Вопросы радиоэлектроники. 2019. № 9. С. 30–35.
8. Петров И. Д., Шкодырев В. П. Обработка эхо-сигналов при радиолокационном наблюдении беспилотных летательных аппаратов // Т-Сomm: Телекоммуникации и транспорт. 2021. Т. 15. № 9. С. 48–54.
9. Татьянакин Д. А. Подход к формированию архитектуры нейронной сети для распознавания образов // Вестник Югорского государственного университета. 2016. № 2(41). С. 61–64.
10. Sentsov A. A., Ivanov S. A., Kostenko D. A. Application of cognitive technologies in solving the recognition task // XXIV International conference «Wave Electronics and its Application in Information and Telecommunication Systems» (WECONF-2022), St. Petersburg, Russia, 2022. P. 1–4.
11. Parallel Deep Convolutional Neural Network Training by Exploiting the Overlapping of Computation and Communication / S. Lee, D. Jha, A. Agrawal [et al.] // 2017 IEEE 24th International Conference on High Performance Computing (HiPC), Jaipur, 2017. P. 183–192.
12. Бредихин А. И. Алгоритмы обучения сверточных нейронных сетей // Вестник Югорского государственного университета. 2019. № 1(52). С. 41–54.
13. Тарик Р. Создаем нейронную сеть: пер. с англ. СПб.: Альфа-книга, 2017. 272 с.
14. Иванов С. А., Сенцов А. А. Вариант применения нейросетевых технологий в решении задачи распознавания малоразмерных воздушных объектов // Региональная информатика (РИ-2022): Юбилейная XVIII С.-Петерб. Междунар. конф.: матер. конф. СПб., 2022. С. 234–235.
15. Сидоренко К. А. Мобильная радиолокационная станция. Патент RU2729704C1 РФ, опубл. 2020-08-11.
16. Radar, and Target Tracking and Data Fusion. L.: Scitech Publishing, 2017. 553 p.



УДК 65.01.007

*А. В. Спесивцев\**

доктор технических наук, доцент

*Ю. Н. Тиличко\**

старший научный сотрудник

*В. А. Спесивцев\**

младший научный сотрудник

\*Санкт-Петербургский Федеральный исследовательский центр Российской академии наук

## МЕТОДОЛОГИЯ ПОСТАНОВКИ И РЕШЕНИЯ ЗАДАЧИ УПРАВЛЕНИЯ ВЗАИМОВЛИЯНИЕМ В КОМПЛЕКСНОЙ СИСТЕМЕ «СЛОЖНЫЙ ОБЪЕКТ – ОКРУЖАЮЩАЯ СРЕДА»

В структуре сложных комплексов взаимодействия сложных объектов с окружающей средой выделена особая зона взаимодействия и взаимовлияния, процессы в которой обуславливают как деградацию экологического состояния природной среды, так и влияние на жизненный цикл сложного объекта искусственного происхождения. Рассмотрен один из подходов решения проблемы принятия обоснованных управленческих решений посредством создания интегрированной информационной системы, адаптированной в структуру сложных комплексов.

**Ключевые слова:** сложный объект, окружающая среда, зона взаимодействия и взаимовлияния, интегрированная информационная система, структура сложного комплекса.

Исследования, выполненные по данной тематике, проводились при частичной финансовой поддержке гранта РФФИ 24-19-00823.

*A. V. Spesivtsev\**

Dr. Sc., Tech., Associate Professor

*Yu. N. Tilichko\**

Senior Research Employee

*V. A. Spesivtsev\**

Junior Research Employee

\*St. Petersburg Federal Research Center of the Russian Academy of Sciences

## METHODOLOGY OF THE ESTABLISHMENT AND SOLUTION OF THE TASK OF MANAGEMENT OF MUTUAL RELATIONS IN A COMPLEX SYSTEM «COMPLEX OBJECT – ENVIRONMENT»

In the structure of complex complexes of interaction with complex objects with the environment, a special area of interaction and reciprocity is highlighted, the study of the processes that occur as a degradation of the environmental state of the natural environment, and the impact on the life cycle of a complex artificial object. One of the approaches to solve the problem of making informed management decisions through the creation of an integrated information system adapted to the structure of complex complexes is considered.

**Keywords:** complex object, environment, area of interaction and mutual connection, integrated information system, structure of complex complex.

### Введение

В процессе функционирования любого сложного объекта (СЛО) наземной инфраструктуры происходят неизбежное его взаимодействие с природной окружающей средой (ОС) и их взаимовлияние. В данном исследовании вводится новое понятие зоны взаимодействия и взаимовлияния (ЗВВ) как естественного объекта изучения, обладающего особенностями ввиду различного рода негативных или нежелательных изменений в процессе его жизнедеятельности. Таким образом, в сложный комплекс (СлК), состоящий из СЛО и СО, включается очень важная составляющая ЗВВ, характеристики которой в рассматриваемой проблеме обладают достаточно высокой неопределенностью. Например, понятно, что жизнедеятельность пространственного кластера естественной СО, т. е. способность самовосстановления при воздействиях СЛО, определяется градиентами – разностями различных параметров, характеристик, свойств или иных атрибутов СлК. Именно они и задают ритм рабочих и естественных процессов ЗВВ.

Понятие ЗВВ в широком смысле охватывает практически любые поверхности физических объектов, поскольку всегда им сопутствует соприкосновение с другими средами, как дружественными (смазка), так и недружественными (ржавление). Изучение приграничных областей присуще многим предметным областям (ПрО) науки и техники, что приводит к разработке и получению новых научных результатов: в гидродинамике – к теории пограничного слоя при обтекании объектов различными средами; в сельском хозяйстве – к науке о процессе циркуляции азота в природе (воздух – земля – растения – усвоение кормов – органические удобрения – земля –

воздух) и способов управления им. Однако исследованиям процессов в ЗВВ, на наш взгляд, уделяется недостаточно внимания, о чем свидетельствуют многочисленные экологические и техногенные катастрофы [1].

На рис. 1 приведена принципиальная схема динамики происходящих процессов в ЗВВ согласно представлениям разрабатываемой проблемы. По оси абсцисс указано время  $T$  от начала функционирования СлК, по оси ординат  $N$  – уровень воздействия некоторого негативного качества в СлК: кривая L2 указывает на развивающийся во времени процесс нарастания негативного воздействия СлО на ОС, а кривая L1 – на потерю свойств самовосстановления ОС от негативного воздействия СлО от начала фоновых значений  $N$ . При этом точка пересечения графиков рассматриваемых тенденций указывает время  $T_{\max}$ , после которого ОС уже не способна к самовосстановлению до своего прежнего естественного фона.




Рис. 1. Схема действия стабилизирующих процессов в зоне взаимодействия и взаимовлияния сложного комплекса

Цель данной статьи – обоснование идеологии создания интегрированной интеллектуальной системы (ИИС) для управления и регулирования процессами в ЗВВ и предложение одного из вариантов формирования модельно-алгоритмического комплекса (МАК) с адаптированной в него информационной системой.

### Вариант построения структуры комплекса

В научно-технической литературе сложилось устойчивое представление о том, что трудноформализуемые СлО, а тем более СлК слабо поддаются моделированию детерминированными математическими методами и лучшие результаты дает применение подходов и технологий формализации сложных многоструктурных предметных областей (Про), к которым относится и проблема решения задач ЗВВ СлК, включая разнообразие информационных сред: обработку слабоформализованной и нечеткой информации вероятностно-статистическим и нечетко-возможностными методами; логико-динамическое описание многоструктурных состояний; их полимодельное описание; сверточный подход к многокритериальному выбору и др. [2–6]. Отмечается также, что совместное использование всех упомянутых подходов позволяет эффективно оперировать как количественными, так и качественными исходными данными об исследуемой проблеме при решении всего комплекса информационно-кибернетических задач как задачи создания и поддержки ЖЦ СлК (СлО – ЗВВ – ОС), так и традиционных системно-кибернетических задач, связанных с анализом, наблюдением, идентификацией, синтезом и моделированием этого комплекса [2; 3].

Проблемы методологического характера, связанные с подбором или созданием расчетных и методических средств решения проблем организации и управления жизнедеятельностью СлК, включают следующие условия: рассмотрение ЗВВ как одну из основных составных частей СлК; постановка и решение создаваемых самим существованием СлК задач многокритериального оценивания состояния ЗВВ; создание МАК для управления и регулирования состояния ЗВВ применительно к изменяющимся внешним и внутренним условиям жизнедеятельности СлК.

На рис. 2 предложен один из возможных вариантов подхода к формированию МАК с адаптированной в него ИИС. Структура МАК представлена в виде функционально и организационно связанных между собой компонент.

1) СТСРУ – субъектная и техническая среда регулирования и управления, которая включает: ЛПР; объектную составляющую СДРС ВИК; технические средства передачи команд; средства преобразования результатов вычисления в регулирующий и/или управляющий сигнал; средства отображения результатов мониторинга и выходных параметров состояния элементов ВИК ЛПР; устройств передачи значений выходных параметров автоматизированным техническим средствам для выработки управленческих команд внутри ВИК;

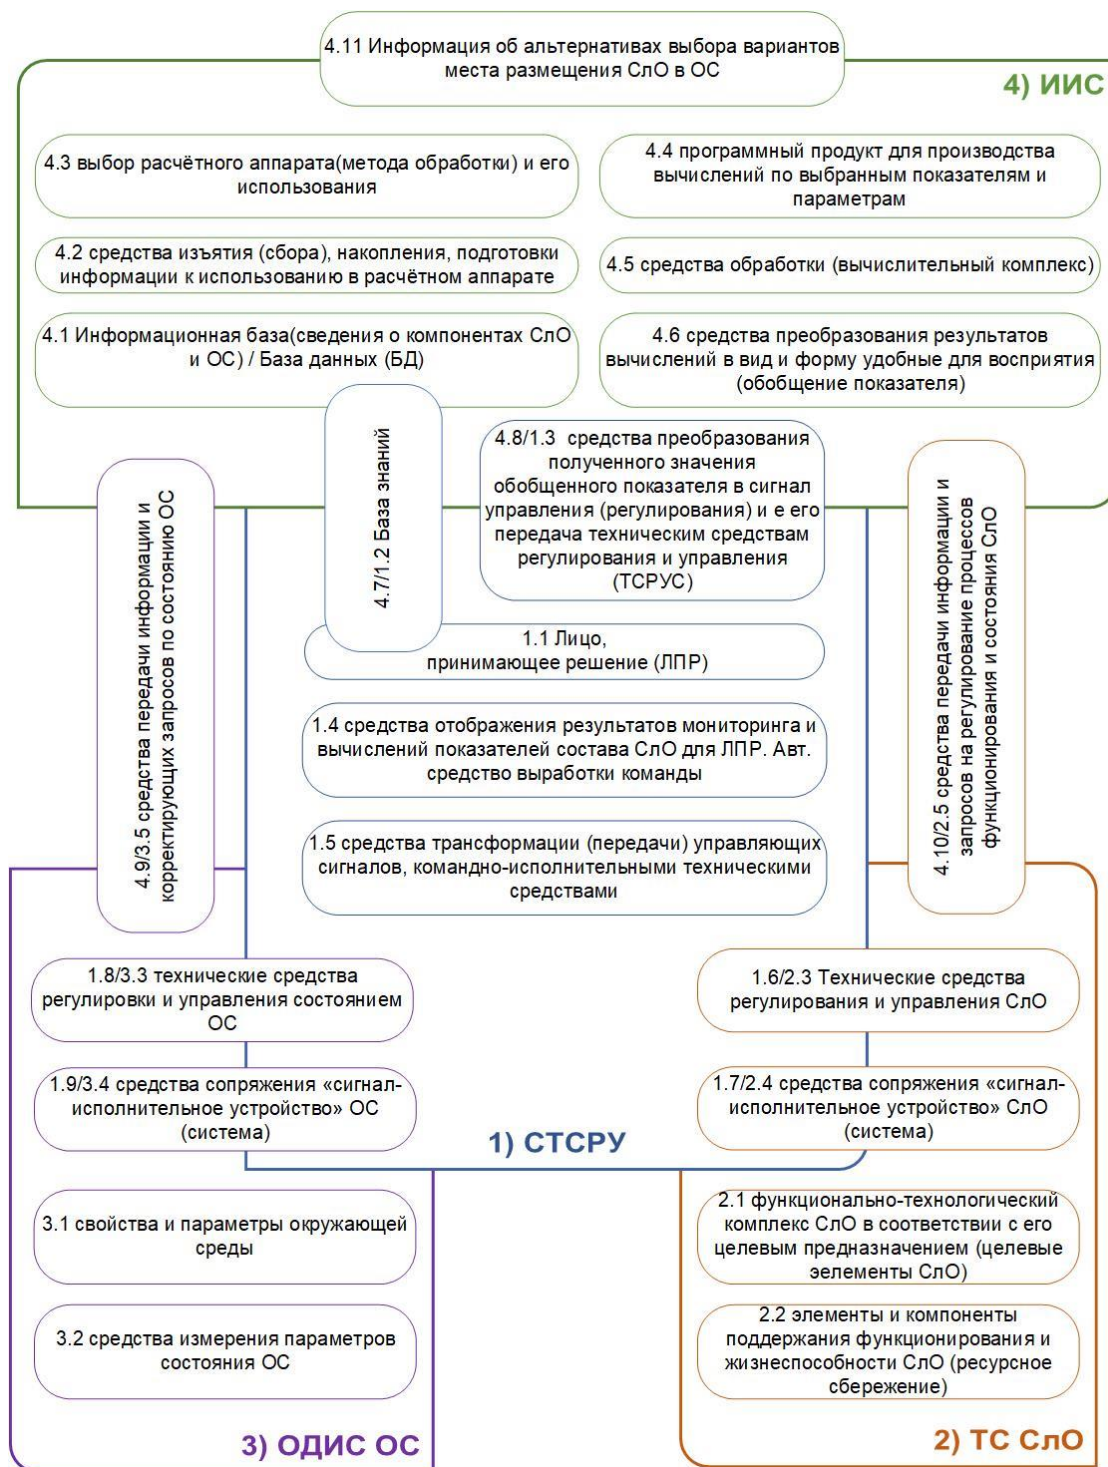


Рис. 2. Структурная схема формирования модельно-алгоритмического комплекса с адаптированной в него ИИС

2) ТС СЛО – техническая среда СЛО, включает: основное функциональное оборудование объекта; элементы обеспечения и поддержания жизнеспособного состояния объекта; средства сопряжения сигналов и команд с комплексом устройств поддержания состояния элементов СЛО; комплекс устройств поддержания состояния элементов СЛО; инфраструктуру обеспечения и поддержания функционирования основного оборудования СЛО; средства мониторинга параметров состояния СЛО; технические каналы передачи результатов измерения в СППР как составной части ИИС;

3) ОДИС ОС – область деструктивного изменения ОС, в состав которой входят: комплекс контрольно-измерительных средств сбора информации о состоянии ОС; технические каналы передачи результатов измерения в СППР; средства сопряжения сигналов команд с комплексом технических устройств регулирования параметров состояния и свойств ОС; технические устройства регулирования параметров состояния и свойств ОС; область ОС, как объект регулирования, подверженная деструктивным процессам от воздействия СЛО на ОС и их трансграничному распространению;

4) ИИС – интегрированная информационная система как информационная база о компонентах СЛО и ОС, включает: базы данных (БД) и базы знаний (БЗ); средства сбора, накопления и подготовки информации о СЛО и ОС к использованию в расчетном аппарате; расчетные методы и модели; программный продукт; вычислительный комплекс; средства преобразования результатов вычисления и представления их конечным пользователям различных управленческих уровней.

Из анализа МАК следует, что некоторые элементы одновременно принадлежат двум компонентам структуры, что подтверждает сложность взаимодействий в системе. Для полноты представления функционирования МАК его структуру необходимо наполнить достаточным объемом связей (на рис. 2 не отображены) как по количеству, так и по качеству [4–6].

Связи должны отражать: смысловое и функциональное содержание, взаимную иерархию и последовательность своего действия в МАК. Множество связей, определяющих динамику процессов в ЗВВ СЛК и подлежащих проактивному управлению для обеспечения устойчивого и сбалансированного состояния СЛК (как системы СЛО – ЗВВ – ОС) в пределах его жизненного цикла, сводится к решению задачи выбора структуры ИИС. В общем виде построение такой структуры сводится [2; 3] к постановке и решению обобщенной оптимизационной задачи поиска экстремума заданной обобщенной целевой функции  $\bar{S}$ :

$$\bar{S} \{ [\bar{f} \subset \bar{F}(\bar{\pi})] \bar{R} [\bar{m} \subset \bar{M}] \} \rightarrow \text{extr}, \quad (1)$$

$$\bar{\pi} \subset \bar{P}, \quad (2)$$

$$\bar{f} \subset \bar{F}(\bar{\pi}), \quad (3)$$

$$\bar{m} \subset \bar{M}, \quad (4)$$

где  $\bar{P}$  – множество возможных алгоритмов управления  $\bar{\pi} \subset \bar{P}$ ;  $\bar{F}$  – множество выполняемых функций в ЗВВ;  $\bar{M}$  – множество элементов комплекса ИИС  $\leftrightarrow$  ЗВВ;  $\bar{R}$  – операция отображения элементов множества  $\bar{F}$  на элементы множества  $\bar{M}$ .

Отображение  $\bar{F}$  должно обеспечивать экстремум заданной целевой функции  $\bar{S}$  при соблюдении множества заданных ограничений.

Перечисленные составляющие МАК и входящая в него ИИС посредством соответствующих связей позволит обеспечить гибкость и динамичность выработки обоснованных решений по поддержанию жизнеспособности СЛО и устойчивости состояния ОС за счет содержательных знаний о процессах, происходящих в ЗВВ.

### Заключение

Предлагаемый вариант совершенствования методологии постановки и решения задачи управления взаимовлиянием в комплексной системе «сложный объект – зона взаимодействия и взаимовлияния – окружающая среда» рассмотрен как обобщенный подход к явлению в целом и может быть применим к его использованию для множества конкретных исследований в различных предметных областях.

### Библиографический список

1. Акимов В. А., Лесных В. В., Радаев И. Н. Риски в природе, техносфере, обществе и экономике: монография. М.: Деловой экспресс, 2004. 352 с.
2. Соколов Б. В., Юсупов Р. М. Полимодельное описание и анализ структурной динамики систем управления космическими средствами // Труды СПИИРАН. 2010. Вып. 4(15). С. 7–52.
3. Кимяев И. Т., Соколов Б. В. Методология обеспечения жизнеспособности сложного объекта на основе управления его структурной динамикой // Мехатроника, автоматизация, управление. 2024. № 25(4). С. 167–176.
4. Моделирование слабо формализованных систем на основе явных и неявных экспертных знаний / М. Б. Игнатъев, В. Е. Марлей, В. В. Михайлов, А. В. Спесивцев. СПб.: Политех-пресс, 2018. 501 с.
5. Тиличко Ю. Н., Спесивцев А. В. Оценивание качества участков местности для строительства по критерию экологической безопасности // Геология и геоэкология, эволюционная география: сб. докл. XVIII Междунар. семинара, СПб., 20–21 дек. 2019 г., СПб.: РГПУ им. А. И. Герцена, 2019. С. 107–110.
6. Спесивцев А. В., Тиличко Ю. Н., Вагин А. В. Оценка воздействия природных и антропогенных рисков на криолитозону для строительства зданий и сооружений в арктическом регионе // Проблемы управления рисками в техносфере. 2017. № 2(42). С. 14–21.

С. Г. Толмачев

кандидат технических наук, доцент

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## АДАПТИВНЫЙ ВЫБОР ПРИЗНАКОВ ДЛЯ РАСПОЗНАВАНИЯ ОБЪЕКТОВ В МНОГОКАНАЛЬНЫХ ИНФОРМАЦИОННЫХ СИСТЕМАХ

Рассматривается задача выбора признаков целевых объектов и семантического сжатия в многоканальных информационных системах освещения обстановки. Предлагается оперативно формировать перечень анализируемых отличительных признаков на основании анализа текущей информации.

**Ключевые слова:** автономный аппарат, семантическое сжатие, объект наблюдения, информативные признаки.

S. G. Tolmachev

PhD, Tech., Associate Professor

St. Petersburg State University of Aerospace Instrumentation

## ADAPTIVE FEATURE SELECTION FOR OBJECT RECOGNITION IN MULTICHANNEL INFORMATION SYSTEMS

The problem of selecting the features of target objects and semantic compression in multichannel information systems for lighting the situation is considered. It is proposed to quickly form a list of analyzed distinctive features based on the analysis of current information.

**Keywords:** autonomous apparatus, semantic compression, object of observation, informative signs.

Задачи поиска, обнаружения, распознавания различного вида объектов и принятия решений – традиционные задачи для автономных систем гражданского и военного назначения на базе беспилотных, безэкипажных и необитаемых аппаратов. Основным фактором, влияющим на выбор способов обработки информации в этих системах, является необходимость обработки больших объемов разнородных данных в условиях жестких временных ограничений на принятие решений.

Современная тенденция в области разработки автономных систем предусматривает наделение их возможностью самостоятельно составлять и выбирать альтернативные варианты действий для достижения поставленных целей на основе заложенных знаний, понимания среды функционирования и динамики развития ситуации. Чтобы успешно выполнять свои задачи, они должны воспринимать обстановку, обнаруживать целевые объекты, идентифицировать их, планировать свои действия, принимать решения и реагировать на разнообразные угрозы в сложных и неопределенных условиях. Все эти задачи предполагают обработку больших массивов данных о фоновой обстановке, в которых необходимо выделить наиболее важную часть.

При разработке новых модификаций специализированных автономных аппаратов стремятся увеличить точность определения координат целевых объектов и достоверность их распознавания за счет использования многоканальных систем обнаружения (радиолокационных, оптических и т. п.) и аппаратуры связи с другими источниками информации, в качестве которых могут выступать другие автономные аппараты при их групповой работе. В этих условиях интеллектуальная обработка данных реализуется в форме их семантического сжатия [1]. Смысл семантического сжатия заключается в концентрации внимания на приоритетной информации, выделяемой из первичных данных от датчиков и передачи этой информации для ее дальнейшей обработки и принятия решений. Введем следующие обозначения: многоканальное устройство аппаратуры обнаружения автономного аппарата содержит  $K$  информационных каналов, где  $k [1:K]$  – номер канала. На рис. 1 приведена схема поэтапной обработки данных каждого  $k$ -го канала, состоящая из ряда блоков.

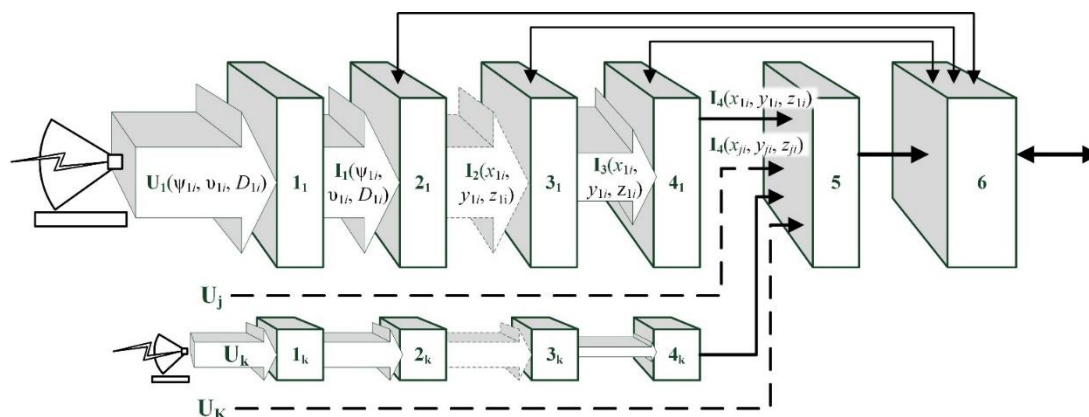


Рис. 1. Схема обработки данных в информационных каналах

**Блоки 1<sub>к</sub>** – преобразователи текущего значения физической величины в электрический сигнал  $U_{ki}(t)$  каждого  $k$ -го канала. Это приемные устройства электромагнитного излучения с каждого  $ki$ -го элемента разрешения наблюдаемой зоны в координатах антенной системы  $k$ -го канала, например в полярных координатах, где  $\psi_{ki}$ ,  $\nu_{ki}$ ,  $D_{ki}$  – углы и дистанция. Обнаружением является принятие решения о наличии или отсутствии сигнала  $U_{ki}(t)$  для его дальнейшего анализа в каждом разрешаемом объеме  $i$  зоны поиска. Информацией  $I_{1k}$  блока  $1_k$  является факт обнаружения или необнаружения отраженного сигнала в каждом элементе пространственного разрешения  $ki(\psi_{ki}, \nu_{ki}, D_{ki})$ .

**Блоки 2<sub>к</sub>** – накопители-сумматоры сигналов  $U_{kXYZi}$  в стартовой системе координат XYZ. Накопление информации необходимо проводить для каждого элемента разрешения в координатах XYZ, так как происходит изменение взаимного положения автономного аппарата и целевого объекта наблюдения (ОН). Скорость изменения дистанции между ОН и автономным аппаратом необходимо учитывать при расчете максимального числа накопленных импульсов. Информацией  $I_{2k}$  являются параметры сигналов, характерных для  $k$ -го канала (например, дистанция, амплитуда, отношение сигнал/шум и их изменение во времени) для каждого обнаруженного ОН в зоне наблюдения.

**Блоки 3<sub>к</sub>** определяют признаки сигналов для каждого элемента разрешения в системе координат XYZ. Информация  $I_{3k}$  – результат объединения численных значений признаков, полученных путем усреднения их значений по всем рядом расположенным элементам пространственного разрешения, в которых наблюдаются отраженные сигналы, превысившие порог обнаружения. Совокупность рядом расположенных элементов пространства, в которых обнаружен отраженный сигнал, или одиночный элемент, принято называть обнаруженными объектами, обладающими рядом классификационных признаков и имеющими количественную оценку. Координаты обнаруженных объектов определяются по энергетическому или геометрическому центру отражений. Таким образом, выходная информация блока  $3_k$  представляет  $N3$  одномерных массива  $U3n$ , соответствующая  $N3$  обнаруженным объектам и  $N$  измеренным параметрам отраженного сигнала от объекта:  $U3n [x_n, y_n, z_n, n(1: N)]$ , где  $x_n, y_n, z_n$  – координаты центра обнаруженного объекта,  $n(1: N)$  – численные значения измеренных параметров сигнала от объекта.

**Блоки 4<sub>к</sub>** выполняют процедуру классификации обнаруженных объектов по значениям измеренных параметров. Процедура может выполняться в каждом  $k$ -м канале предварительно обученным классификатором, построенном, например, на основе искусственной нейронной сети. Каждому обнаруженному объекту определяется важность передачи факта его обнаружения и координат его местонахождения. В зависимости от предварительного целеназначения автономного аппарата, при составлении для него полетного задания устанавливается список приоритетов признаков в блоках 3 и 4.

В **блок 5** из блока  $4_k$  передается сокращенный массив из  $N3$  векторов, формируемый путем удаления информации о признаках классификации, заменив их условным номером типа обнаруженного объекта  $N_{nk}$ , согласно используемому каталогу объектов:  $I_{4k} [N_{nk}, x_n, y_n, z_n, k, q_{nk}]$ , где  $q_{nk}$  – мера доверия к результатам классификации. В блоке 5 формируется окончательное решение о принадлежности каждого обнаруженного объекта к определенному классу каждым  $k$ -м каналом. Это решение выносится на основании частных мер доверия  $q_{nk}$  к результатам классификации. Решение может быть получено с помощью правила Демпстера или методами нечеткой логики.

**Блок 6** формирует пакет информации для передачи из главного уровня и более низких уровней, выбирая данные из блоков 4, 3, 2 и загружая ими пропускную способность канала связи, для передачи информации на головной аппарат в группе. Таким образом, блоки 5 и 6 реализуют семантический отбор информации для ее дальнейшей передачи (рис. 2).




Рис. 2. Схема формирования сообщений

В рассматриваемых многоканальных системах классификация обнаруженных объектов по их заданным отличительным признакам реализуется в блоках 4к. Реальные условия наблюдения целевых ОН зависят от состояния фоноцелевой обстановки, наличия естественных и искусственных помех, дистанции до ОН, отведенного времени на принятие решения и т. п. Поэтому не все отличительные признаки ОН могут быть доступны для анализа, некоторые из них выявляются расчетным путем. Представляется целесообразным применить алгоритм классификации ОН, в котором осуществляется выбор анализируемых отличительных признаков, доступных в текущих условиях наблюдения. Эталонный вектор признаков каждого класса формируется на основании априорных знаний статистических характеристик распределения значений каждого признака [2]. Для каждого класса известны векторы средних значений признаков  $\mathbf{m}$  и их дисперсий  $\mathbf{D}$ , косинусное расстояние между вектором признаков ОН  $\mathbf{V}_x$  и эталонным вектором признаков класса  $\mathbf{V}_y$  вычисляется в  $m$ -мерном пространстве признаков:

$$d_{xy} = 1 - \left( \frac{\mathbf{v}_x \times \mathbf{v}_y^T}{(\mathbf{v}_x \times \mathbf{v}_x^T)^{1/2} (\mathbf{v}_y \times \mathbf{v}_y^T)^{1/2}} \right).$$

В каждой конкретной ситуации размерность  $m$  вектора признаков ОН и эталонов классов определяется текущими условиями наблюдения.

### Заключение

Рассматриваемый вариант семантического сжатия информации, передаваемой по каналам связи в информационно-управляющих системах автономных аппаратов, можно трактовать как фильтрацию или отбор информации по приоритетам ее ценности и достоверности, которые априори устанавливаются при составлении полетного задания. На основании анализа получаемой информации может оперативно изменяться перечень анализируемых отличительных признаков целевых ОН. При групповой работе автономных аппаратов это позволяет наблюдать обнаруженный объект с разных ракурсов, что существенно повышает качество распознавания, а семантическое сжатие позволяет снизить объем передаваемой информации путем отбора ее наиболее полезной части.

### Библиографический список

1. Шаров С. Н., Толмачев С. Г. Семантическое сжатие информации мониторинга группой беспилотных летательных аппаратов // Искусственный интеллект и принятие решений. 2015. № 3. С. 95–105.
2. Лепский А. Е., Броневиц А. Г. Математические методы распознавания образов. Таганрог: Изд-во ТТИ ЮФУ, 2009. 154 с.

*А. А. Тюгашев*

доктор технических наук

Самарский государственный технический университет

## ПРОБЛЕМЫ ИНТЕЛЛЕКТУАЛЬНОГО УПРАВЛЕНИЯ СЛОЖНЫМИ ТЕХНИЧЕСКИМИ СИСТЕМАМИ

Рассматриваются проблемы интеллектуального управления сложными техническими системами, алгоритмы и программные средства, позволяющие проверять соответствие логики управления требованиям.

**Ключевые слова:** интеллектуальные системы, обработка данных, искусственный интеллект, автоматизация процессов, алгоритмы машинного обучения.

*A. A. Tyugashev*

Dr. Sc., Tech.

Samara State Technical University

## PROBLEMS OF COMPLEX TECHNICAL SYSTEMS INTELLIGENT MANAGEMENT

The article discusses problems of intelligent control of complex technical systems, algorithms and software tools that allow to check the conformity of logic of management requirements.

**Keywords:** intelligent systems, data processing, artificial intalect, automation of processes, machine learning algorithms.

В XXI в. широко распространены сложные технические системы, можно упомянуть автоматизированные производства, атомные электростанции, космические аппараты и т. п. [1; 2]. Подобные системы обычно имеют многоуровневую иерархическую структуру с множеством подсистем, включающих, в свою очередь, различные устройства, датчики и исполнительные механизмы. При этом данные системы должны поддерживать адаптивное устойчивое поведение в динамичных средах, функционируя в режиме реального времени. Обеспечение управления в данных условиях, особенно при необходимости соблюдения ограничений по доступным ресурсам, представляет собой серьезную проблему. Актуальная и важная проблема заключается в том, как мы можем обеспечить «согласованное» или «устойчивое» управление и что в данном случае означает понятие «интеллектуальное управление».

Анализируемые системы имеют то или иное предназначение или главную цель. Например, транспортировка пассажиров и грузов, производство продукции, выработка энергии и пр. Успех в достижении поставленной цели зависит от своевременного выполнения нужных операций с задействованием того или иного оборудования. Предполагается выполнение логически скоординированных и зависящих от времени действий, что можно назвать «планом», «расписанием», в аэрокосмической промышленности используется понятие «циклограмма» [1]. Устойчивое управление подразумевает необходимые реакции на непредсказуемые события, обеспечивая выполнение системой своих задач как в нормальных, так и в нештатных ситуациях. Сложность управления требует разнообразных реакций на воздействия окружающей среды, что согласуется с кибернетическим законом необходимого разнообразия Эшби [3; 4].

Аппаратное обеспечение сложных систем включает множество устройств, что весьма увеличивает риск сбоев и отказов оборудования. Необходимо парирование этих рисков. Для этого используют избыточность за счет дублирования и функционального резервирования. Функциональная избыточность позволяет системе полагаться на альтернативные устройства или подсистемы с аналогичными возможностями для решения конкретных задач в нештатных ситуациях [5–10].

Для достижения целей системы необходимы различные виды функциональности, предоставляемые тем или иным устройством или прибором, и эти возможности должны поддерживаться на требуемом уровне в течение заданного времени. Функциональность всей системы в любой момент времени представляет собой совокупность возможностей, предоставляемых ее отдельными компонентами, на которые влияют их текущие режимы работы [8].

Отдельной проблемой является управление ресурсами, необходимыми для выполнения поставленных задач на каждом из участков функционирования системы. Системам требуются различные возобновляемые и исчерпаемые ресурсы. Система управления должна обеспечивать, чтобы потребление ресурсов оставалось в заданных пределах, учитывая взаимное влияние системы и окружающей среды.

При этом современные системы управления используют вычислительные возможности цифровых компьютеров или даже сетей для выполнения широкого спектра управляющих воздействий [5; 11]. Непосредственная реализация логики управления при этом возлагается на управляющее программное обеспечение (ПО). Оно играет критически важную роль, выдавая команды бортовым устройствам, переключая их режимы, в случае необходимости активируя резервные устройства [5].



Данную разновидность ПО часто называют критически важным программным обеспечением [3; 10]. Это программное обеспечение управляет бортовыми устройствами с помощью последовательностей выдаваемых аппаратных команд, обеспечивая необходимую гибкость при перенастройке оборудования для поддержания необходимых уровней функциональности на протяжении всей миссии [2; 3]. Различные режимы работы устройства требуют разного уровня ресурсов, (например, электроэнергии), которые могут быть как исчерпаемыми, так и возобновляемыми [1; 11]. Система должна так управлять потреблением ресурсов, чтобы избежать превышения критических пороговых значений [7].

Взаимодействие между системой и ее окружающей средой является двунаправленным, при этом внешние факторы влияют на производительность системы, а деятельность системы изменяет ее окружение, например за счет выбросов и отходов. Следовательно, система управления должна обеспечивать как внутреннюю, так и внешнюю безопасность, поддерживая работоспособность устройства и ограничивая воздействие системы на окружающую среду в заранее установленных пределах [3; 10].

Важнейшим аспектом управления в сложных системах является наличие внутреннего представления «о мире» и «о себе». Этот внутренний «образ» должен охватывать состояние внешней среды, статус и функциональность системы, а также прогресс в достижении целей, определяя, какие были достигнуты, а какие еще должны быть достигнуты [7; 10].

Итак, мы можем выделить следующие существенные особенности рассматриваемых систем:

- непредсказуемость внешней среды, которая должна адекватно отражаться системой управления;
- различные устройства (блоки, датчики, агрегаты и т. д.) с иерархической структурой;
- необходимость достижения поставленных целей путем выполнения заданного графика (плана) в режиме реального времени;
- система управления на базе компьютеров / компьютерной сети;
- использование критически важного программного обеспечения, управляющего конфигурацией и режимами работы оборудования;
- возможные отказы бортовых устройств и ухудшение функциональности, подлежащие компенсации;
- ограниченный объем доступных ресурсов, необходимых для выполнения задач системы, которые меняются со временем;
- взаимное влияние системы и внешней среды, а также наличие аспектов безопасности, связанных с выбросами.

Что же мы должны подразумевать под термином «интеллектуальное управление»? Во-первых, термин «интеллектуальный» может быть истолкован по-разному, можно вести анализ от исторического регулятора паровой машины Ватта до более современных подходов, основанных на программном обеспечении. Очевидно, что любая система управления, способная адекватно реагировать на изменения в окружающей среде, может считаться обладающей определенной степенью гибкости или «интеллектуальности». «Устойчивость», с другой стороны, означает некоторый холизм, целостность, живучесть, способность противостоять неблагоприятным внешним воздействиям.

С нашей точки зрения, устойчивое управление – это управление, обеспечивающее гарантированное выполнение миссии системы, достижение ее цели.

В простых случаях для этого может потребоваться просто последовательность шагов, но в реальном мире мы имеем дело с системами реального времени, поэтому, например, если нам нужно отправить космический корабль на Марс, мы должны сначала осуществить выведение с Земли, затем совершить межпланетное путешествие на Марс, а когда это произойдет, необходимо снизить скорость, например используя атмосферу, и в конце концов использовать реактивные двигатели для окончательной посадки. При этом операции должны выполняться с учетом движения планет и других факторов космического пространства. Мы должны запланировать и выполнить не просто последовательность шагов, а некий план с привязкой действий ко времени. Важно при этом, чтобы планирование задач было гибким и адаптируемым, чтобы заранее учесть факторы окружающей среды и возможные отказы оборудования, которые могут возникнуть во время миссии. Кроме того, в процессе планирования необходимо учитывать изменения уровня ресурсов, таких как энергия и топливо.

На этапе проектирования следует провести анализ потенциальных сбоев при эксплуатации, чтобы обеспечить возможность принятия надлежащих мер по парированию аномальных ситуаций. В частности, это приводит к разработке не одной циклограммы, или плана полета, а фактически набора циклограмм, или «гипер-плана». Фрагмент такого «гипер-плана» или расписания мы можем видеть на рис. 1, где разными цветами обозначены задачи, выполненные в различных ситуациях.

Как уже отмечалось, сложная логика управления с задействованием устройства из различных подсистем, реализованных в специализированном программном обеспечении («интегральное управление»), известна как управляющие алгоритмы реального времени [1; 2]. Как правило, алгоритм управления конкретным прибором содержится в определенном программном модуле, выполняющемся как процесс в многопрограммной операционной системе реального времени.




Рис. 1. Фрагмент плана функционирования системы

Различные сценарии выполнения (задействование разных ветвей управляющего алгоритма) приводят к реализации различных временных последовательностей операций. В какой-то момент потребление конкретного ресурса, например электроэнергии, может превысить «красную черту», соответствующую доступному уровню (рис. 2).




Рис. 2. График потребления ресурса

Нужно сформировать конкретное расписание/план для каждого возможного сценария. Дополнительная сложность логики управления при ограниченных ресурсах вызвана тем, что параллельно выполняется несколько управляющих модулей программного обеспечения, каждый из которых реализует различные последовательности действий, часть из которых активирует другие алгоритмы [5; 10].

Исходя из сказанного, сложная система может быть представлена следующими наборами: устройств, функциональных возможностей, ресурсов, выбросов, лимитами ресурсов и выбросов, режимов работы устройств, векторами потребления/производства ресурсов и выбросов в режимах [5].

Отправной точкой при проектировании логики управления является формирование набора задач, которые должны выполняться оборудованием системы, с заданием моментов времени [6]. Затем необходимо: определить взаимосвязи между задачами, требуемыми функциональными возможностями и задействованными устройствами, между устройствами и модулями управляющих программ; задать временные параметры. Все это позволяет построить план системы и рассчитать потребление ресурсов и уровни выбросов [7].

При построении или синтезе управления сложной системой мы будем осуществлять (это *прямая* задача):

- 1) построение расписания, удовлетворяющего приведенным условиям;
- 2) на основе расписания осуществление синтеза логико-временной схемы (аналога управляющего графа, но с учетом временных установок) управляющего алгоритма реального времени;
- 3) на основе логико-временной схемы – синтез собственно управляющей программы в том или ином представлении (внутренние структуры данных для макропрограмм интегрального управления, исходный текст на параметрически задаваемом языке программирования и пр.)

На каждом шаге здесь возможна оптимизация в том или ином понимании.

Это *прямая* задача. Но есть и задача *обратного проектирования*, или задача *верификации*:

- а) проверить, действительно ли существующее управляющее программное обеспечение реализует нужную логико-временную схему;
- б) проверить, действительно ли логико-временная схема (управляющий граф) алгоритма реализует нужное расписание;
- в) проверить, действительно ли расписание удовлетворяет условиям согласованности по позициям сохранения функциональности, отсутствия превышения лимитов на потребление ресурсов, отсутствия превышения лимитов неблагоприятного воздействия на окружающую среду.

Для выполнения приведенных операций верификации мы можем задействовать специальные алгоритмы. Также специфичные требования к функционированию сложной системы в реальном времени можно записывать на языке логики УА РВ (операторы неналожения во времени, временного предшествования, логического неналожения, совпадения процессов по началу, концу, непосредственного следования и пр.) и затем проверять каждый из проектных артефактов, удовлетворяет ли он этим требованиям при заданных параметрах функциональных задач (длительности).

Затем специальные автоматизированные средства позволяют с применением необходимых алгоритмов выполнять верификацию, иными словами, проверять, исполняются ли сформулированные требования при той или иной конкретной реализации управления аппаратными и программными средствами.

Какие методы мы можем использовать для моделирования и решения поставленных задач? В проблемной области описания функционирования систем реального времени существует несколько известных и апробированных подходов. Некоторые из них используют различные виды логики [9; 12–17], некоторые основаны на алгебрах процессов [18–20]. Мы пытаемся добиться синергии логического и алгебраического подходов.

Одна из основных предлагаемых нами идей для обеспечения устойчивого интеллектуального управления сложными системами реального времени – использование описательных возможностей логики алгоритмов управления реального времени RTCAL [8; 9] и конструктивных возможностей связанной с ней в качестве семантической модели алгебры управляющих алгоритмов. RTCAL использует более высокий уровень абстракции по сравнению с другими моделями, не обращаясь к понятию состояния системы, и поддерживается оригинальным программным обеспечением для моделирования и верификации.

В реальном мире некоторые процессы в плане работы или расписании могут быть не связаны жестко, т. е. нет строгих ограничений на указанное время начала процесса или его продолжительность. В этом случае мы можем указать только отношение приоритета между процессами. В других случаях, напротив, мы должны установить строгую связь (например, «совпадение по началу», «совпадение по концу» или «непосредственное следование») между двумя или более процессами, которые должны быть реализованы средствами управления. Более того, иногда нам необходимо привязать действие к указанному астрономическому времени (абсолютное время). А некоторые задержки и временные сдвиги должны быть указаны количественно. RTCAL предоставляет все необходимые операторы для описания синхронизации параллельных процессов, как количественной, так и качественной [10]. Например,  $f_1 \rightarrow f_2$  означает, что выполнение функциональной задачи  $f_2$  должно начаться сразу после завершения  $f_1$ ;  $f_1 \text{ CH } f_2$  означает, что задачи  $f_1$  и  $f_2$  стартуют одновременно. В таблице приведено краткое описание операторов, предоставляемых RTCAL.

#### Операторы RTCAL

Обозначение	Семантика	Пример записи
<i>CH</i>	Совпадение по началу	$UA_1 \text{ CH } UA_2$
<i>CK</i>	Совпадение по концу	$UA_1 \text{ CK } UA_2$
$\rightarrow$	Непосредственное следование	$UA_1 \rightarrow UA_2$
<i>H</i>	Наложение с параметром	$H(UA_1, UA_2, \text{int})$
<i>ЗА</i>	Параметрическое следование	$ЗА(UA_1, UA_2, \text{int})$
@	Привязка к абсолютному времени	@(UA, int)
?	Обусловливание действия условием	(condition)? UA

Управляющая программа может иметь разные операторы, но с точки зрения логики управления наше внимание сосредоточено:

- 1) на операторе вызова, который запускает другой программный модуль;
- 2) выдаче команд управления оборудованию;
- 3) установке или сбросе логических переменных (флагов).

Флаги влияют на выполнение системного плана, например «уровень заряда батареи 1 критически низкий» или «вторая солнечная панель полностью готова к работе». Полный набор логических значений формирует «вектор текущего состояния» системы [3], или «логический вектор». Подмножества этого вектора, например описывающие состояние отдельной подсистемы, называются «частными векторами состояния» [12]. Значения логических переменных определяют возможный сценарий выполнения алгоритма управления, по сути, направляя ход управления. Различные сценарии выполнения приводят к выполнению различных временных последовательностей операций. Как уже говорилось, мы можем сформировать отдельный план или расписание для каждого возможного сценария либо использовать цвета или иные обозначения, чтобы показать, что процессы относятся к разным сценариям на одной и той же циклограмме.

На практике один алгоритм управления может активировать множество других алгоритмов, каждый из которых имеет собственную циклограмму действий. Для проектировщика является сложной задачей рассмотреть все ветви «дерева выполнения» с всесторонней проверкой отсутствия нарушения ограничений на ресурсы.

Итак, сложная система может быть представлена с помощью следующих базовых множеств:

$A = \{BA_i\}, i=1 \dots N$  – множество приборов (устройств);

$FA = \{FA_j\}, j=1 \dots P$  – множество видов функциональности поддерживаемой оборудованим;

$AP = \{AP_j\}, j=1 \dots M$  – множество используемых ресурсов;

$EP = \{EP_j\}, j=1 \dots R$  – множество выбросов – воздействий системы на среду;

$Lim(AP_j) = \{LimAP_1, LimAP_2, \dots, LimAP_M\}$  – набор ограничений на ресурсы;

$Lim(EP_j) = \{LimEP_1, LimEP_2, \dots, LimEP_M\}$  – набор ограничений на допустимые выбросы;

$REA(BA_i) = \{ (RM_{i1}, RM_{i2} \dots RM_{iN}) \}$  – множество режимов работы устройств;

$CL(RM_{ik}) = \{ (CP_{i1}, CP_{i2} \dots CP_{iN}) \}$  – набор векторов потребления ресурсов в каждом из режимов работы устройства;

$CE(RM_{ik}) = \{ (EP_{i1}, EP_{i2} \dots EP_{iN}) \}$  – набор векторов выбросов в каждом из режимов работы.

Первым этапом при проектировании логики управления служит формирование набора задач, которые должны выполняться оборудованием системы. И, как было упомянуто, важным моментом становится то, что мы должны выполнить действие в определенный момент. Мы используем следующий набор:

$Z = \{ (PT_j, t_j) \}$  – набор задач, которые нужно выполнить системе (см. рис. 1).

Набор управляющих алгоритмов реального времени, реализованных программным обеспечением, в свою очередь, может быть представлен с помощью следующих множеств:

$UA = \{ CA_m \}, m=1 \dots U$ .

Затем необходимо выполнить следующее.

1. Реализовать отображение  $f_1: Z \rightarrow FA \rightarrow EA$ , т. е. на базе того, какие виды функциональности будут необходимы в какой момент, задать время активации устройств, вовлекаемых в процессы решения поставленных задач, с учетом необходимого режима работы.

2. Реализовать отображение  $f_2: EA \rightarrow UA$ , т. е. какие именно программные модули необходимо запустить в нужное время.

3. Задать временные параметры  $f_3: EA \rightarrow T$  and  $UA \rightarrow T$ .

Используя приведенные отображения, мы можем построить план (расписание, циклограмму) функционирования различных устройств и рассчитать общий уровень потребления определенных ресурсов и уровни выбросов в зависимости от времени. Наконец, заключительное отображение позволяет нам сформировать набор кортежей следующего вида:  $\{ \langle BA_i, CA_{ij}, t_i, l_i \rangle \}$ .

Каждая четверка здесь определяет сценарий выполнения управляющего алгоритма  $CA_i$ , запускаемого в момент времени  $t_i$  в ситуации, описываемой логическим вектором  $l_i$ .

Логический вектор может выглядеть, например, следующим образом:  $l = (\alpha_1 = TRUE, \alpha_2 = FALSE, \dots, \alpha_q = H)$ , где  $\alpha_i$  соответствует определенному «флагу». Иногда значимость конкретного логического условия может ограничиваться контекстом данного сценария выполнения. В данной ситуации мы используем дополнительное значение истинности 'H', означающее независимость исполнения действий от значения данного логического условия. Иначе говоря, мы имеем дело с разновидностью трехзначной логики в определенном смысле.

Набор приведенных кортежей определяет последовательность «участков» функционирования сложной системы и сценарий, который должен быть выполнен управляющей логикой. И наоборот, эта последовательность может быть использована для определения того, есть ли какие-либо совпадения между режимами и функциями рассматриваемых устройств, а также конкретными выполняемыми программными модулями, что важно для задачи верификации уже существующего управляющего программного комплекса.

Затем мы рассматриваем сопряженное выполнение программных модулей и работу бортового оборудования. По сути, будут построены план функционирования бортового оборудования и соответствующие графики потребления бортовых ресурсов, внешних выбросов и функциональных возможностей, предоставляемых оборудованием.

Чтобы построить формальные математические модели для входных и выходных данных вышеупомянутых этапов проектирования системы управления, необходимо рассмотреть модели, которые способны обеспечить адекватное описание объектов, относящихся к различным бортовым системам, устройствам и исполнительным механизмам с их соответствующими режимами работы, как обсуждалось ранее. Кроме того, модель должна описывать набор алгоритмов управления, которые были разбиты на разделы, а также соответствующим образом отражать различные сценарии, относящиеся к миссии. На данном этапе модель алгоритма управления можно рассматривать как «базовую».

В [2] авторы формулируют уровни сложности кибернетических систем.

– Детерминированные системы  $S_1$  с жестким правилом преобразования  $X$  в  $Y$ .

– Стохастические системы  $S_2$  с заметным влиянием случайных факторов на результаты.

– Системы  $S_3$  без четко определенных правил преобразования входных данных в выходные.

– Системы  $S_4$ , реализующие планы и достигающие заранее установленных целей.

– Системы  $S_0$ , выбирающие собственные цели и изменяющие структуру и адаптивную реакцию на входные данные.

Используя данный подход, рассмотренные системы можно отнести к системе  $S_0$ . Причины следующие. Во-первых, у нас есть гибкая логика управления, учитывающая различные ситуации, реализуемые управляющим программным обеспечением. Во-вторых, мы можем констатировать наличие возможности самореструктуризации. Наконец, набор целей, которые необходимо достичь, может обновляться в процессе эксплуатации.

Каким образом мы можем задать логику управления в реальном времени, используемую рассматриваемыми системами? Когда мы говорим о логике, мы предполагаем использование аксиом и правил. Мы должны применять механизмы рассуждения, основанные на правилах логики. Что мы можем рассматривать как «логику управления» сложной технической системой?

Правила могут быть сформированы в виде «ЕСЛИ {предпосылки/предположения} ТО {выводы}». Для сложных технических систем, работающих в режиме реального времени, наилучшие результаты могут быть достигнуты с помощью временных версий этих правил, которые могут быть заданы следующим образом:

$$\alpha_1(t_{u1}) \wedge \neg \alpha_2(t_{u2}) \wedge \dots \wedge \alpha_M(t_{uM}) \rightarrow A_1(t_{a1}) \wedge A_2(t_{a1}) \wedge \dots \wedge A_N(t_{aN}).$$

В левой части формулы указаны логические переменные (со значениями ИСТИНА и ЛОЖЬ), а в правой части содержатся действия. Некоторые из этих действий устанавливают флаги, поэтому после применения некоторого правила истинность определенных условий может быть изменена.

Важным аспектом взаимодействия системы с внешней средой посредством физических процессов является изменение условий, отражающих текущую ситуацию. Мы имеем дело с сочетанием условий (некоторые с логическим отрицанием) в левой части правила. Можно указать несколько правил с одинаковой левой частью, поэтому эти правила можно использовать как связанные логическим ИЛИ (дизъюнкция). Следовательно, благодаря логической полноте дизъюнктивной нормальной формы (ДНФ) мы можем говорить об универсальности данного подхода для описания любой логики управления в реальном времени.

На следующем шаге нам нужно перейти от системного плана к набору правил управляющей логики. И затем мы можем реализовать (путем ручного программирования или автоматической генерации управляющей программы [6; 21]) данную логику в управляющем программном обеспечении. Есть и задача обратного проектирования – задача проверки соответствия логики, реализованной в управляющем программном обеспечении, целям и срокам их достижения. Она предполагает переход от существующих программных модулей обратно к правилам управляющей логики.

Мы можем применить здесь специальные процедуры для извлечения логических правил управления из программного кода путем анализа программных модулей, затем для восстановления упомянутых графиков, а затем для проверки своевременности достижения требуемых целей.

Всякий раз, когда мы строим расписание, исходя из целей системы или извлекая его из управляющих программ, его соответствие требованиям синхронизации можно проверить, используя физический смысл операторов логики RTCAL: << (временное предшествование), <> (запрет на наложение), СН (совпадение по началу), СК (совпадение по концу), → (непосредственное следование) [10; 22].

На самом деле блоки действий можно рассматривать как «кирпичики» алгебры управляющих алгоритмов, изучая систему с точки зрения принадлежности устройства к системе.

Как уже отмечалось, ограничения на минимально необходимый уровень каждого вида функциональности и максимально доступные уровни каждого вида ресурсов являются еще одним существенным ограничением для построения «устойчивой» логики управления, наряду с временными ограничениями.

Чтобы решить эту проблему, мы можем использовать компьютерное моделирование с помощью специально созданного программного средства для расчета потребления ресурсов и выбросов за все время функционирования системы. На рис. 3 приводится копия экрана при работе данного средства.

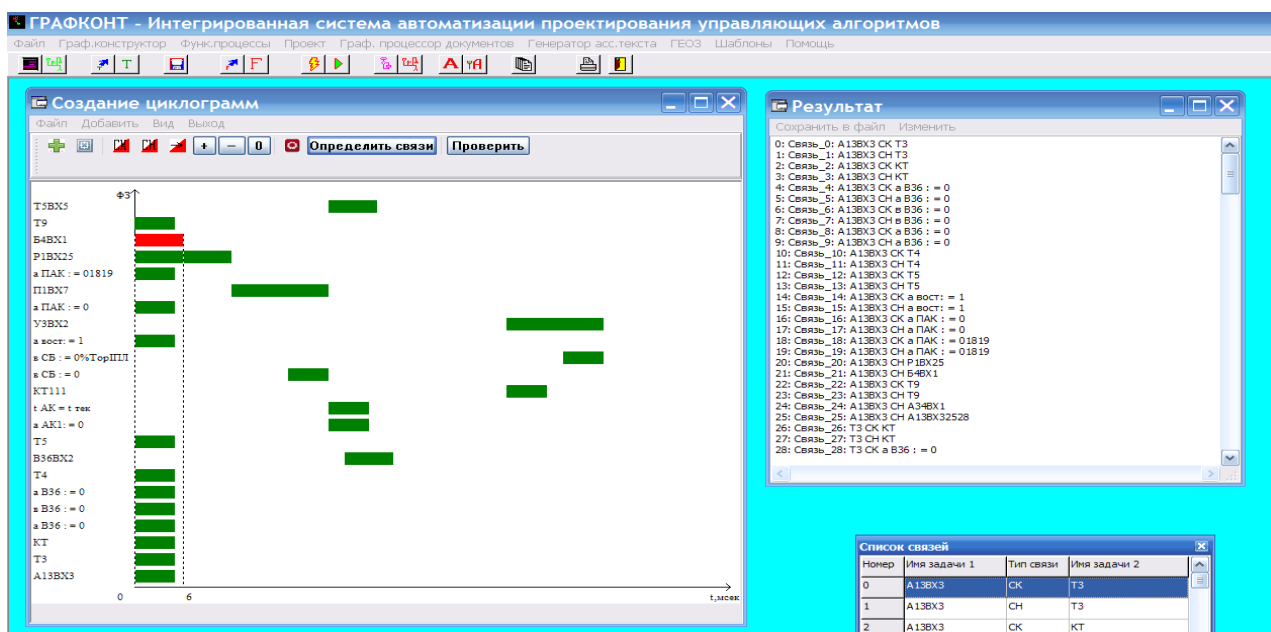


Рис. 3. Экран инструментального программного средства

Другой механизм моделирования может позволить проверить, будут ли уровни всех видов требуемой функциональности достаточными для достижения целей системы в случае возникновения нештатных ситуаций.

Проблема верификации логики управления [8; 23] заключается в проверке того, соответствует ли указанный набор правил графику, гарантирующему достижение целей с соблюдением их сроков; не нарушены доступные/допустимые уровни ресурсов и выбросов; и существующие ограничения не нарушены.

В случае возникновения нештатной ситуации, вызванной неисправностью конкретного устройства, подсистема управления должна проверить уровень падения соответствующей функциональности, а затем выдать специальную команду для активации резервного оборудования.

Эти правила – весьма существенная часть среди всех правил управляющей логики.

В связи с характером рассматриваемой задачи мы предполагаем, что для поиска решения могут быть применены некоторые перспективные современные технологии, например программирование в ограничениях (Constraint Programming), верификация выполнимости логических формул (SAT), динамическое программирование. Некоторые из этих методов поддерживаются специальным программным обеспечением – так называемые «решатели» часто используют достаточно оптимизированные и продвинутые алгоритмы и предоставляют эффективные методы с задействованием параллельных вычислений [12].

Данные программные средства могут применяться во многих проблемных областях. Некоторые решатели доступны через интерфейс прикладного программирования (API), некоторые имеют свои проблемно-ориентированные языки.

Некоторые инструменты бесплатны, существуют даже онлайн-версии. Но, используя возможности именovaných решателей, можно столкнуться с некоторыми проблемами. Язык моделирования должен быть нацелен на то, чтобы максимально четко передать структуру задачи решателю. Однако пользователи могут не распознать их в спецификациях своих моделей, основанных на языке ввода. Таким образом, некоторые решатели часто используют отдельные этапы обработки, которые, среди прочих действий, пытаются вывести некоторую неявную структуру из модели (например, распознать разрезы рюкзака путем комбинирования ограничений).

Подходящая система моделирования должна достигать аналогичной цели, но для этого требуется гораздо более богатый язык моделирования и больший набор базовых технологий решения. Основное внимание следует уделять автоматическому определению глобальной подструктуры в виде подразумеваемых глобальных ограничений.

Мы надеемся, что добьемся успеха на этом пути. Во-первых, проблему логической выполнимости можно рассматривать как проблему, частично аналогичную рассмотренной здесь, с последовательным управлением, которое обеспечивает гарантии завершения миссии системы в случае ограниченных бортовых ресурсов и других ограничений, упомянутых в статье.

Подход, основанный на использовании SMT-решателей, выглядит еще более подходящим в нашей проблемной области. Мы можем рассмотреть возможность применения таких инструментов, как ABSolver, Alt-Ergo, Barcelogic, MathSAT, CVC, OpenSMT, Simplify, STeP, Yices, Z3 и др. В [24] мы описали практический пример использования возможностей, предоставляемых решателем Z3.

Был разработан программный прототип, позволяющий проверять соответствие логики управления важным требованиям, сформулированным на языке логики RTCAL.

Программирование с ограничениями также может рассматриваться как подход, хорошо соответствующий задаче управления в случае ограниченных доступных ресурсов, поскольку наши ограничения являются своего рода ограничениями. Это обстоятельство открывает возможности для применения программирования с ограничениями в нашей проблемной области.

Чтобы сделать это, нам сначала нужно представить математические объекты, описанные ранее, используя языки ввода инструмента программирования ограничений. Затем мы должны сформулировать набор системных целей. После этого мы должны указать пределы системных ресурсов и выбросов и проверить, нарушаются ли эти пределы. Добавление этих глобальных ограничений к модели (с устранением или без устранения подразумевающих их ограничений) может значительно улучшить способность к решению задач.

Сегодня наиболее актуальным подходом в области искусственного интеллекта является использование глубоких нейронных сетей. Успешное применение трансформаторов, сверточных сетей и обучения с подкреплением в таких областях, как обработка естественного языка, автоматическая генерация кода, компьютерное зрение и генерация изображений, вызывает восхищение. В области управления обучение с подкреплением представляет собой многообещающее направление для дальнейших исследований.

Однако существует несколько принципиальных ограничений, которые необходимо учитывать при попытке использования возможностей глубоких нейронных сетей в нашей предметной области. Существенная проблема связана с понятием «объяснимого искусственного интеллекта», или Explainable AI. Обычно нейронная сеть выглядит как «черный ящик», имеющий входы и выходы, однако точные механизмы, с помощью которых она получает результат, остаются скрытыми.

При этом системы управления реального времени относятся к системам «критической важности» в силу возможности неприемлемых последствий при ошибке в их работе, катастрофических последствий, материальных потерь, ущерба здоровью и жизни человека. Поэтому необходимо иметь прозрачные и понятные правила для выработки оптимального реагирования на изменения во внешней среде и внутри самой системы.

Еще одним существенным ограничением для внедрения нейронных сетей в области интеллектуального управления является нехватка достаточных наборов данных для эффективного машинного обучения. Во многих

случаях у нас нет «исторических» данных, связанных с управлением конкретной сложной системой, мы можем вообще быть еще на стадии проектирования/внедрения.

В рассматриваемой предметной области представляется перспективной и полезной возможная будущая интеграция подходов, основанных на логике, и нейросетевых подходов. Это тема для дальнейших исследований и разработок. В настоящее время автор руководит разработкой прототипа специализированного программного средства, которое позволит верифицировать существующую логику управления, реализованную в существующих управляющих программах.

Чтобы решить проблему синтеза устойчивой логики управления, мы предлагаем использовать возможности современных SMT-решателей и программирования в ограничениях (Constraint). Ранее нам уже удавалось применить основанные на логике программные инструменты для целей верификации и синтеза алгоритмов управления космическими аппаратами в режиме реального времени [12, 22]. В заключение хотели бы выразить осторожную надежду, что мы находимся на пути к снижению влияния человеческого фактора на надежность управления сложной системой, как это было заявлено в [21].

#### Библиографический список

1. Козлов Д. И., Анишаков Г. П., Мостовой Я. А. Управление космическими аппаратами зондирования Земли: компьютерные технологии. М.: Машиностроение, 1998.
2. Ахметов Р. Н., Макаров В. П., Соллогуб А. В. Принципы управления космическими аппаратами мониторинга Земли в аномальных ситуациях // Информационно-управляющие системы. 2012. № 1(56).
3. Tyugashev A. A., Sygurov Yu. M. Method for modelling of Spacecraft onboard apparatus and building of consistent control logic with limited onboard resources // Journal of Physics Conference Series. 2019. November. 1368:042032.
4. Tyugashev A. A., Ermakov I. E., Ilyin I. I. Ways to Get More Reliable and Safe Software in Aerospace Industry // Program Semantics, Specification and Verification: Theory and Applications (PSSV 2012). Nizhni Novgorod, 2012. P. 121–129.
5. Establishing flight software reliability: Testing, model checking, constraint-solving, monitoring and learning / A. Groce, K. Havelund, G. Holzmann [et al.] // Annals of Mathematics and Artificial Intelligence. 2014. Vol. 70, № 4. P. 17–25.
6. Zimmerman M., Rodriguez M., Leveson N. Making Formal Methods Practical // Digital Aviations Systems Conference (DASC). October 2000, Philadelphia, USA.
7. Advances in Technological Applications of Logical and Intelligent Systems / J. M. Abe, J. I. Da Silva Filho, H. G. Martins, G. Lambert-Torres / Selected Papers from the Sixth Congress on Logic Applied to Technology. In Series Frontiers in Artificial Intelligence and Applications, IOS Press. 2008.
8. Тюгашев А. А. Интегрированная среда для проектирования управляющих алгоритмов реального времени // Известия Российской академии наук. Теория и системы управления. 2006. Т. 45, № 2. С. 287–300.
9. Tyugashev A. A. Application of SMT solvers for evaluation of Real-Time control logic of spacecraft // Journal of Physics: Conference Series. 2018. 1096:012156.
10. Tyugashev A. A., Belozubov A. V. Toolset for construction and verification of rules for spacecraft's autonomous decision making // 20th International Conference on Knowledge Based and Intelligent Information and Engineering Systems KES2016, Procedia computer science. 2016. Vol. 96. P. 811–818.
11. Тюгашев А. А., Богатов А. Ю., Шульдин А. В. Визуальный подход к верификации управляющих программ реального времени // Вестник Самарского государственного аэрокосмического университета им. академика С. П. Королева (национального исследовательского университета). 2012. № 1(32). С. 219–225.
12. Nakamatsu K., Jain L. C. The Handbook on Reasoning-Based Intelligent Systems. World Scientific Publishing Co. Ltd., Singapore, 2013.
13. Tyugashev A. Visual Builder of Rules for Spacecraft Onboard Real-Time Knowledge Base // 8th KES International Conference on Intelligent Decision Technologies (KES-IDT 2016). 2016. Part II. P. 189–205.
14. Maler O., Nickovic D., Pnueli A. Real-Time Temporal Logic: Past, Present, Future // International Conference on Formal Modelling and Analysis of Timed Systems Formats 2005. Lecture Notes in Computer Science. 2005. Vol. 3829. P. 2–16.
15. A real-time interval logic and its decision procedure / Y. S. Ramakrishna, L. K. Dillon, L. E. Moser [et al.] // Sadhana – Academy Proceedings in Engineering Sciences. 1996. Vol. 21, № 2. P. 147–184.
16. Beyer D., Lewerentz C., Noack A. Rabbit: A Tool for BDD-Based Verification of Real-Time Systems // 15th International Conference on Computer Aided Verification (CAV), Lecture Notes in Computer Science. 2003. Vol. 2725. P. 122–125.
17. Tyugashev A. A. Build and evaluation of real-time control algorithms in case of incomplete information about functional processes' parameters // XX IEEE International Conference on Soft Computing and Measurements (SCM 2017). 2017. P. 179–185.
18. Allen J. F. Maintaining knowledge about temporal intervals // Communications of the ACM. 1983. Vol. 26, № 11. P. 832–843.
19. Martin J. Application Development without Programmers, Prentice-Hall, Saddle River, NJ, USA, 1982.

20. *Nakamatsu K., Abe J. M.* Advances in Logic Based Intelligent Systems: Selected Papers of LAPTEC 2005. IOS Press, Amsterdam, Netherlands, 2005.
21. *Nakamatsu K., Abe J. M., Akama S.* A Logical Reasoning System of Process Before-After Relation Based on a Paraconsistent Annotated Logic Program bf-EVALPSN // International Journal of Knowledge-Based and Intelligent. Engineering Systems. 2011. Vol. 15, № 3. P. 145–163.
22. *Baeten J. C. M.* A brief history of process algebra. Vakgroep Informatica, Technische Universiteit, Eindhoven, Netherlands, 2004.
23. Вычислительный алгоритм формирования программного движения в программном повороте малого космического аппарата / А. В. Филатов, В. В. Салмин, И. С. Ткаченко [и др.] // Вестник Самарского государственного аэрокосмического университета им. академика С. П. Королева (национального исследовательского университета). 2015. Т. 14, № 2. С. 9–19.



*А. С. Харланов\**

доктор экономических наук, кандидат технических наук

*Е. А. Яковлева\*\**

кандидат физико-математических наук

\*Научно-исследовательский испытательный центр подготовки космонавтов имени Ю. А. Гагарина, Звездный городок, Россия

\*\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ГЕНЕРАТИВНЫЙ ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И ТРАНСФОРМАЦИЯ ГЛОБАЛЬНОЙ КОСМИЧЕСКОЙ ОТРАСЛИ

Описаны изменения в цифровой трансформации креативных индустрий и развитии технологий космической отрасли, ставших следствием роста цифровых сервисов и выстраивания экосистем человекоцентричных компетенций в направлении создания и развития соответствующих адаптивных навыков.

**Ключевые слова:** генеративный искусственный интеллект, биг дата, глобальная космическая отрасль, креативные индустрии, экосистема, технологии НБИКС, индустрия 4.0, Лунная база, Марсианская база.

*A. S. Kharlanov\**

Dr. Sc., Economic, PhD, Tech.

*E. A. Yakovleva\*\**

PhD, Phys.-Math.

\*Research Testing Center for Cosmonaut Training named after Yu. A. Gagarin, Zvyozdny gorodok, Russia

\*\*St. Petersburg State University of Aerospace Instrumentation

## GENERATIVE ARTIFICIAL INTELLIGENCE AND THE TRANSFORMATION OF THE GLOBAL SPACE INDUSTRY

The article talks about changes in the digital transformation of creative industries and space industry technologies, resulting from the growth of digital services and the building of ecosystems of human-centric competencies towards the creation and development of relevant adaptive skills.

**Keywords:** generative artificial intelligence, big data, global space industry, creative industries, ecosystem, NBICS technologies, industry 4.0, Moon base, Mars base.

Цифровой скачок в науке и в экономике, начавшейся с 2001 г., не только определил широкий диапазон подходов к умению извлекать дополнительные опции из применяемых диджитализируемых процессов в бизнесе и в «экономике производства», но и заставил экспертное сообщество и потенциальных потребителей пересмотреть понятие 4-го энергоперехода, известного как индустрия 4.0, наступающего робот-гуманоидного уклада [1].

Задачи цифровых сервисов и их влияние на природу более действенных, качественных и безопасных бизнес-процессов становятся следствием развития самих технологий искусственного интеллекта от машинного до глубокого обучения, трансформировавшихся за последние два года в системы генеративного искусственного интеллекта, определивших до 93% всей мировой торговли и более 85% международных производств массовых и прототипированных вариантов симбиоза технологии, материала и получаемой продукции, как явления непрекращающегося эксперимента в системе нарастающего перфекционизма «сырье/материал – технологии НБИКС/генеративный ИИ – продукт/услуга/решение», позволяющее преобразовывать как сам социум, так и пространство «конечного потребления», будь то рынок, креативная индустрия или интернет вещей, утверждающее «зеленую повестку» и ЦУР ООН в области улучшения качества и безопасности жизни населения отдельных государств, регионов, интеграционных блоков и союзов [2].

Статистика указанных процессов показывает мейнстрим единства хеджирования рисков «человеческого гения» системными и рациональными коррекциями со стороны машин и роботов, киборгов и дронов, способных выводить задачи на уровень единого уровня целеполагания, которые могут иметь филантропический, гуманитарный или креативный характер поиска оптимума между действиями нейроалгоритмов, переходящих в нейросети собственной мотивации и каскадного развития, с одной стороны, и отсечкой устаревших компетенций «синих воротничков» низкой квалификации «вчерашнего дня» в стремлении занять свое место в глокализованных цепочках идущих процессов альтерглобализации и формируемого технологического суверенитета от собственного рабочего места, до ниши в корпорации, кластерной поляризации формируемых новых навыков и компетенций, суммарно и аддитивно и определяющих национальную и глобализированную технологическую самодостаточность или рецессивную зависимость от внедряемых технических решений, включая саму схмотехнику, чиповое и релейно-платовое сопровождение гаджетов «нового мира» [3].

И конечно же, венцом инноваций и задачей прорыва человечества вне рамок своего обитания становится глобальная космическая отрасль, не позволяющая технически выходить за рамки генеративных моделей ускоренных передвижений в околоземном пространстве и в возможностях качественного и недорогого дистанционного зондирования Земли, ограниченных технологическими и материаловедческими возможностями по удержанию экосистемы «человек – Земля – космос» в рамках тестирования «цифровых двойников» и отработки на уровне аватаров в виртуальных и дополнительных реальностях метавселенных конечного уровня анализа, имитирующих будущие полеты в Солнечной системе и в ожидании рывков на расстояния вечных поисков в дальнем космосе [4; 5].

Космическая отрасль в ее глубинном глобализированном развитии начинает подразделяться на пилотируемую космонавтику системами искусственного интеллекта и роботоподобных комплексов и манипуляторов и навигационных провайдеров, зондов-исследователей и добытчиков машинного универсализма. Отдельно стоит космический туризм, который, как оказывается, за счет систем интернета вещей, генеративных систем обработки данных в режиме реального времени и получаемых нагрузок, может либо реализовывать возможность участия в прямых полетах на шаттлах, либо создавать максимально схожую имитацию для пользователей виджетов и гаджетов, готовых ради ощущений положить свои тела в специальные скафандры и залечь на виртуальных космодромах гейминговых пространств.

До настоящего момента не обосновано, исходя из критериев эндорфинных шоков и оплаты данных реальных и виртуально формируемых услуг, что будет безопаснее, дешевле и более массово востребовано: когда потенциальный «космический турист» вместо 20 млн долл. США за полет в несколько часов на околоземной орбите и при нескольких месяцах подготовки к нему при полной выкладке и при существующей и еще не до конца отработанной системе безопасности массовой эксплуатации космических капсул внеземного многоразового использования, в том числе в целях туризма по Солнечной системе, сможет конкурировать с тем же набором роботов и манипуляторов, встроенных в специальный тренажер имитационных процессов, которые точно, безопасно и когнитивно адресно насытят определенные зоны коры головного мозга, жаждущих ощущений и внеземного драйва от удовольствий подобного хайпа научных решений в виртуальных и в дополненных реальностях метавселенных [7].

Поэтому сами системы искусственного интеллекта и глобальная космическая отрасль только выходят на расчеты динамических моделей совместного эксперимента на Луне и на Марсе, тестируют варианты ловли космических тел, особенно метеоров и комет, готовых быть привлеченными в магнитные и гравитационные ловушки для более качественного и уместного их применения вместо ледяного вакуума Вселенной в технологиях легирования и адгезии в высокоэффективных сплавах и материалах/металлах с «памятью формы» и уникальных возможностей [6].

При этом сам космос и его участники в процессе научной гонки за первую Лунную, а потом уже Марсианскую космическую базу все более отдаляются от совместной международной кооперации, отдавая предпочтение «утечке мозгов», «бегству капиталов и технологий» в рамках научных кампусов и нанокластеров, ставя механизмы технического шпионажа и санкционных ограничений во главу угла, забывая о том, что космос может быть поднят как глобальный и единый проект только всего интегрированного в него человечества, не способного поодиночке решить все вопросы от качества и безопасности полетов вне нашей планеты, так и в системы экологичного и самодостаточного жизнеобеспечения колонистов на любом внеземном теле и планете [1; 7].

Промежуточные успехи в навигации новых видов средств доставки в космос, в квантовых сверхскоростных вычислениях, в создании новых линз для сверхмощных электронных телескопов по типу «Хаббл» или «Уэбстер», включая разрастающуюся сеть лабораторий, обсерваторий и электронного коллайдера для выделения бозона Хиггса как главного кирпичика строительства Вселенной, свидетельствуют лишь о разрозненности подходов агрессивного человечества и о тупиковости предпринимаемых усилий научных школ, неспособных, как и постреcessionное восстановление мировой экономики, определить бесспорные точки своего фундамента для бессрочного задела фундаментальных и только потом уже прикладных исследований, и неминуемого восстановления всего мирового хозяйства в целом [7].

При этом данный в помощь людям генеративный ИИ все более замкнут на детализации конкретной итерации, не занимается системными решениями единства подходов к прорывам в киберсреде, не дает сократить отставание в гиперзвуке и в создании оружия на неклассических принципах и с местом его потенциального размещения не различных околоземных орбитах или да же на астероидах, что, наверное, отрадно и гуманистически, возможно, и оправдано, с точки зрения, блоковых и интеграционных решений формируемого полицентричного и многополярного мира, рушащего вековое засилие англо-саксов в неокOLONIALном доминировании странами «золотого миллиарда» над другой частью человечества. Однако при этом данные несистемные попытки обогнать всех и стать монополистом на Земле и в космосе на «единую мирную кнопку» не делают мир ни более предсказуемым, ни уж тем более безопасным. Наоборот, заявление В. В. Путина о том, что «коллективный Запад» занимается экспериментами с ядерным оружием сверхмалой мощности, наталкивает на мысль о том, что и космические двигатели, подпадающие под категорию данной классификации, способны быть доставщиками летательных аппаратов внутри нашей галактики и уже успешно тестируются на предприятиях и в лабораториях ГК «Роскосмос». А имеющийся морской аналог вооружений аппарат «Посейдон» на ядерном реакторе отвечает в одной из сред (водной) таким же принципам безопасности и автономности, как и изделия подобного типа, что могут быть применены и выставляются в космическую эксплуатацию [8].

Поэтому либо глобальная космическая отрасль сможет привлечь не только лучшие научные и философские умы к спасению Земли и людей, либо мир станет полностью цифровым и дипфейковым и каждый окажется заложником бесконечного набора картинок, рисуемых различными формами искусственного интеллекта по когнитивному рабству и цифровому обнулению остатков человечности разума землян.

#### Библиографический список

1. Харланов А. С. Поддержание имперских устремлений России в новом миропорядке // Наука и инновации – современные концепции. М.: Инфинити, 2024.
2. Котлер Ф., Айвен С., Хермаван К. Маркетинг 5.0. Технологии следующего поколения. М.: Эксмо, 2023.
3. Китай – стратегический партнер и ценный сосед. Цивилизационный выбор и современные тренды кооперации: монография / А. С. Харланов, И. А. Максимцев, А. А. Бобошко, М. М. Новиков; отв. ред. С. В. Локтионов. М., 2022. 176 с.
4. Худякова О. Ю., Харланов А. С. Критерии анализа первого этапа ИИ: конфликты идей или синергия разума? // Экономика и предпринимательство. 2024. № 3(164). С. 951–956.
5. Гривен М., Йип Дж., Вэй В. Новаторы Поднебесной, или китайский бизнес покоряет мир. М.: Ланит, 2022.
6. Кай-Фу Ли. Сверхдержавы искусственного интеллекта. Китай, Кремниевая долина и новый мировой порядок. Бостон, Нью-Йорк. 2018.
7. Харланов А. С., Толмачев П. И., Эванс Ю. Н. Тенденции перераспределения активов на фоне дикаплинга экономик Китая и США // Вопросы инновационной экономики. 2023. Т. 13, № 4.
8. Космос России: выбор будущего и основные тренды доминирования: монография / А. С. Харланов, М. М. Харламов, Р. В. Белый [и др.]; науч. ред. В. И. Крючков. М., 2022.

*В. В. Шмелёв\**

доктор технических наук, доцент

*А. М. Попов\**

адъюнкт

*А. Н. Баранов\**

курсант

\*Военно-космическая академия имени А. Ф. Можайского, Санкт-Петербург, Россия

## МОДЕЛИРОВАНИЕ И ОТЛАДКА АЛГОРИТМОВ ОБРАБОТКИ ИЗМЕРИТЕЛЬНОЙ ИНФОРМАЦИИ

Представлен подход к верификации и отладке алгоритмов обработки телеметрической информации. На практическом примере показано поведение телеметрируемых параметров (ТМП) при возникновении в алгоритме обработки телеметрической информации (ТМИ) различного рода ошибок. Продемонстрировано, каким образом осуществляются поиск и коррекция возникающих ошибок с использованием формальных математических инструментов сетей Петри. Рассмотрены два типа ошибок, а также интерпретация этих ошибок в поведении свойств сети Петри.

**Ключевые слова:** алгоритмы обработки телеметрической информации, ошибки в алгоритмах обработки, сети Петри, анализ свойств сетей Петри, верификация, коррекция, моделирование вычислительных процессов.

*V. V. Shmelev\**

Dr. Sc., Tech., Associate Professor

*A. M. Popov\**

Adjunct

*A. N. Baranov\**

Cadet

\*A. F. Mozhaysky Military-Space Academy, St. Petersburg, Russia

## SIMULATION AND DEBUGGING OF ALGORITHMS FOR PROCESSING MEASUREMENT INFORMATION

The paper presents an approach to verification and debugging of algorithms for processing telemetry. The practical example shows the behavior of telemetry parameters when various kinds of errors occur in the algorithm for processing telemetry information. It is shown how the search and correction of the arising errors are carried out using formal mathematical tools of Petri nets. Two types of errors are considered, as well as an interpretation of these errors in the behavior of the properties of the Petri net.

**Keywords:** algorithms of processing of telemetry information, errors in the processing algorithms, Petri nets, analysis of properties of Petri nets, verification, correction, simulation of computed processes.

### Введение

Стандарт ISO 9000:2000 определяет процесс верификации изготавливаемого продукта следующим образом. Верификация – подтверждение на основе представления объективных свидетельств того, что установленные требования были выполнены.

Верификация (от лат. verus – верный) – это проверка того, что продукт удовлетворяет сформулированным требованиям.

Формальная верификация программ – это приемы и методы формального доказательства (или опровержения) того, что модель программной системы удовлетворяет заданной формальной спецификации.

Отладка (в широком смысле) – процесс поиска, локализации и исправления ошибок.

Отладка алгоритма – совместные процессы:

– приближения представлений наладчика о правильной работе алгоритма к действиям «идеального» алгоритма;

– поиска дефектов в алгоритме, не имеющем достоверного образца, на основании этих представлений.

В настоящее время проверка функционирования алгоритмов обработки результатов телеизмерений осуществляется в простейшем варианте: по ожидаемому поведению эталонных параметров с тестовых записей или аналогичных изделий ракетно-космической техники. Данный способ имеет набор прикладных недостатков, заключающийся в сложности подготовки алгоритмов обработки результатов телеизмерений новых или модифицированных изделий, в низкой оперативности изменения алгоритмов, практически полном доверии оператору в принятии решения о достоверности результата обработки. С теоретической позиции причиной указанного факта служит несовершенство научно-методического аппарата формализации алгоритмов обработки ТМИ.

Поскольку что-то доказать формально можно только относительно формальной модели, анализируемая система (реализация) должна быть представлена для верификации и отладки формальной моделью.

Процесс обработки ТМИ состоит из разнообразных компонентов, различающихся физическими свойствами, функциональным назначением, сложностью внутренней структуры. Для того чтобы сконструировать адекватный математический аппарат, предназначенный для моделирования требуемого процесса, необходимо установить круг вопросов, которые должны решаться с помощью моделей, и осуществить переход от физических сущностей к их абстракциям, сначала в форме некоторого (ограниченного) набора концептуальных понятий, затем – в точных математических терминах.

В работе [1] произведен подробный анализ подходов к моделированию алгоритмов обработки ТМИ. Из него следует, что использование вычислительных сетей Петри для анализа и верификации алгоритмов обработки ТМИ наиболее предпочтительно ввиду наличия формальных способов проверки алгоритма на желательные или нежелательные свойства.

### Представление алгоритмов обработки телеметрической информации сетями Петри

Сеть Петри состоит из четырех элементов: множество позиций  $P$ , множество переходов  $T$ , входная функция  $I$  и выходная функция  $O$ . Входная и выходная функции связаны с переходами и позициями. Входная функция  $I$  отображает переход  $t_j$  в множество позиций  $I(t_j)$ , называемых входными позициями перехода. Выходная функция  $O$  отображает переход  $t_j$  в множество позиций  $O(t_j)$ , называемых выходными позициями перехода. Структура сети Петри определяется ее позициями, переходами, входной и выходной функциями [2–3].

Сеть Петри  $S$  является четверкой  $S = (P, T, I, O)$ .  $P = \{p_1, p_2, \dots, p_n\}$  – конечное множество позиций,  $n \geq 0$ .  $T = \{t_1, t_2, \dots, t_m\}$  – конечное множество переходов,  $m \geq 0$ . Множество позиций и множество переходов не пересекаются,  $P \cap T = \emptyset$ .  $I: T \rightarrow P^\infty$  является входной функцией – отображением из переходов в комплекты позиций.  $O: T \rightarrow P^\infty$  есть выходная функция – отображение из переходов в комплекты позиций.

Мощность множества  $P$  есть число  $n$ , а мощность множества  $T$  есть число  $m$ . Произвольный элемент  $P$  обозначается символом  $p_i, i = 1, \dots, n$ , а произвольный элемент  $T$  – символом  $t_j, j = 1, \dots, m$ .

Маркировка  $\mu$  есть присвоение фишек позициям сети Петри. Фишка – это примитивное понятие сетей Петри (подобно позициям и переходам). Фишки присваиваются (можно считать, что они принадлежат) позициям. Количество и положение фишек при выполнении сети Петри могут изменяться. Фишки используются для определения выполнения сети Петри.

Маркировка  $\mu$  сети Петри  $S = (P, T, I, O)$  есть функция, отображающая множество позиций  $P$  в множество неотрицательных целых чисел  $N$ .  $\mu: P \rightarrow N$ . Маркировка  $\mu$  может быть также определена как  $n$ -вектор  $\mu = (\mu_1, \mu_2, \dots, \mu_n)$ , где  $n = |P|$  и каждое  $\mu_i \in N, i = 1, \dots, n$ . Вектор  $\mu$  определяет для каждой позиции  $p_i$  сети Петри количество фишек в этой позиции. Количество фишек в позиции  $p_i$  есть  $\mu_i, i = 1, \dots, n$ . Связь между определениями маркировки как функции и как вектора очевидным образом устанавливается соотношением  $\mu(p_i) = \mu_i$ . Обозначение ее в виде функции является несколько более общим и поэтому употребляется гораздо чаще.

Маркированная сеть Петри  $M = (S, \mu)$  есть совокупность структуры сети Петри  $S = (P, T, I, O)$  и маркировки  $\mu$  и может быть записана в виде  $M = (P, T, I, O, \mu)$ .

Структурно-функциональная модель обработки телеметрической информации представлена на рис. 1.

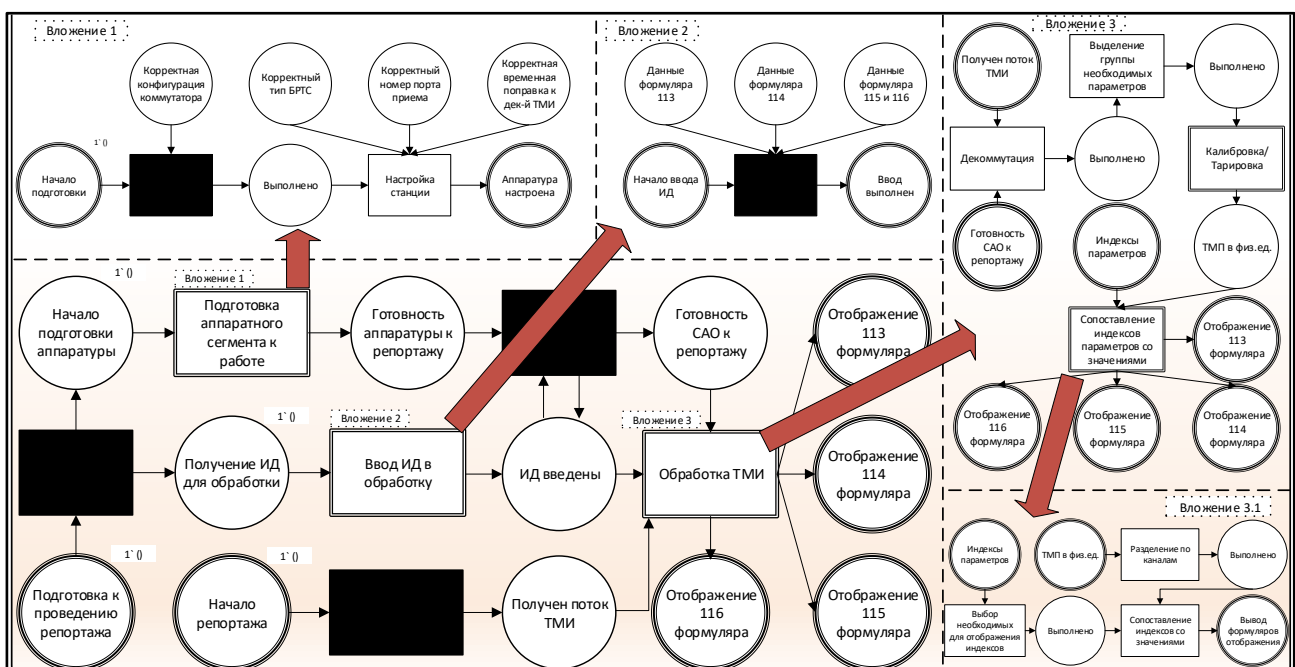


Рис. 1. Структурно-функциональная модель обработки ТМИ

В качестве примера рассмотрим случай неправильного внесения в массив исходных данных для обработки значения масштабного коэффициента. Поскольку модель, представленная на рис. 1 достаточно громоздкая, произведем ее декомпозицию до части внесения исходных данных в обработку. Тогда искомая часть может быть представлена в виде сети Петри, как показано на рис. 2.




Рис. 2. Декомпозированная сеть Петри ввода исходных данных для обработки ТМИ

Необходимо составить матрицу инцидентности полученной сети и решить уравнение достижимости;

$$D = \begin{matrix} & t_1 & t_2 & t_3 \\ p_1 & -400 & 0 & 0 \\ p_2 & 0 & 0 & -1 \\ p_3 & 0 & -1 & 0 \\ p_4 & 1 & 0 & -1 \\ p_5 & 0 & 1 & -1 \\ p_6 & 0 & 0 & 1 \end{matrix} \quad (1)$$

$$(0,0,0,0,0,1) = (250,1,1,0,0,0) + \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} \cdot \begin{bmatrix} -400 & 0 & 0 \\ 0 & 0 & -1 \\ 0 & -1 & 0 \\ 1 & 0 & -1 \\ 0 & 1 & -1 \\ 0 & 0 & 1 \end{bmatrix}; \quad (2)$$

$$\begin{cases} 400x_1 = 250 \\ x_3 = 1 \\ x_2 = 1 \\ x_1 - x_3 = 0 \\ x_2 - x_3 = 0 \\ x_3 = 1 \end{cases} \quad (3)$$

Система линейных уравнений (3) не имеет корректного решения, необходимо осуществить переход к этапу коррекции начальной маркировки.

Сведя (3) к каноническому виду, получим:

$$J = \begin{pmatrix} 400 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & -1 & 0 \\ 0 & 1 & -1 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} = \begin{pmatrix} 250 \\ 1 \\ 1 \\ 0 \\ 0 \\ 1 \end{pmatrix}. \quad (4)$$

Используя предлагаемый в работах [4; 5] подход, получим скорректированную систему линейных уравнений:

$$\begin{cases} 400x_1 = 400 \\ x_3 = 1 \\ x_2 = 1 \\ x_1 - x_3 = 0 \\ x_2 - x_3 = 0 \\ x_3 = 1 \end{cases}. \quad (5)$$

Для алгоритма обработки ТМИ корректировка системы линейных уравнений означает, что ошибочное значение масштабного коэффициента, введенное в массив исходных данных на обработку, исправилось на корректное (исправлено значение масштабного коэффициента с 250 на 400) (рис. 3).




Рис. 3. Поведение параметра с ошибкой в значении масштабного коэффициента и после исправления

В качестве второго примера рассмотрим случай возникновения заикливания в алгоритме обработки телеметрической информации. Декомпозированная сеть Петри такого процесса представлена на рис. 4.




Рис. 4. Устойчивая сеть Петри процесса обработки ТМИ

Физический смысл такого заикливания может быть выражен: неосвобождением буфера от предыдущего значения на этапе сравнения значений телеизмерений при повышении достоверности, нереализацией в алгоритме обработки приоритетных предикатов, неочищением буфера от разностных характеристик и т. п.

Для поиска заикливаний в сети, представленной на рис. 4, необходимо составить матрицу инцидентности и решить уравнение устойчивости [6]. Поскольку в данном случае речь идет об алгоритме обработки ТМИ, необходимо чтобы все операции над телеизмерениями выполнялись в соответствии со своей очередностью, поэтому вектор срабатываний переходов будет единичным:

$$D = \begin{matrix} & P_1 & P_2 & P_3 & P_4 & P_5 \\ \begin{matrix} t_1 \\ t_2 \\ t_3 \\ t_4 \\ t_5 \end{matrix} & \begin{bmatrix} -1 & 0 & 1 & 0 & 0 \\ 0 & -1 & 1 & 0 & 0 \\ 0 & 0 & -1 & 0 & 1 \\ 0 & 0 & -1 & 1 & 0 \\ 0 & 0 & 1 & -1 & 0 \end{bmatrix} \end{matrix}; \quad A = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{pmatrix}. \quad (6)$$

Сеть будет устойчива, если произведение матрицы инцидентности на вектор срабатываний переходов даст нулевое решение:

$$\begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{pmatrix} \cdot \begin{bmatrix} -1 & 0 & 1 & 0 & 0 \\ 0 & -1 & 1 & 0 & 0 \\ 0 & 0 & -1 & 0 & 1 \\ 0 & 0 & -1 & 1 & 0 \\ 0 & 0 & 1 & -1 & 0 \end{bmatrix} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}. \quad (7)$$

Для поиска и устранения заикливания в алгоритме обработки ТМИ необходимо проанализировать матрицу входных инцидентий на «неединичные вхождения» и внести изменения в сеть, исправив отношения между позициями и переходами в ручном режиме, или последовательно «занулять» отношения между позициями и переходами до решения уравнения достижимости в автоматизированном режиме [6].

Анализ матрицы входных инцидентий показывает, что позиция P<sub>3</sub> входит в несколько переходов, образуя цикл, и является началом заикливания алгоритма:

$$D^- = \begin{matrix} & P_1 & P_2 & P_3 & P_4 & P_5 \\ \begin{matrix} t_1 \\ t_2 \\ t_3 \\ t_4 \\ t_5 \end{matrix} & \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \end{bmatrix} \end{matrix}. \quad (8)$$



Возможное поведение параметра при наличии заикливания в алгоритме обработки ТМИ представлено на рис. 5.




Рис. 5. Поведение параметра при заикливании и после коррекции

### Заключение

Представленный подход описания алгоритмов обработки ТМИ позволяет, используя математический аппарат сетей Петри задавать и проверять формальные требования к моделям на их основе. Интерпретация этих требований для алгоритмов обработки ТМИ дает возможность создавать методическое и программное обеспечение для поиска и коррекции ошибок в подобных алгоритмах. В докладе на практических примерах показано, какие ошибки при обработке ТМИ могут быть допущены, поведение значений ТМП при допущенных ошибках, а также порядок их поиска и устранения.

### Библиографический список

1. Николаев А. Ю., Шмелёв В. В., Попов А. М. Поиск путей решения задачи моделирования алгоритмов обработки телеметрической информации для их дальнейшей верификации // Труды НППАП. Системы и приборы управления. 2023. № 2. С. 12–20.
2. Котов В. Е. Сети Петри. М.: Наука. Глав. ред. физ.-мат. лит. 1984. 160 с.
3. Веретельникова Е. Л. Теоретическая информатика. Теория сетей Петри и моделирование систем: учеб. пособие. Новосибирск: Изд-во НГТУ, 2018. 82 с.
4. Павлов Д. А., Попов А. М., Ткаченко В. В. Модель коррекции начальной маркировки классической сети Петри на основе решения задачи дискретного программирования // Труды МАИ. 2023. № 131.
5. Павлов Д. А., Попов А. М., Шмелёв В. В. Модель верификации исходных данных в процессе обработки телеметрической информации на основе решения задачи линейного целочисленного программирования // Авиакосмическое приборостроение. 2023. № 7. С. 3–10.
6. Попов А. М. Алгоритм автоматизированной верификации структурно-функциональной модели обработки телеметрической информации на основе вычислительной сети Петри // Известия Тульского государственного университета. Технические науки. 2023. Вып. 11. С. 251–257.

**В. В. Шмелёв\***

доктор технических наук, доцент

**Е. Б. Самойлов\***

кандидат технических наук, доцент

**О. А. Плахин\***

начальник учебной лаборатории

\*Военно-космическая академия имени А. Ф. Можайского, Санкт-Петербург, Россия

## ОБОСНОВАНИЕ ИСПОЛЬЗОВАНИЯ КОМПЛЕКСНОГО ПОКАЗАТЕЛЯ ЗНАЧИМОСТИ ТЕЛЕМЕТРИРУЕМЫХ ПАРАМЕТРОВ НА ОСНОВЕ ИХ ДИНАМИЧЕСКИХ И КОРРЕЛЯЦИОННЫХ СВОЙСТВ ДЛЯ ФОРМИРОВАНИЯ РЕПОРТАЖНОГО ПОТОКА

Приведена модель представления репортажного потока телеметрической информации космических средств. Рассмотрена одна из методик оценивания значимости телеметрируемых параметров. Поставлена задача формализовать репортажный поток телеметрической информации. Для получения числовых характеристик значимости (введения показателя значимости) с целью упорядочения множества телеметрируемых параметров показана интеграция полученных показателей.

**Ключевые слова:** телеметрируемые параметры, значимость параметров.

**V. V. Shmelev\***

Dr. Sc., Tech., Associate Professor

**E. B. Samoylov\***

PhD, Tech., Associate Professor

**O. A. Plakhin\***

Head of the Training Laboratory

\*A. F. Mozhaysky Military-Space Academy, St. Petersburg, Russia

## JUSTIFICATION OF THE USE OF A COMPLEX INDICATOR OF SIGNIFICANCE OF TELEMETRY PARAMETERS BASED ON THEIR DYNAMIC AND CORRELATIVE PROPERTIES FOR THE FORMATION OF A REPORT STREAM

The paper gives a model of representation of the report stream of telemetry information of space means. One of the methods for evaluating the significance of telemetry parameters was considered. The task is to formalize the reporting flow of telemetry information. To obtain numerical characteristics of significance (introduction of the indicator of importance) in order to organize a set of telemetry parameters, the integration of the obtained indicators is shown.

**Keywords:** parametric parameters, significance of parameters.

### Введение

В процессе летных испытаний и летной эксплуатации проводятся набор и оценка опытных данных по нагрузкам, действующим на ракету космического назначения (РКН) при старте и в полете, температурным режимам работы элементов РКН, динамике, устойчивости и управляемости движения, точности выведения на заданную орбиту. Практическая реализация данных мероприятий заключается в формировании, сборе, накоплении и анализе телеметрической информации (ТМИ), получаемой при пуске и полете РКН. Высокий уровень сложности современных и перспективных РКН, экстремальные режимы и условия их функционирования в полете приводят к необходимости измерений, сбора, обработки и оценки большого количества параметров, характеризующих состояние и режимы работы как отдельных систем и агрегатов, так и РКН в целом [1]. Вместе с тем существующие материально-технические и методические базы системы информационно-телеметрического обеспечения (СИТО) не в полной мере обеспечивают выполнение современных требований к количеству и качеству ТМИ, доставляемой в центры контроля полета РКН. В основном это связано с недостаточной пропускной способности космических и наземных каналов передачи данных [2].

Кроме того, современная военно-политическая обстановка требует неотложного принятия мер по закрытию доступа иностранных технических средств к результатам телеизмерений отечественных объектов ракетно-космической техники. Эта задача решается внедрением на передающую и приемную части комплекса средств измерений, сбора и обработки телеметрической информации специальной аппаратуры, ограничивающей доступ к семантическому содержанию информационных потоков. Следствием применения данной аппаратуры является временная задержка в десятки часов между моментом регистрации и окончанием предварительной и первичной обработки полного потока ТМИ. В реальном времени имеется возможность обработки потока, называемого «репортажным потоком» (РП), информативностью не более 1 МБ/с, причем информативность полного потока составляет до 16–20 МБ/с.

Перечень телеметрируемых параметров (ТМП) для включения в РП рекомендуется эксплуатационно-технической документацией по оперативной обработке телеметрической информации. Однако в настоящий момент отсутствует *научно обоснованный* подход к формированию РП и параметров для оперативной обработки. Таким образом, сегодня не учитываются вообще или не учитываются в необходимой степени следующие факторы: во-первых, постоянная отработка бортовых систем, благодаря которой возникает необходимость переноса внимания с одних систем на другие, во-вторых, индивидуальный опыт специалистов боевых расчетов обработки и анализа телеметрической информации, учитывающий неформализованные профессиональные предпочтения по актуальности обработки конкретных параметров, в-третьих, современные научно-методические наработки по формализованному оцениванию информационной значимости ТМП для наиболее эффективного определения технического состояния бортовых систем [3; 4], в-четвертых, постепенное техническое и алгоритмическое совершенствование аппаратно-программных комплексов, позволяющее повысить количество контролируемых при оперативной обработке ТМП.

Формализованное обоснование состава РП телеметрической информации позволит более гибко управлять оперативной обработкой измерений, учесть и наследовать опыт специалистов, тем самым будет повышена полнота результатов оперативной обработки.

Это показывает актуальность исследований, направленных на повышение полноты результатов оперативного анализа телеметрической информации баллистических ракет, ракет-носителей и космических аппаратов за счет создания и внедрения методики обоснования состава РП телеметрической информации баллистических ракет, ракет-носителей и космических аппаратов с учетом информационных ограничений на объем телеизмерений, обрабатываемых в реальном масштабе времени, на основе комплексной значимости ТМП.

### Модель представления репортажного потока телеметрической информации космических средств

Метод минимизации представления информации, содержащейся в матрицах ситуаций исходных таблицах наблюдений (ИТН), основывается на определении логических связей между наборами значений ТМП и режимами работы бортовой аппаратуры (БА). Закономерности изменения значений ТМП представляются в виде И-ИЛИ дерева и одновременно являются наглядным способом представления алгоритма классификации. Формируемые при этом граф-схемные модели (ГСМ) анализа используются для оперативного определения режима функционирования БА [5]. Подобная модель может быть использована и для описания РП.

Комплексная значимость не учитывается, ТМП входят ИТН в порядке нумерации внутри телеметрического кадра. Однако задание на множестве ТМП отношения порядка, связанного с каким-либо показателем значимости, по нашему мнению, позволит значительно оптимизировать ГСМ РП.

В целом показатель значимости ТМП характеризует относительную величину «вклада» того или иного параметра в решение задачи определения режима функционирования БС. На сегодняшний день разработан ряд информационных технологий, позволяющих определять этот показатель для ТМП бортовых систем космических средств. Использование показателя значимости позволит применять алгоритмы оценивания режима функционирования (технического состояния) с использованием минимального набора наиболее значимых ТМП, входящих в РП.

Представим модель  $RT$  РП ТМИ для с диапазонными ТМП как упорядоченное множество

$$RT = \langle X, Y, D, T \rangle, \quad (1)$$

где  $X$  – множество имен ТМП,  $X = \{x_1, x_2, \dots, x_j, \dots, x_{N_x}\}$ ,  $|X| = N_x \geq 1$ ;

$Y$  – множество различных режимов функционирования БА,  $Y = \{y_1, y_2, \dots, y_k, \dots, y_{N_y}\}$ ,  $|Y| = N_y \geq 2$ ;

$D$  – множество различных диапазонов ТМП,  $D = \{d_1, d_2, \dots, d_l, \dots, d_{N_d}\}$ ,  $|D| = N_d \geq 2$ ;

$T$  – множество моментов времени (условные номера экспертов или архивных данных),  $T = \{t_1, t_2, \dots, t_i, \dots, t_{N_t}\}$ ,  $|T| = N_t$ .

Под режимом функционирования БА  $y_k$  здесь понимается либо штатный – аварийный режим («норма» – «не норма»), либо, в более сложном случае, один из нескольких штатных вариантов работы.

Таким образом, ИТН представляет собой структурированную совокупность условных номеров диапазонов определенных ТМП в зависимости от режимов функционирования БА и от моментов времени.

### Использование динамических и корреляционных свойств телеметрируемых параметров для оценивания их комплексного показателя значимости

Далее рассмотрена одна из методик оценивания значимости ТМП, основанная на разбиении свойства значимости на два частных свойства:

- а) свойство сцепленности ТМП с фиксированными режимами функционирования БА;
- б) свойство изменчивости ТМП при смене режима функционирования БА.

Свойство сцепленности определяется динамикой изменения ТМП внутри одного режима функционирования БА: чем меньше изменяется ТМП при неизменности режима функционирования, тем больше он сцеплен с данным режимом. Другими словами, чем больше совпадающих между собой пар значений имеет данный ТМП

внутри подмножества своих значений, принадлежащих одному режиму работы БС, тем больше вклад этого ТМП в успешное определение данного режима.

Количественно сцепленность оценивается с помощью *коэффициента сцепленности*  $\beta_j^k$ . Он определяет степень неизменности значения диапазона  $j$ -го ТМП при переходе от одной строки ИТН к другой в пределах  $k$ -го режима работы функционирования БА:

$$\beta_j^k = \frac{1}{C_{N_k}^2} \sum_{r=1}^{C_{N_k}^2} J_r^j, \quad (2)$$

где  $N_k$  – количество строк в  $k$ -м режиме;  $J_r^j$  – индикатор сцепленности.

Индикатор сцепленности  $J_r^j$  может принимать следующие значения:

- 1 – в случае совпадения пары значений  $j$ -го ТМП внутри одного режима;
- 0 – в случае несовпадения.

При этом сравниваются все возможные пары значений:

$$J_r^j = \begin{cases} 1 & \text{при } D_{a_k}^j = D_{b_k}^j (a \neq b), \\ 0 & \text{else.} \end{cases} \quad (3)$$

Таким образом, для получения оценки  $\beta_j^k$  необходимо выполнить такую последовательность операций.

1. Выбрать множество строк, принадлежащих неизменному режиму (т. е. произвести сортировку ИТН).
  2. Подсчитать для каждого ТМП число совпадений диапазонов (значений) внутри неизменного режима БС.
  3. Произвести вероятностную нормировку полученных количеств совпадений с учетом всех возможных сочетаний пар значений.
  4. Задать отношение порядка на множестве значений, оцененных по сцепленности ТМП.
- Введем понятие средней сцепленности  $j$ -го ТМП, которую определим как

$$\beta_j = \frac{1}{N_Y} \sum_{k=1}^{N_Y} \beta_j^k. \quad (4)$$

*Свойство изменчивости* характеризует степень изменения значений ТМП при переходе от одного режима функционирования БА к другому: чем больше несовпадающих между собой пар значений имеет ТМП в двух подмножествах строк, принадлежащих двум различным режимам, тем большей изменчивостью он обладает и тем выше вклад данного ТМП в успешное решение задачи распознавания режима БС.

Количественно изменчивость характеризуется коэффициентом изменчивости  $\gamma_j^{k_1, k_2}$ , который представляет собой сумму числа несовпадений значений диапазонов  $j$ -го ТМП из пар строк ИТН  $k_1$  и  $k_2$ , принадлежащих двум различным режимам. Эта сумма нормируется по отношению к количеству возможных пар значений, принадлежащих различным режимам:

$$\gamma_j^{k_1, k_2} = \frac{1}{N_{k_1} \cdot N_{k_2}} \sum_{r=1}^{N_{k_1} \cdot N_{k_2}} Q_r^j, \quad (5)$$

где  $N_{k_1}, N_{k_2}$  – количество строк в режимах  $k_1$  и  $k_2$  соответственно;  $Q_r^j$  – индикатор изменчивости.

Индикатор изменчивости  $Q_r^j$  принимает следующие значения:

- 1 – в случае несовпадения пары значений  $j$ -го ТМП из пар строк из разных режимов,
- 0 – в случае совпадения.

При этом сравниваются все возможные пары строк для всех режимов:

$$Q_r^j = \begin{cases} 1 & \text{при } D_{k_1}^j \neq D_{k_2}^j, \\ 0 & \text{else.} \end{cases} \quad (6)$$

Средний коэффициент изменчивости по ИТН  $j$ -го ТМП ( $\gamma_j$ ) характеризует среднюю вероятность изменения значений диапазона ТМП при смене режимов БС (при равновероятной смене режимов):

$$\gamma_j = \frac{1}{C_{N_Y}^2} \sum_{k=1}^{C_{N_Y}^2} \gamma_j^{k_1, k_2}, \quad k_1 \neq k_2. \quad (7)$$

Для оценивания характеристики  $\gamma_j$  необходимо:

- 1) отсортировать ИТН по режимам работы БС;
- 2) взять пару значений  $j$ -го ТМП, принадлежащих двум различным режимам работы, и подсчитать число несовпадений значений для данного ТМП путем перебора всех входящих в ИТН режимов;
- 3) произвести необходимую нормировку полученных сумм с учетом общего количества возможных вариантов пар значений, принадлежащих различным режимам;
- 4) построить отношение порядка на множестве значений  $\gamma_j$  для каждого из ТМП;
- 5) при необходимости вычислить среднее значение коэффициента изменчивости для данных, собранных в ИТН.

*Свойство значимости* ТМП является объединением двух ранее описанных свойств: сцепленности параметра с режимом и его изменчивости. Чем больше значимость ТМП, тем более оправданным является его анализ в первую очередь и включение его в так называемые опорные множества.

Для получения числовых характеристик значимости (введения показателя значимости) с целью упорядочения множества ТМП необходимо каким-либо образом осуществить интеграцию полученных показателей  $\beta_j$  и  $\gamma_j$ . Поскольку условия, при которых вычисляются показатели  $\beta_j$  и  $\gamma_j$ , не совместны, то для оценивания результирующего показателя значимости  $\alpha_j$  возможно применение мультипликативной формы:

$$\alpha_j = \beta_j \cdot \gamma_j. \quad (8)$$

### Заключение

Предложенные и обоснованные динамические и корреляционные характеристики телеметрируемых параметров космических средств, а именно изменчивость и сцепленность, а также их комплексная характеристика – значимость – могут принести значительную пользу при решении прикладных задач обработки и передачи телеметрической информации, а также задач анализа технического состояния бортовых систем РКН.

### Библиографический список

1. Николаев А. Ю., Самойлов Е. Б., Шмелёв В. В. Методика оперативного диагностирования системы управления расходом топлива ракет-носителей типа «Союз-2» на основе функционально-логических схем обработки телеметрической информации в режиме реального времени // *Авиакосмическое приборостроение*. 2022. № 5. С. 34–46.
2. Теория и практика построения автоматизированных систем мониторинга технического состояния космических средств: монография / О. В. Майданович, В. А. Каргин, В. В. Мышко [и др.]. СПб.: ВКА, 2011. 219 с.
3. Охтилев М. Ю. Основы теории автоматизированного анализа измерительной информации в реальном времени. Синтез системы анализа. СПб.: ВКА имени А. Ф. Можайского, 2007. 166 с.
3. Николаев А. Ю., Самойлов Е. Б., Шмелёв В. В. Модель выявления семантических ошибок в алгоритмах первичной обработки телеметрической информации космических средств // *Труды Военно-космической академии имени А. Ф. Можайского*. 2022. № 682. С. 139–148.
4. Николаев А. Ю., Самойлов Е. Б., Шмелёв В. В. Модель выявления семантических ошибок в алгоритмах первичной обработки телеметрической информации космических средств // *Труды Военно-космической академии имени А. Ф. Можайского*. 2022. № 682. С. 139–148.
5. Мальцев В. Б. Анализ состояния технических систем. М.: МО РФ, 1992. 160 с.

**В. Н. Штепа\***

доктор технических наук, доцент

**В. В. Смелов\***

кандидат технических наук, доцент

**Д. С. Карпович\***

кандидат технических наук, доцент

\*Белорусский государственный технологический университет

## СТРУКТУРНЫЕ СХЕМЫ ЦИФРОВЫХ ДВОЙНИКОВ ПРОЦЕССОВ ПРОМЫШЛЕННОГО ВОДООТВЕДЕНИЯ

Совместное внедрение подходов автоматизации и оптимизации производственных функций, включая использование интернета вещей для сбора и обмена данными между оборудованием и системами мониторинга, и принципов Cleaner Production обеспечит минимизацию выбросов, оптимизацию использования ресурсов и развитие решений, направленных на снижение негативного влияния промышленности на окружающую природную среду. Приведены структурные схемы цифровых двойников процессов промышленного водоотведения на основании данных подходов и принципов.

**Ключевые слова:** индустрия 4.0, интернет вещей, автоматизация производственных функций, цифровые двойники, промышленное водоотведение.

**V. N. Sthepa\***

Dr. Sc., Tech., Associate Professor

**V. V. Smelov\***

PhD, Tech., Associate Professor

**D. S. Karpovich\***

PhD, Tech., Associate Professor

\*Belarusian State Technological University

## STRUCTURAL DIAGRAMS OF DIGITAL TWINS OF INDUSTRIAL WATER TREATMENT PROCESSES

Joint implementation of automation and optimization approaches to production functions, including the use of the Internet of Things for data collection and exchange between equipment and monitoring systems, and the principles of «Cleaner Production» will ensure minimization of emissions, Optimizing the use of resources and developing solutions aimed at reducing the negative impact of industry on the natural environment. The paper gives structural diagrams of digital duals of industrial water treatment processes based on these approaches and principles.

**Keywords:** industry 4.0, internet of things, automation of production functions, digital twins, industrial water purification.

Одним из базовых международных документов в сегменте цифровых двойников является ISO 23247 Automation systems and integration – Digital twin framework for manufacturing. Этот норматив определяет Digital Twin (ЦД) как «цифровую модель конкретного физического элемента или процесса с подключениями к данным, которая обеспечивает конвергенцию между физическим и виртуальным состояниями с соответствующей скоростью синхронизации». ЦД выступает неотъемлемой частью концепта «индустрия 4.0», сочетающей цифровые, физические и биологические технологии, что предполагает внедрение современных подходов для оптимизации процессов и облегчения производства экологически чистой продукции.

Компания UPM-Куммеле внедрила методологию «индустрия 4.0» для прогнозирования технического обслуживания, что привело к снижению затрат на него на 30% и сокращению незапланированных простоев производства около 20%. Концерн Stora Enso активно использует датчики интернета вещей (IoT) и аналитику данных для оптимизации своей цепочки поставок: это позволило сократить потребление ресурсов на 20% и уменьшить количество отходов на 15%, что подчеркивает успешную цифровую трансформацию в направлении устойчивого развития. Соответственно, использование концепции «индустрия 4.0» более полно интегрирует цифровые технологии в производственные процессы: автоматизацию и оптимизацию производственных функций, включая использование интернета вещей для сбора и обмена данными между оборудованием и системами мониторинга [1].

Совместное внедрение подходов и принципов Cleaner Production обеспечит минимизацию выбросов и оптимизацию использования ресурсов и развитие решений, направленных на снижение негативного влияния промышленности на окружающую природную среду. Наибольшую экологическую опасность несут некачественно очищенные (неочищенные) сточные воды: прежде всего промышленного формирования [2]. Таким образом, комплексное внедрение цифрового моделирования в управление водоотведением, куда входят составляющей частью и очистные сооружения, является актуальной научно-практической задачей.

При этом на производственном уровне для достижения указанной стратегической цели необходимо достичь следующие подцели управления производственными операциями: организация и координация ресурсов (материалов, энергии, оборудования, персонала и информации), планирование производства, отгрузка продукции, управление базами данных производства, контроль качества сточных вод, обслуживание оборудования, управление запасами посредством прогнозирования. Неопределенность на этом уровне связана с ресурсной (доступность материалов, энергии, оборудования и рабочей силы), технической (отказ оборудования) и управленческой неопределенностями (решения, принятые на производственном уровне, могут быть субъективными и основываться на неоднозначных данных и предположениях), а также связана с колебаниями показателей качества сырья и ресурсов. Тогда структура цифрового двойника водоотведения должна включать элементы передачи и хранения данных, моделирования, пользовательской среды (рис. 1).

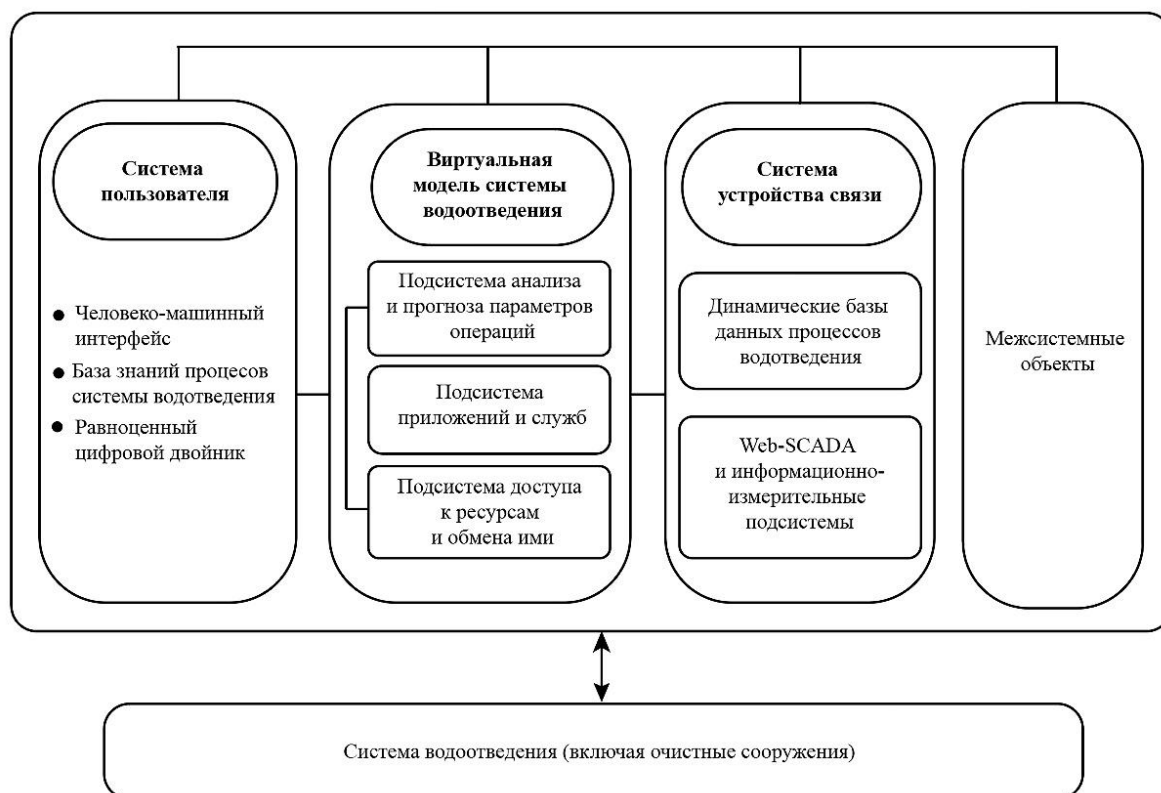


Рис. 1. Структурная модель цифрового двойника водоотведения

Для эффективного цифрового моделирования необходимо решить следующие технологические подзадачи [3]:

- скрининг и прогнозирование критических этапов производственных процессов для исключения неконтролируемого попадания недопустимых концентраций вредных веществ в сточные воды перед очисткой, контроль состояния агрегатов и узлов;
- автоматический контроль (при возможности) состояния водных ресурсов на производственных этапах;
- контроль параметров и количества реагентов, вводимых в технологические процессы;
- контроль состояния сырья, поставляемого на производство;
- контроль гидравлических параметров отведения сточных вод (включая расходы сточных вод на отдельных агрегатах перед поступлением на очистные сооружения);
- адаптивное управление и оперативное прогнозирование экологической и ресурсоэффективности очистных сооружений и их углеродного следа.

Развернутая архитектура ЦД промышленного водоотведения, решающая указанные подзадачи, представлена на рис. 2.

Соответственно, продуктом цифрового моделирования является фактически система поддержки принятия решений (СППР) управления водопользованием промышленными объектами с внедрением ЦД на основе машинного обучения, адаптивного мониторинга и других интеллектуальных подходов; СППР относится к производственному процессу и операциям на уровне MES/MOM.

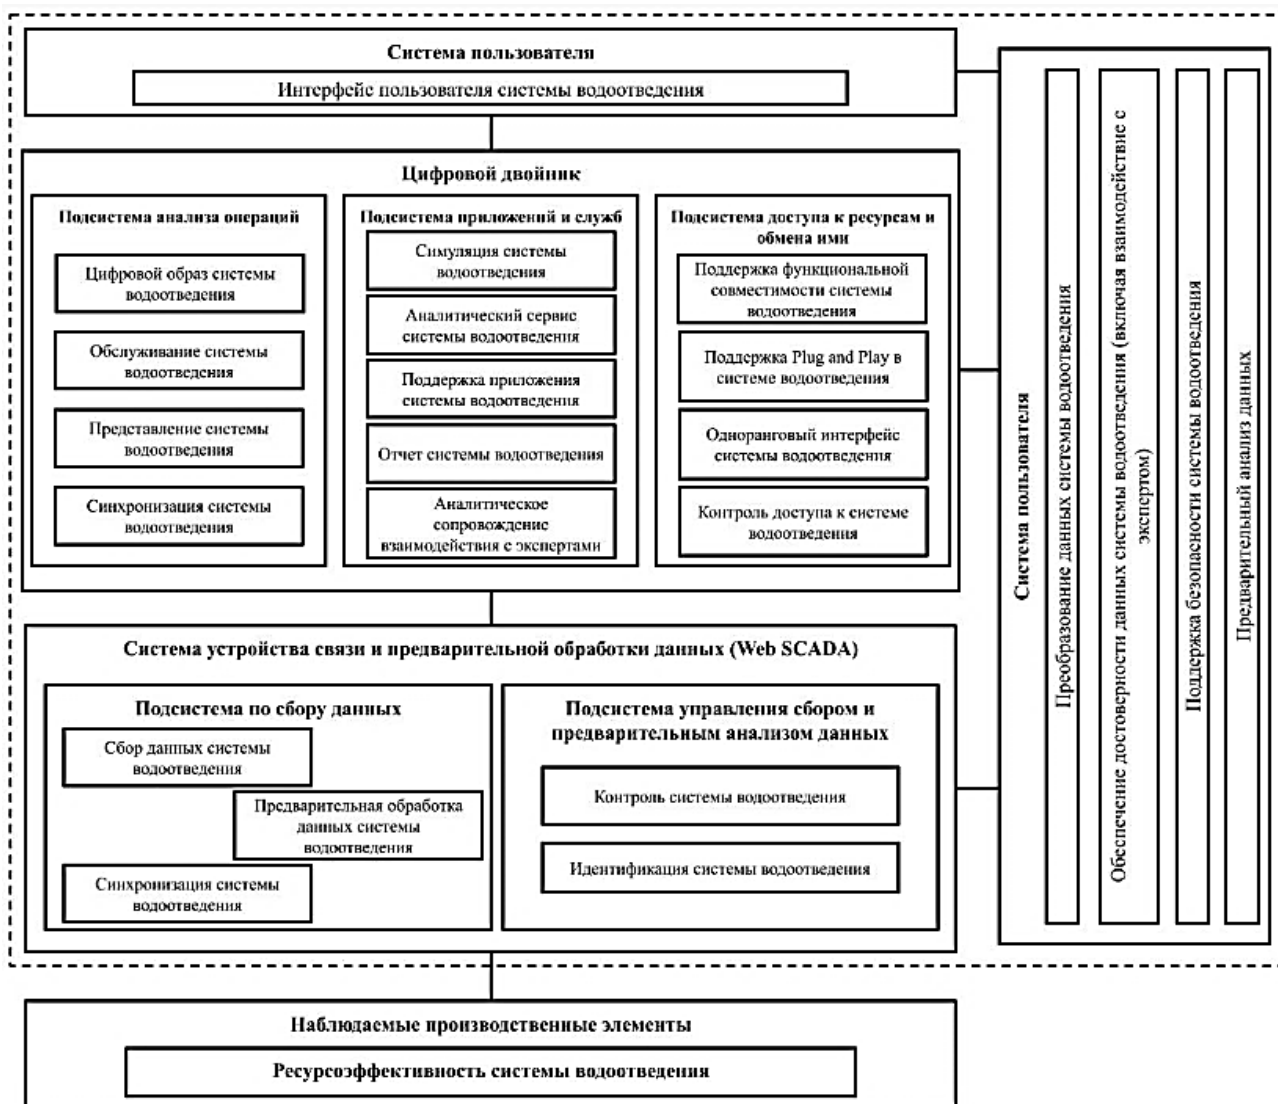


Рис. 2. Развернутая структурная модель цифрового двойника водоотведения

Общие ожидаемые результаты цифрового моделирования [4]:

- соблюдение норм обеспечения экологической безопасности эксплуатации систем водоотведения, в том числе очистных сооружений;
- повышение экономической эффективности производства, использующего водные ресурсы на разных стадиях жизненного цикла продукции;
- снижение затрат на ресурсы, повышение эффективности принятия управленческих решений, оптимизация технического обслуживания и ремонта и исполнение требований экологической безопасности;
- повышение эффективности и распределенного контроля качества сточных вод в узлах их отведения;
- снижение рисков возникновения антропогенных чрезвычайных ситуаций в водных объектах путем прогнозирования и обнаружения мест потенциального их возникновения;
- масштабирование цифровых двойников основных технологических элементов водоотведения на другие производственные подсистемы, в том числе исключительно производственного характера;
- повышение квалификации и переподготовки специалистов предприятий с использованием цифровых СППР.

### Заключение

Потенциально цифровое моделирование должно повысить ресурсоэффективность и экологическую безопасность эксплуатации систем водоотведения производств на различных жизненных циклах продукции с использованием современных информационно-коммуникационных технологий на базе IoT, многомерной обработки данных и интеллектуального мониторинга, экспертных программных продуктов и систем поддержки принятия решений, виртуального представления реальных промышленных объектов.



### Библиографический список

1. Оценка применимости международных стандартов цифровых двойников для решения задач водоотведения / А. Б. Шикунец, В. Н. Штепа, В. В. Смелов, Д. С. Карпович // Инженерно-экологические аспекты и перспективы развития систем водоснабжения и водоотведения, Брест, 28 марта 2024 г. / Брест. гос. техн. Ун-т. Брест, 2024. С. 174–177.
2. *Войтов И. В., Штепа В. Н.* Использование цифровой платформы водоотведения для предупреждения технологических рисков биологической очистки сточных вод // Инновационные биотехнологии для охраны окружающей среды: от теории к практике: матер. I Междунар. науч.-практ. конф., Минск, 23–25 апр. 2024 г. / Ин-т микробиологии НАН Беларуси; орг. комитет конф.: А. А. Шепшелев (пред.) [и др.]. Минск, 2024. С. 83–84.
3. О задачах цифровизации систем водоотведения коммунально-промышленных объектов / И. В. Войтов, В. В. Смелов, А. В. Дернович, В. Н. Штепа // Нефтегазохимия-2023: матер. VI Междунар. науч.-техн. форума по хим. технологиям и нефтегазопереработке, Минск, 1–3 нояб. 2023 г. / Белорус. Гос. технол. ун-т»; отв. за выпуск К. В. Вишневский. Минск, 2023. С. 147–151.
4. Практическое использование информационно-аналитической системы оценки экологической безопасности водоотведения / В. Н. Штепа, А. Б. Шикунец, А. В. Козырь, Н. Ю. Золотых // II Форум IT-Академграда «Искусственный интеллект в Беларуси»: доклады, Минск, 12–13 окт. 2012 г. / Нац. акад. наук Беларуси, Объединен. ин-т проблем информатики; науч. ред.: С. В. Кругликов; С. Н. Касанин. Минск, 2023. С. 251–256.

# ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ОБРАЗОВАНИИ

УДК 004.8

*А. В. Аграновский\**

кандидат технических наук, доцент

*Е. Л. Турнецкая\**

кандидат технических наук, доцент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ФОРМИРОВАНИЕ ОБРАЗОВАТЕЛЬНОЙ ТРАЕКТОРИИ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Рассмотрено применение рекомендательной системы для формирования индивидуальной образовательной траектории студента. Показано, что ее использование позволяет студентам соотнести имеющиеся у них профессиональные навыки с требованиями соответствующих вакансий на рынке труда и принять решение о векторе своего дальнейшего профессионального развития. Для организаторов процесса обучения применение рекомендательной системы помогает определить вариативные и факультативные дисциплины, упростить подбор дидактических единиц и индикаторов проверки сформированности компетенций по указанным дисциплинам.

**Ключевые слова:** рекомендательная система, образовательная траектория.

*A. V. Agranovskii\**

PhD, Tech., Associate Professor

*E. L. Turnetskaya\**

PhD, Tech., Associate Professor

\*St. Petersburg State University of Aerospace Instrumentation

## FORMATION OF EDUCATIONAL TRAJECTORY WITH THE HELP OF ARTIFICIAL INTELLIGENCE

The article considers the use of recommendation system for the formation of individual educational trajectory of a student. It is shown that the use of such a system allows students to correlate their professional skills with the requirements of relevant vacancies in the labor market and decide on the vector of their further professional development. For the organizers of the educational process the application of the recommender system helps to define variable and optional disciplines, to simplify the selection of didactic units and indicators for checking the formation of competencies in these disciplines.

**Keywords:** recommendation system, educational trajectory.

Одно из направлений повышения качества высшего образования – формирование индивидуальной образовательной траектории для каждого обучающегося. Процесс подготовки и корректировки такой траектории достаточно сложен и подразумевает не только регулярную оценку уровня знаний, но и учет сформированных профессиональных компетенций, а также пожеланий студентов относительно их будущей сферы деятельности. Развитие современных информационных технологий в области искусственного интеллекта позволяет автоматизировать ряд задач, возникающих в процессе работы над индивидуальными образовательными траекториями.

Первоочередная задача при формировании образовательных траекторий со стороны учебного заведения – анализ текущего состояния рынка труда с целью выявления запросов потенциальных работодателей. Различные направления образовательной траектории предлагают студентам в формате факультативных курсов и дисциплин по выбору. В свою очередь, обучающийся может определить возможный вектор своего профессионального роста и развития на основе сопоставления своих профессиональных интересов и описания требований к интересующим его вакансиям. Таким образом, существуют две задачи, решение которых заложено в формирование индивидуальной образовательной траектории: определение блока вариативных и факультативных дисциплин образовательной организацией и выбор студентом из этого блока предметов, необходимых с точки зрения интересующего его направления деятельности. Решение указанных задач может быть реализовано с использованием рекомендательных систем.

Рекомендательные системы представляют собой программные инструменты, которые предлагают пользователям персонализированные рекомендации о товарах, услугах, контенте или других объектах на основе их предпочтений и поведения [1]. Чтобы нивелировать субъективные предпочтения организаторов процесса обучения и студентов, можно выбрать рекомендательную систему на основе контента, которая создает рекомендации без учета оценок и предположений пользователей [2–3].

Рассмотрим в качестве примера экспериментальную рекомендательную систему по выбору вакансий, разработанную на кафедре прикладной информатики ГУАП [4]. Перед ее разработкой был проведен опрос внутри фокус-группы из 30 студентов для определения формата взаимодействия между студентом и рекомендательной системой. На основании опроса было принято решение, что студент самостоятельно оценивает свои профессиональные навыки и фиксирует их в резюме, на основании которого система подбирает вакансии. Таким образом, были определены функционал и интерфейс рекомендательной системы.

На первом этапе разработки системы был собран датасет ИТ-вакансий, опубликованных на портале интернет-рекрутмента hh.ru. Выбор в качестве источника данного онлайн-сервиса обусловлен понятной структурой описания вакансии, состоящего из 15 параметров. Датасет состоит из 15 столбцов данных, которые были получены при автоматизированном скачивании информации.

Для создания рекомендаций по подбору вакансий достаточно трех столбцов: код (Ids), название (Name) и описание вакансии (Description). Так как на портале hh.ru не сформулированы строгие правила описания вакансий работодателем, потребовалось создать новый столбец с предобработанными описаниями (Prep\_Description), в котором каждое описание было приведено к нижнему регистру, удалены переносы строк и табуляция, после чего тексты были очищены от ненужных символов и знаков препинания, также были удалены стоп-слова и произведена лемматизация оставшихся слов. Также производится предобработка резюме студента, в результате чего кратко формулируются навыки соискателя.

Предобработанные тексты описаний вакансий и навыков соискателя на следующем этапе векторизуются с помощью TD-IDF [3], после чего находится косинусное сходство между этими векторами. Вакансии с наибольшим значением косинусного сходства выводятся в качестве рекомендаций на основе введенных студентом навыков.

Для доступа к системе разработано веб-приложение с использованием фреймворка Streamlit, который предоставляет нативную поддержку популярных библиотек анализа данных и машинного обучения, таких как Pandas, NumPy, Matplotlib и TensorFlow. Кроме того, Streamlit предоставляет возможность размещать веб-приложения на собственной платформе-хостинге.

Разработанное веб-приложение имеет три основные функции: сбор вакансий с сервиса и запись их в базу данных, визуализация информации о вакансиях, рекомендация профессий.

Для получения рекомендаций студенту необходимо ввести набор ключевых навыков, например «Я знаю Python, SQL, теорию вероятностей, статистику. Умею работать с Pandas, Numpy. Вывожу графики с помощью Tableau, Seaborn, Matplotlib».

После предобработки такое описание навыков приобретает вид: «знать python sql теория вероятность статистика уметь работать pandas numpy выводить графика помощь tableau seaborn matplotlib».

Система при этом рекомендует студенту две профессии (рис. 1).

Рис. 1. Рекомендация профессии на основе ключевых навыков

Также возможен вывод рекомендаций в табличном формате. Для рассматриваемого примера системой было определено 5 возможных вакансий (таблица).

### Рекомендации по заданному набору навыков

Ids	Name	Description	Prep_Description
48438134	Data Scientist (Predict)	Задачи: 80% – разработка моделей машинного об...	Задача разработка модель машинный обучение отк...
49919663	Ведущий аналитик Data Scientist	Что вам предстоит: Разрабатывать механизмы оп...	Предстоять разрабатывать механизм оптимизация ...
49843936	Аналитик данных	Привет! Мы международная IT компания Marfatech...	Привет международный it компания marfatech рын...
49309067	Менеджер по продукту в Data Science, Ozon Express	Что вам предстоит: Анализировать большие дан...	Предстоять анализировать больший дать строить ...
49471304	Аналитик данных	Обязанности: - Автоматизация отчетности по рис...	Обязанность автоматизация отчётность риск сбор..

Разработанная рекомендательная система на основании датасета по ИТ-вакансиям позволяет визуализировать результаты. При этом в графическом виде демонстрируются востребованность выбранной студентом профессии на рынке труда (рис. 2), количество вакансий по регионам и др.

Топ 10 профессий по количеству вакансий




Рис. 2. Профессии с наибольшим числом вакансий

Таким образом, применение рекомендательной системы позволяет студентам соотнести имеющиеся у них профессиональные навыки с требованиями соответствующих вакансий на рынке труда и принять решение о векторе своего дальнейшего профессионального развития. Они могут выстроить собственную систему грейдинга и выбрать в процессе обучения те факультативные и вариативные дисциплины, результаты обучения по которым позволят им собрать комплекс навыков для соответствия требованиям желаемой вакансии.

Для организаторов процесса обучения применение рекомендательной системы при формировании образовательной траектории позволяет определить вариативные и факультативные дисциплины, упростить подбор дидактических единиц и индикаторов проверки сформированности компетенций по указанным дисциплинам.

Таким образом, в формировании образовательной траектории принимают участие непосредственно сам обучающийся, организаторы обучения и в качестве независимого эксперта рекомендательная система.

Применение практик машинного обучения и искусственного интеллекта создает уникальные возможности для трансформации образовательных практик и подходов к организации процесса образования.

#### Библиографический список

1. Ricci F., Rokach L., Shapira B. Introduction to recommender systems handbook. Springer Science & Business Media, 2015. 842 p.
2. Recommender systems: an introduction / D. Jannach, M. Zanker, A. Felfernig, G. Friedrich. Cambridge University Press, 2011. 353 p.
3. Isinkaye F. O., Folajimi Y. O., Ojokoh B. A. Recommendation systems: Principles, methods and evaluation // Egyptian Informatics Journal. 2015. P. 261–273.
4. Пономаренко В. В., Турецкая Е. Л. Разработка рекомендательной системы вакансий в ИТ-сфере // Обработка, передача и защита информации в компьютерных системах: Четвертая Междунар. науч. конф. (СПб., 8–15 апр. 2023 г.): сб. докл. СПб.: ГУАП, 2024. С. 72–79.

**Ю. А. Антохина\***

доктор экономических наук, профессор

**М. Л. Кричевский\***

доктор технических наук, профессор

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## РИСКИ ИСПОЛЬЗОВАНИЯ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ В ОБРАЗОВАНИИ

Рассмотрены возможности использования больших языковых моделей в образовательной деятельности. Приведены примеры применения таких моделей и указаны различные виды возникающих при этом рисков.

**Ключевые слова:** большие языковые модели, образовательная деятельность, риски.

**Yu. A. Antokhina\***

Dr. Sc., Economic, Professor

**M. L. Krichevsky\***

Dr. Sc., Tech., Professor

\*St. Petersburg State University of Aerospace Instrumentation

## RISKS OF LARGE LANGUAGE MODELS IN EDUCATION

The work considers possibilities of using large language models in educational activities. Examples of such models are provided and the different types of risks involved are indicated.

**Keywords:** large language models, educational activities, risks.

После революционного открытия архитектуры трансформера в 2017 г. [1] появились предварительно обученные и большие языковые модели, в основе которых в той или иной степени использовалась такая структура. Однако языковые модели тоже прошли свой путь развития. Технически языковое моделирование (Language Modeling, LM) является одним из основных подходов к развитию языкового интеллекта машин. Большое внимание в литературе уделено исследованию LM, которое можно разделить с точки зрения способности решать задачи на четыре основных этапа эволюции [2].

Кратко охарактеризуем каждую генерацию языковых моделей.

1. *Статистические языковые модели* (Statistical Language Models, SLM), которые разрабатывались на основе статистических методов обучения, получили распространение в 1990-е гг. [3]. Основная идея состоит в том, чтобы построить модель предсказания слов, например спрогнозировать следующее слово на основе самого последнего контекста. SLM широко применяются для повышения производительности задач в информационном поиске и обработке естественного языка, однако они часто страдают от проклятия размерности.

2. *Нейронные языковые модели* (Neural Language Models, NLM), которые оценивают вероятность последовательности слов с помощью нейронных сетей, например многослойного перцептрона и рекуррентных нейронных сетей. В разработанной методологии word2vec было предложено построить упрощенную нейронную сеть для изучения распределенных представлений слов, которая продемонстрировала высокую эффективность при решении задач обработки естественного языка [4].

3. *Предварительно обученные языковые модели* (Pre-trained Language Models, PLM). В качестве первой попытки использовался подход, основанный на вложениях для языковых моделей для захвата контекстно-зависимых представлений слов [5]. Кроме того, в 2017 г. была описана архитектура новой сети типа Transformer, обладающая высокой степенью параллелизма и механизмами самовнимания [1].

4. *Большие языковые модели* (Large Language Models, LLM). Исследователи обнаружили, что масштабирование PLM (например, масштабирование размера модели или размера данных) часто приводит к улучшению производительности модели при решении последующих задач. В ряде работ изучали предел производительности, обучая большие PLM, например у GPT-3 (Generative Pre-trained Transformer) число параметров составляет 175 млрд. Исследовательское сообщество ввело термин «большие языковые модели» для большемерных PLM, которые привлекают все большее внимание.

Использование LLM в образовании было определено как потенциальная область интереса из-за разнообразного спектра приложений, которые они предлагают. Благодаря использованию этих моделей возможности для повышения качества обучения и преподавания могут стать достижимыми для людей на всех уровнях образования, включая начальное, среднее, высшее и профессиональное развитие. *Для студентов университетов* большие языковые модели могут помочь в исследовательских и письменных задачах, развитии критического мышления и навыков решения проблем. Эти модели можно использовать для создания резюме и набросков текстов. Кроме того, LLM способны оказать помощь в развитии исследовательских навыков, предоставляя студентам информацию и ресурсы по определенной теме и указывая на неизученные аспекты и темы исследований.

Модель GPT (Generative Pre-trained Transformer, GPT) [6], разработанная OpenAI, стала первой большой языковой моделью, которая была публично выпущена в 2018 г. GPT смогла генерировать текст, похожий на человеческий, отвечать на вопросы и помогать в выполнении задач, таких как перевод и обобщение. На основе этой первоначальной разработки OpenAI позже выпустила последующие модели вплоть до ChatGPT-4o (буква «o» в названии расшифровывается как «omni» и указывает на универсальность нейросети) с более продвинутыми возможностями. Можно утверждать, что выпуск GPT открыл множество путей для распространения, как в исследовательских, так и в промышленных приложениях.

С точки зрения студента, LLM могут быть использованы различными способами для облегчения процесса обучения. Один из примеров – создание и дизайн образовательного контента. В частности, в недавней работе [7] исследователи использовали GPT-3 для генерации вопросов и ответов с несколькими вариантами ответов для задачи на понимание прочитанного и утверждают, что автоматизированная генерация тестов не только снижает нагрузку на преподавателей по ручному проектированию тестов, но прежде всего предоставляет студентам полезный инструмент для тренировки и проверки своих знаний во время обучения по учебникам и при подготовке к экзаменам.

В области компьютерного образования LLM может применяться для создания объяснений кода [8]. Несмотря на несколько открытых исследовательских и педагогических вопросов, которые нуждаются в дальнейшем изучении, эта работа успешно продемонстрировала потенциал машины для поддержки обучения путем объяснения аспектов данного фрагмента кода.

Для курса по науке о данных (data science) рассматривалась возможность создания конвейера для генерации оценочных вопросов на основе тонко настроенной модели на текстовых учебных материалах [9]. Сгенерированные вопросы были дополнительно оценены с точки зрения их полезности для результата обучения на основе автоматизированных с помощью обученной модели и ручных проверок экспертами-людьми.

В недавнем обзоре разговорного ИИ в языковом образовании авторы обнаружили, что наиболее распространенным применением разговорного ИИ во время обучения является использование больших языковых моделей в качестве собеседника в письменной или устной форме, например в контексте ориентированного на задачу диалога, который предоставляет возможности языковой практики, такие как произношение [10].

Укажем возможные риски, связанные с применением LLM в образовательных задачах [11].

*Авторские права.* При формировании контента с использованием больших языковых моделей в образовательных задачах – программе курса, научной работе – должно быть проведено обучение на примерах таких текстов. Во время генерации нового запроса ответ может содержать целое предложение или даже абзац, который можно увидеть в обучающем наборе, что приводит к проблемам с авторскими правами и плагиатом.

*Студенты могут слишком сильно полагаться на модель.* Легко сгенерированная информация может негативно повлиять на их критическое мышление и навыки решения проблем. Это связано с тем, что модель упрощает получение ответов или информации, что может усилить лень и противодействовать интересу обучающихся к проведению собственных исследований, выводам или решениям.

*Преподаватели могут стать слишком зависимыми от моделей.* Использование больших языковых моделей может предоставить точную и актуальную информацию, но они не могут заменить креативность, критическое мышление и навыки решения проблем, которые развиваются благодаря человеческому обучению. Поэтому важно, чтобы преподаватели использовали эти модели в качестве дополнения к своему обучению, а не замены.

*Трудность отличить ответы, сгенерированные моделью, от ответов студентов.* Становится все труднее различать, является ли текст машинным или человеческим, что представляет собой дополнительную серьезную проблему для преподавателей. (Департамент образования Нью-Йорка недавно запретил ChatGPT на школьных устройствах и в сетях.)

*Стоимость обучения и обслуживания.* Поддержка больших языковых моделей может стать финансовым бременем для учебных заведений. Для решения этой проблемы в качестве отправной точки может послужить использование предварительно обученных моделей и облачных технологий в сочетании с кооперативными схемами использования в партнерстве с учреждениями и компаниями.

*Затраты на проверку информации и поддержание целостности.* Важно проверить информацию, предоставленную моделью, обратившись к внешним авторитетным источникам, чтобы убедиться в точности и целостности. Кроме того, могут возникнуть финансовые затраты, связанные с поддержанием и обновлением модели для обеспечения предоставления точной и актуальной информации

*Сложность отличить реальные знания от убедительно написанных, но непроверенных результатов модели.* Способность больших языковых моделей генерировать человекоподобный текст может затруднить для студентов различение реальных знаний и непроверенной информации. Это может привести к тому, что обучающиеся будут принимать ложную или вводящую в заблуждение информацию как правдивую, не ставя под сомнение ее достоверность.

*Недостаточная адаптивность.* Большие языковые модели не способны адаптироваться к разнообразным потребностям учащихся и преподавателей и могут быть не в состоянии обеспечить уровень персонализации, необходимый для эффективного обучения. Это ограничение текущей технологии, но вполне возможно, что с более совершенными моделями адаптивность будет увеличиваться.

### Библиографический список

1. Attention is all you need / A. Vaswani, N. Shazeer, N. Parmar [et al.] // Advances in neural information processing systems. 2017. P. 5998–6008.
2. A Survey of Large Language Models / Wayne Xin Zhao, Kun Zhou, Junyi Li [et al.]. 2023. URL: <https://arXiv.2303.18223> (дата обращения: 12.08.2024).
3. *Rosenfeld R.* Two decades of statistical language modeling: Where do we go from here? // Proceedings of the IEEE. 2000. Vol. 88, № 8. P. 1270–1278.
4. Distributed representations of words and phrases and their compositionality / Т. Mikolov, I. Sutskever, K. Chen [et al.]. 2013. URL: <https://arXiv.1310.4546> (дата обращения: 10.08.2024).
5. Deep contextualized word representations / М. E. Peters, М. Neumann, М. Iyyer [et al.] // Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, NAACL-HLT 2018. Vol. 1. P. 2227–2237.
6. Improving language understanding by generative pre-training / A. Radford, K. Narasimhan, T. Salimans [et al.]. 2018. URL: <https://www.cs.ubc.ca/~amuham01/LING530/papers/radford2018improving.pdf> (дата обращения: 10.08.2024).
7. Reading Comprehension Quiz Generation using Generative Pre-trained Transformers / R. Dijkstra, Z. Genc, S. Kayal [et al.]. 2022. URL: [https://e.humanities.uva.nl/publications/2022/dijk\\_read22.pdf](https://e.humanities.uva.nl/publications/2022/dijk_read22.pdf) (дата обращения: 10.09.2024).
8. Generating Diverse Code Explanations Using the GPT-3 Large Language Model / S. MacNeil, A. Tran, D. Mogil [et al.] // Proceedings of the 2022 ACM Conference on International Computing Education Research. N. Y., 2022. Vol. 2. P. 37–39.
9. Towards Automated Generation and Evaluation of Questions in Educational Domains / S. Bhat, H. A. Nguyen, S. Moore [et al.] // In Proceedings of the 15th International Conference on Educational Data Mining. Durham, United Kingdom, 2022. P. 701–704.
10. *Reham E.* Effects of artificial intelligence on english speaking anxiety and speaking performance: A case study // Expert Systems. 2021. Vol. 38(3):12667.
11. ChatGPT for Good? On Opportunities and Challenges of Large Language Models for Education / E. Kasneci, K. Sessler, S. Kuchemann [et al.]. 2023. URL: [https://www.researchgate.net/publication/367541637\\_ChatGPT\\_for\\_Good\\_On\\_Opportunities\\_and\\_Challenges\\_of\\_Large\\_Language\\_Models\\_for\\_Education/citation/](https://www.researchgate.net/publication/367541637_ChatGPT_for_Good_On_Opportunities_and_Challenges_of_Large_Language_Models_for_Education/citation/) (дата обращения: 10.09.2024).

*А. Э. Бердин*

старший преподаватель

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ИСПОЛЬЗОВАНИЕ БОЛЬШИХ ДАННЫХ В ОБРАЗОВАТЕЛЬНОЙ ДЕЯТЕЛЬНОСТИ

Обозначены ключевые преимущества, проблемы и тренды внедрения больших данных в образовательный процесс.

**Ключевые слова:** большие данные, образование.

*A. E. Berdin*

Senior Lecturer

St. Petersburg State University of Aerospace Instrumentation

## USE OF BIG DATA IN EDUCATION

The paper outlines key advantages, problems and trends of introducing big data into educational process.

**Keywords:** big data, education.

Искусственный интеллект (ИИ) обладает уверенным потенциалом для решения некоторых ключевых проблем в качественном развитии современного образования, внедрения инноваций в методы преподавания. Среди различных инструментов ИИ, которые реализуются в образовательной деятельности, наиболее практико-ориентированной, по нашему мнению, является область по применению больших данных.

Как во всех секторах экономики, использование больших данных в образовании осуществляется ускоренными темпами. Сбор данных в образовании помогает образовательным учреждениям понимать потребности и поведение учащихся. Использование данных для улучшения результатов высшего образования становится обязательным. Глобальный рынок аналитики больших данных в образовании демонстрирует стабильные цифры своего роста. Прогнозируется, что его оценочная стоимость взлетит до 41,54 млрд долл. к 2028 г. с годовым темпом прироста в 14,9% [1]. Растущее внедрение цифровых обучающих платформ и растущий спрос на персонализированный учебный опыт подпитывают этот рост. Большие данные в образовании играют здесь важную роль: они обеспечивают персонализированное обучение, повышают вовлеченность студентов и позволяют учреждениям принимать решения на основе фактических данных.

Использование больших данных в образовании в основном сосредоточено на адаптивном обучении. Данные используются для анализа среды, успеваемости, мотивации и потребностей учащихся, чтобы предоставить им персонализированное обучение, адаптированное к их потребностям. Создание индивидуальных учебных траекторий и программ является основной задачей данного инструмента ИИ, который направлен на содействие адаптированному обучению и повышению мотивации учащихся.

Результаты сбора и анализа данных предоставляют преподавателям информацию об учащихся, которая может помочь им открыть новые знания и, таким образом, улучшить функционирование образовательных учреждений любого уровня (школа, техникум, вуз).

Большие данные в образовании сформировали новые модели и концепции обучения, которые можно использовать для получения более эффективного понимания и обеспечения надлежащего обучения учащихся. Более широкое использование новых цифровых инструментов (например, виртуальная реальность, VR), также предоставляет образовательным учреждениям больше информации о навыках и уровне подготовки их учащихся и педагогов. Например, они могут видеть, выполняют студенты онлайн-курса задание за один раз или делают перерыв.

После проведения анализа и обработки большого массива данных можно выявить закономерности и тенденции, а также сформулировать гипотезы и сделать весьма реалистичные прогнозы для принятия решений, которые смогут улучшить процесс обучения. Существует немало приложений, но успех их применений заключается именно в способности улучшать процессы обучения. В целом можно обозначить следующие ключевые преимущества от внедрения больших данных в образовательный процесс [2].

*Персонализированное обучение.* Большие данные предоставляют педагогам большой объем информации о процессе обучения. Этот анализ позволяет узнать, насколько хорошо каждый обучающийся усваивает программу, и если есть проблемы в отдельных дисциплинах, то почему это происходит, чтобы иметь возможность найти оптимальное решение проблемы в режиме реального времени. Цель состоит в том, чтобы проанализировать успеваемость, определить, где появляются наибольшие трудности, и помочь преодолеть их. Своевременное реагирование – ключ к достижению прогресса с каждым обучающимся и адаптации каждого занятия. Для этого технология должна продолжать экспериментировать и развиваться, чтобы помочь принимать решения в режиме реального времени.



*Понимание моделей поведения.* Использование приложений и инструментов с детьми в возрасте до 12 лет помогает контролировать посещаемость, постоянно регистрировать академическую активность, обеспечить всестороннее понимание каждого ученика на основе моделей поведения, настроения, успеваемости и т. д. Все эти данные позволяют уделять каждому ученику необходимое ему внимание и адаптировать его образование к его потребностям, проблемам и различиям. Например, есть специальные программные продукты на основе больших данных для улучшения успеваемости каждого сегмента учеников. В них используются записывающие камеры, которые фиксируют с разных ракурсов все, что происходит в классе, с целью запечатлеть выражение лица детей, речь, словарный запас, жесты и т. д. Это позволяет учителям реагировать на поведение всего класса. Хотя идея установки камер в классах и анализа поведения детей вызывает споры среди родителей, избирательное применение данного программного продукта нацелено на будущее развитие адаптивного и гибкого образования.

*Предотвращение конфликта.* Анализ данных о возможном конфликте также может выявлять среди прочего случаи исключения риска и психических расстройств. Таким образом, учителя, психологи и воспитатели смогут действовать быстро и предвидеть серьезную проблему. Кроме того, эти инструменты могут предсказывать, как изменятся модели обучения, даже до того, как это произойдет. Это позволяет учителям определить для каждого ученика свой вариант решения возможного конфликта и вмешиваться на ранней стадии, чтобы снизить уровень вынужденного отсева проблемных обучающихся, особенно в случаях, когда выявляются особые потребности (например, дислексия). Использование больших данных в образовании дает множество преимуществ, особенно в оптимизации дистанционного обучения.

Преподаватели могут определить, как учащиеся используют различные образовательные ресурсы и какие методы дают им наилучшие результаты, поскольку они могут видеть успеваемость каждого из них в реальном времени и анализировать достигнутые академические результаты и их динамику.

Вместе с тем, несмотря на очевидные преимущества от использования больших данных в образовании, им присущ и ряд проблем. Их понимание очень важно для максимально эффективного использования их потенциала в образовательных процессах.

– Проблемы конфиденциальности данных: использование персональных данных в образовательных целях представляет собой значительную проблему. Это включает обеспечение соответствия таким правилам, как соблюдение общего регламента по защите данных (GDPR) для защиты конфиденциальной информации.

– Качество и согласованность данных: поддержание точности, полноты и согласованности данных в различных источниках представляет собой проблему. Низкое качество данных может привести к ошибочным идеям и решениям, что снижает эффективность образовательных инициатив.

– Инфраструктура и технические ограничения: неадекватная инфраструктура, включая устаревшие аппаратные и программные системы, может препятствовать эффективному сбору, хранению и обработке больших объемов образовательных данных. Устранение этих ограничений требует инвестиций в надежную ИТ-инфраструктуру и модернизацию технологий.

– Интеграция разрозненных хранилищ данных: учебные заведения часто имеют фрагментированные данные, хранящиеся в разных системах и форматах, что создает разрозненные хранилища данных. Интеграция разрозненных источников данных для обеспечения комплексного анализа и понимания может быть сложной задачей.

Заинтересованные участники образовательного процесса должны отдавать приоритет структурам управления данными и инвестировать в инструменты управления качеством данных, чтобы преодолеть эти проблемы. Они также должны модернизировать технологическую инфраструктуру и внедрять совместимые системы для бесшовной интеграции данных. Поощрение грамотности и прозрачности данных также может снизить риски приложений больших данных в образовании.

Нивелируя с помощью имеющихся в арсенале образовательных учреждений программных средств риск появления рассмотренных недостатков, определим основные тенденции и драйверы роста применения больших данных в образовании.

– Рост цифрового обучения: ускоренный переход к цифровым платформам обучения, вызванный технологическими достижениями и тенденциями дистанционного обучения, стимулирует спрос на решения по аналитике больших данных в образовании [3].

– Персонализированное обучение: аналитика больших данных позволяет предоставлять индивидуальный опыт обучения. Анализируя показатели производительности, уровни вовлеченности и области улучшения, педагоги могут настраивать и корректировать по мере необходимости траектории обучения и механизмы поддержки.

– Сосредоточение на успеваемости учащихся: уделяя все большее внимание успеваемости учащихся, образовательные учреждения используют аналитику больших данных для выявления тех, кто относится к так называемой группе риска, прогнозируя показатели отсева неуспевающих и внедряя целевые механизмы вмешательства в качественный образовательный процесс.

Говоря о прогнозах развития данного направления в ИИ, можно отметить следующие ключевые тренды [2].

– Интеграция искусственного интеллекта (ИИ): интеграция машинного обучения, обработки естественного языка и интеллектуальных систем обучения еще больше произведет революцию в образовании. Образовательные платформы на базе ИИ будут предлагать адаптивный опыт обучения, персонализированные рекомендации и обратную связь на основе данных.

– Улучшенные меры безопасности данных и конфиденциальности: по мере увеличения объема и конфиденциальности данных учащихся все больше внимания будет уделяться мерам безопасности данных и конфиденциальности. Образовательные учреждения будут инвестировать в надежные протоколы кибербезопасности, технологии шифрования и фреймворки соответствия для защиты данных учащихся и обеспечения соблюдения нормативных требований.

– Профорентация: образовательная система преобразует профорентацию. Использование аналитики больших данных предоставит персонализированные рекомендации и пути развития навыков, соответствующие способностям и интересам отдельных студентов, будь то в технических или гуманитарных науках.

– Интеграция распознавания лиц и обучения на основе голоса: эти технологии обеспечат обратную связь в реальном времени, адаптивное обучение и персонализированные учебные процессы, которые соответствуют уникальному стилю и темпу обучения каждого студента.

– Практики найма на работу на основе данных: компании будут все больше полагаться на практики подбора персонала на основе данных. Использование информации из образовательных данных университетов для оценки производительности кандидатов и их пригодности для определенных должностей изменит стратегии подбора кадров и приобретения ценных сотрудников.

– Максимальная эффективность обучения: сочетание аналитики больших данных, искусственного интеллекта, геймификации и технологий моделирования откроет новые уровни эффективности обучения. Они обеспечат персонализированные учебные пути, адаптивные оценки и иммерсивные учебные процессы, которые оптимизируют сохранение знаний и освоение навыков.

Таким образом, тезисно обозначив суть, проблемы и перспективы внедрения такого инструмента искусственного интеллекта, как большие данные, в образовательный процесс, сделаем вывод, что использование больших массивов данных, а также результаты их обработки и анализа позволят участникам образовательного процесса, в первую очередь педагогам, оценить и при необходимости модернизировать технологии обучения, сделать учебный процесс более персонализированным, усовершенствовать сами методики преподавания и более качественно проводить оценку достижений учащихся. Большие данные позволяют обнаруживать поведение учащихся, выполнять предиктивное моделирование и разрабатывать персонализированные пути обучения.

#### **Библиографический список**

1. Global Big Data Analytics in Education Market (2023–2028). URL: <https://finance.Yahoo.Com/news/global-big-data-analytics-education-172400236.Html> (дата обращения: 10.09.2024).
2. Using Big Data in education: examples and benefits. URL: <https://www.telefonica.com/en/communication-room/news/using-big-data-in-education-examples-and-benefits/> (дата обращения: 05.05.2023).
3. *Kvartalnyi N.* Big Data in Education: Challenges & Benefits. URL: <https://inoxoft.Com/blog/impact-of-big-data-on-education-history-benefits-and-examples/> (дата обращения: 25.04.2024).

*И. М. Бойназаров*

кандидат технических наук, доцент

Самаркандский филиал Ташкентского университета информационных технологий им. Мухаммада аль-Хоразмий, Узбекистан

## АДАПТИВНЫЕ МЕТОДЫ ОЦЕНКИ КАЧЕСТВА ОБРАЗОВАТЕЛЬНОГО КОНТЕНТА

Описаны подходы к построению гибкой модели оценки ресурсов электронного обучения, направленной на повышение интереса студентов и разработку качественных образовательных ресурсов. Уровень качества электронных образовательных ресурсов был проанализирован по результатам анкетирования, проведенного с точки зрения студентов. В связи с этим за основу были взяты платформа электронного обучения и ресурсы электронного обучения, подготовленные для формы дистанционного обучения, созданные в Самаркандском филиале Ташкентского университета информационных технологий имени Мухаммада аль-Хоразмий. В качестве метода оценки из изученных научных материалов и методов оценки была выбрана модель SURE (Structure-Oriented Evaluation). На ее основе сделаны выводы.

**Ключевые слова:** ресурсы электронного обучения, смешанное обучение, методы оценки ресурсов электронного обучения: TAM, QM, SURE.

*I. M. Boynazarov*

PhD, Tech., Associate Professor

Samarkand Branch of Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Uzbekistan

## ADAPTIVE METHODS OF ASSESSING EDUCATIONAL CONTENT QUALITY

This article describes approaches to building a flexible, e-learning resource evaluation model aimed at increasing students' interests and developing quality educational resources. The quality level of electronic educational resources was analyzed based on the results of the survey conducted from the point of view of students. In this regard, the e-learning platform and e-learning resources prepared for the form of distance education established at the Samarkand branch of the Tashkent University of Information Technologies named after Muhammad al-Khorazmi were taken as a basis. The SURE (Structure-Oriented Evaluation) model was selected from the studied scientific materials and evaluation methods as an evaluation method. Conclusions are made based on this model.

**Keywords:** e-learning resources, blended learning, evaluation methods of e-learning resources: TAM, QM, SURE.

### I. Введение

Электронные образовательные ресурсы становятся неотъемлемой частью современной системы высшего образования. Процессы глобализации и цифровизации начали оказывать существенное влияние на сферу образования, что требует совершенствования методов обучения и создания гибких образовательных ресурсов. Проведено множество исследований с целью повышения эффективности использования электронных ресурсов в образовательном процессе, обеспечения их более широкого использования, повышения качества образования. В частности, исследования важности и эффективности электронного обучения научно доказали, что оно дает возможность улучшить качество образования, поднять уровень обучения студентов и сделать образовательный процесс более гибким. Например, в исследовании Андерсона и Эллуми [1] приводятся научные мнения о том, что электронное обучение дает студентам возможность выбирать темп индивидуального обучения и делает образование более интерактивным и интересным. Электронные ресурсы играют важную роль в образовательном процессе, предоставляя учащимся быстрый и простой доступ к широкому спектру информации. Многие исследования, особенно проведенные Бейтсом [2], показывают, что электронные ресурсы способны повысить интерес учащихся и обеспечить их активное участие в процессе обучения.

Исследования Г. Сименса показывают, что инфраструктура электронного обучения состоит из набора технических инструментов, платформ и сервисов, подчеркивается, что эти инструменты необходимы для эффективной организации образовательного процесса [3]. Удовлетворенность пользователей (студентов и преподавателей) считалась важным показателем в научных работах, проводимых с точки зрения удовлетворенности пользователей электронных образовательных ресурсов. В частности, показано, что уровень удовлетворенности студентов и преподавателей электронными курсами обучения оказывает большое влияние на общее качество образования. Для повышения эффективности электронного обучения важно повысить уровень цифровой грамотности учащихся и преподавателей. Развитие таких навыков помогает сделать образовательный процесс более эффективным, традиционные и смешанные подходы к обучению также являются неотъемлемой частью электронного обучения. Согласно научным результатам, смешанный подход к образованию сочетает лучшие стороны электронного и традиционного образования, что позволяет эффективно организовать учебный процесс [4–6].

## II. Анализ методов оценки ресурсов электронного обучения

Определение и оценка эффективности новых технологий или реформ, проводимых в любой области, имеет важное значение. Важно определить, насколько внедряемая инновация подходит данной среде, не допустить ошибок и вовремя устранить недостатки. Остановимся на моделях, примененных в системе образования и прошедших ряд испытаний.

TAM (Technology Acceptance Model, модель принятия технологии) – модель оценки, которая используется в отношении уровня принятия пользователем внедряемых новых технологий и методов [7]. Оценивает факторы, влияющие на принятие пользователями новых технологий. Хотя TAM подвергался критике по ряду причин, он обеспечивает полезную общую основу и подходит для изучения ряда факторов, влияющих на намерения пожилых людей использовать новые технологии [8; 9]. Два основных фактора: простота использования и воспринимаемая эффективность.

Kirkpatrick's Evaluation Model (модель оценки Киркпатрика) предлагает четырехуровневую систему оценки: реакция, обучение, поведение и результаты. Его также можно использовать при оценке ресурсов электронного обучения, поскольку он исследует процессы от первоначальной реакции учащихся до практического применения полученных ими знаний и результатов [10]. Факторы, влияющие на удовлетворенность студентов асинхронными онлайн-курсами, изучались в исследовании [11] с учетом методов оценки и измерений. Среди них особое внимание уделялось структуре курса, участию преподавателей и возможностям взаимодействия со сверстниками.

Модель успеха электронного обучения, или модель Делоне и Маклина, помогает измерить эффективность, удовлетворенность пользователей и влияние последних при оценке ресурсов электронного обучения. Широко используется для измерения общего успеха образовательных технологий [12].

Модель «Quality Matters» (QM) – широко используемый инструмент для оценки качества онлайн-курсов. Включает дизайн курса, цели обучения, учебные материалы и методы оценки [13]. Работу [14] также можно включить в перечень исследований, проводимых по оценке интерактивности электронных образовательных ресурсов и эффективности образовательных результатов. В данной работе изучалось влияние интерактивности на удовлетворенность и успеваемость учащихся. Интерактивные курсы электронного обучения получили высокую оценку студентов.

Результаты указанных исследований и моделей оценки важны для эффективной оценки и улучшения ресурсов электронного обучения. Их можно использовать для развития инфраструктуры электронного обучения и повышения удовлетворенности пользователей.

## III. Методика оценки

В исследовании, проведенном Вольфрамом Хардтом и Уранчимегом Тудевдагвой [15], была предложена модель SURE (структурно-ориентированная оценка) для оценки ресурсов электронного обучения. Она обеспечивает детальную основу для оценки качества курсов электронного обучения, уделяя особое внимание их компонентам. Модель дает возможность разработать содержание электронных образовательных ресурсов, определить стратегию обучения, а также установить, совместимы ли образовательные цели и задачи курса с пользовательским интерфейсом.

Структурно-ориентированная оценка позволяет проводить систематическую оценку курсов электронного обучения, что помогает выявить сильные и слабые стороны дизайна курса. Этот подход необходим для постоянного улучшения ресурсов электронного обучения и обеспечения их соответствия желаемым стандартам качества.

Процесс применения модели SURE осуществляется в следующие этапы:

- этап 1 – определение основных целей оценки;
- этап 2 – формирование подцелей для достижения основных целей;
- этап 3 – выбор метода оценки;
- этап 4 – сбор данных;
- этап 5 – обработка данных;
- этап 6 – сделать вывод на основании полученных результатов.

Как отмечено в [15], процесс обработки данных осуществляется по следующей формуле, основанной на правилах расчета модели SURE:

$$Q_e^*(C) = \frac{1}{n} \sum_{k=1}^n Q_e^{*(k)}(C) = \frac{1}{n} \sum_{k=1}^n \left( \prod_{i=1}^r \left( 1 - \sqrt[s_i]{\prod_{j=1}^{s_j} (1 - q_{ij}^{*(k)})} \right) \right). \quad (1)$$

Результаты формулы (1) помогают оценить показатели качества электронных образовательных ресурсов.

#### IV. Эксперимент


Практическое применение указанных методов оценивания мы проводили в Самаркандском филиале Ташкентского университета информационных технологий имени Мухаммада аль-Хорезми. Целью было оценить качество электронных образовательных ресурсов, подготовленных для студентов, обучающихся в филиале по форме «Дистанционное образование». В табл. 1 перечислены цели и подцели.

Таблица 1

Цели оценки

Основная цель	Содержание	Частичные цели	Содержание
$B_1$	Определить общую информацию об электронных учебных ресурсах	$A_{11}$	Определение простоты использования ресурсов электронного обучения
		$A_{12}$	Техническое качество ресурсов электронного обучения (скорость, простота использования, дизайн интерфейса)
		$A_{13}$	Содержание электронных образовательных ресурсов (полнота и достоверность информации)
$B_2$	Интерактивность и образовательный процесс	$A_{21}$	Интерактивность ресурсов электронного обучения (видео, тесты, дискуссионные форумы)
		$A_{22}$	Наличие электронных учебных ресурсов для общения с преподавателями
		$A_{23}$	Доступность ресурсов электронного обучения для однорангового общения
$B_3$	Уровень удовлетворенности	$A_{31}$	Общая удовлетворенность ресурсами электронного обучения
		$A_{32}$	Эффективность электронных образовательных ресурсов в процессе обучения

Модель SURE, построенная на основе этих целей, представлена на рисунке.



Структура оценки на основе поставленных целей

В табл. 2 приведены примеры результатов оценки курсов электронного обучения, разработанных на весенний семестр 2023–2024 учебного года для студентов, обучающихся в форме дистанционного обучения. Все собранные данные были оценены с использованием онлайн-инструмента модели SURE [16].

Анкета, раздававшаяся студентам, была адаптирована к логической структуре, изображенной на рисунке. В опросе приняли участие 75 человек. Для всех подцелей интервал оценки основывался на наборе  $\{0, 1, \dots, 5\}$ . При этом часть со значением 5 означает, что цель достигнута полностью, а значение 0 – что часть цели не выполнена. В последней строке табл. 2 указаны приблизительные значения, рассчитанные по формуле (1).

Данные и результаты для оценки

k	B1			B2			B3		$Q_e^*(C)$
	A11	A12	A13	A21	A22	A23	A31	A33	
1	0.4	0.6	0.4	0.8	0.4	1	0	0.4	0.48
2	1	0.2	0.2	0.2	0.4	0.8	0.4	0.6	0.65
3	0.4	0.4	0.4	0.2	0.4	0.4	0.4	0.4	0.38
4	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8
5	1	0.8	0.8	0.8	1	0.8	0.8	0.6	0.9
6	1	0.6	0.8	0.8	0.8	0.8	0.8	0.6	0.83
7	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8
8	1	1	1	1	1	1	1	1	1
9	1	0.8	0.8	1	1	1	1	1	1
10	1	0.8	0.8	1	1	1	1	1	1
11	1	1	1	1	1	1	1	1	1
...	...	...	...	...	...	...	...	...	...
15	0.6	0.4	0.8	0.6	0.6	0.8	0.6	0.8	0.68
16	1	1	1	1	1	1	1	1	1
...	...	...	...	...	...	...	...	...	...
70	0.8	0.6	0.6	0.6	0.8	1	0.6	0.6	0.74
71	1	1	1	0.8	1	1	0.6	0.8	0.9
72	1	1	1	1	1	1	1	1	1
73	1	1	1	0.8	0.8	1	1	0.8	1
74	1	1	1	1	1	1	1	1	1
75	0.4	0.6	0.6	0.6	0.8	0.8	0.4	0.6	0.59
$Q^*(A_{ij})$	0.89	0.86	0.87	0.87	0.89	0.9	0.87	0.85	$Q_e^*(C) = 0.885$
$Q_e^*(B_i)$	0.89			0.91			0.87		-

Всего на курсах дистанционного обучения в весеннем семестре II курса приняли участие 107 студентов. Оценочная анкета рассылается всем студентам, обучающимся на дистанционных курсах обучения. Однако количество людей, ответивших на оценочные вопросы, составило 75 ( $\approx 70\%$ ).

### V. Заключение

Во многих исследованиях обсуждалась проблема «электронных ресурсов в высшем образовании» и то, что они могут сделать для высших учебных заведений. В частности, вопросы качества и эффективности образования, увеличения доступа пользователей к электронным ресурсам, повышения удобства и гибкости являются поводом для проведения научных исследований.

Таким образом, результаты, полученные на основе выборочного объема собранных данных, не представлены как мнение всех пользователей. Если обратить внимание на результаты, то шесть студентов (четыре –  $<0,4$  и два –  $<0,6$ ) оценили курсы электронного обучения как неудовлетворительные. Этот показатель также очень мал по сравнению с количеством студентов, принявших участие в оценивании (8,0%).

При этом оценочные баллы показали, что уровень электронных курсов по частичному разделу составляет  $Q^*(A_{ij}) > 0,8 >$  для каждой частичной цели, а  $Q_e^*(B_i) > 0,85$  по основному разделу цели.

Развитие навыков и компетенций, подходящих и необходимых для реформ цифровизации современного общества, в частности обеспечение пользователей навыками цифровой грамотности, необходимыми в их деятельности, требует специальных исследований.

#### Библиографический список

1. *Anderson T., Elloumi F.* Theory and Practice of Online Learning. Athabasca University, 2004.
2. *Bates A. W.* Teaching in a Digital Age: Guidelines for designing teaching and learning. BCcampus, 2015.
3. *Siemens G.* *Connectivism: A learning theory for the digital age* // International Journal of Instructional Technology and Distance Learning. 2005.
4. *Arbaugh J. B., Benbunan-Fich R.* The importance of participant interaction in online environments // Decision Support Systems. 2007. № 43(3). P.853–865.
5. *Garrison D. R., Vaughan N. D.* Blended Learning in Higher Education: Framework, Principles, and Guidelines. Jossey-Bass, 2008.
6. *Graham C. R.* *Blended learning systems: Definition, current trends, and future directions* // The Handbook of Blended Learning / C. J. Bonk, C. R. Graham (Eds.). San Francisco: Pfeiffer, 2006.
7. *Davis F. D.* (1989). Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology // MIS Quarterly. 1989. № 13(3). P. 319–340.
8. *Charness N., Boot W. R.* Handbook of the Psychology of Aging, Book: Chapter 20. Technology, Gaming, and Social Networking, Elsevier, 2016.
9. What drives a successful e-Learning? An empirical investigation of the critical factors influencing learner satisfaction / P. C. Sun, R. J. Tsai, G. Finger [et al.] // Computers & Education. 2008. № 50(4). P. 1183–1202.
10. *Kirkpatrick D. L.* Evaluating Training Programs: The Four Levels. San Francisco: Berrett-Koehler. 1996.
11. *Swan K.* Virtual Interaction: Design Factors Affecting Student Satisfaction and Perceived Learning in Asynchronous Online Courses // Distance Education. 2001. № 22(2). P. 306–331.
12. *DeLone W. H., McLean E. R.* (2003). The DeLone and McLean Model of Information Systems Success: A Ten-Year Update // Journal of Management Information Systems. 2003. № 19(4). P. 9–30.
13. *Shattuck K.* Quality Matters: A Process for Continuous Improvement of Online Courses // Online Learning: Common Misconceptions, Benefits, and Challenges / P. R. Lowenthal, C. S. York, J. C. Richardson (eds.). 2015. P. 111–131.
14. *Arbaugh J. B.* Virtual Classroom Characteristics and Student Satisfaction with Internet-Based MBA Courses // Journal of Management Education. 2000. № 24(1). P. 32–54.
15. *Hardt W., Tudevtagva U.* Quality evaluation of e-learning courses using the SURE model // Global Engineering Education Conference (EDUCON), 2013 IEEE.
16. *Tudevtagva U.* Education. URL: <https://uranchimeg.com/sure/eva.php> (дата обращения: 28.07.2024).

*М. В. Величко\**

старший преподаватель

*Т. А. Бобович\**

ассистент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В ОБРАЗОВАНИИ: РОЛЬ ЧАТ-БОТОВ

Рассмотрена роль чат-ботов в системе образования. Выделены как положительные, так и отрицательные стороны использования искусственного интеллекта в процессе обучения. Сформирован список задач, выполняемых ботами в образовательной деятельности.

**Ключевые слова:** искусственный интеллект (ИИ), чат-бот, образование.

*M. V. Velichko\**

Senior Lecturer

*T. A. Bobovich\**

Assistant

\*St. Petersburg State University of Aerospace Instrumentation

## ARTIFICIAL INTELLIGENCE IN EDUCATION: THE ROLE OF CHATBOTS

This article discusses the role of chatbots in the education system. Both positive and negative aspects of using artificial intelligence in the learning process are highlighted. A list of tasks performed by bots in educational activities has been generated.

**Keywords:** artificial intelligence (AI), chatbot.

Характерная особенность современной образовательной политики Российской Федерации – достижение целей учебного процесса с учетом не только специфических черт обучаемого поколения, но и тенденций научно-технического прогресса. В июне 2018 г. президиумом Совета при Президенте Российской Федерации по стратегическому развитию и национальным проектам был утвержден паспорт проекта «Национальная программа „Цифровая экономика Российской Федерации“». Одно из направлений данной программы – проект «Кадры для цифровой экономики», цель которого состоит в подготовке высококвалифицированного персонала для работы в современных условиях рынка. Реализация данного проекта возможна при корреляции процесса цифровизации и образования.

Внедрение цифровых технологий в современный образовательный процесс требует существенных изменений в функционировании образовательной отрасли в целом. Все больше образовательных учреждений, внедряющих цифровизацию в свою непосредственную деятельность, выделяют такие положительные аспекты использования ИИ, как: сокращение издержек, оптимизация использования имеющихся ресурсов, создание новых возможностей и перспектив, систематизация и анализ результатов деятельности. Один из способов применения ИИ в образовании – чат-боты [1].

Чат-боты представляют собой программу, имитирующую общение с живым человеком в режиме реального времени. Чат-боты имеют различную классификацию: по алгоритму работы выделяют ограниченные и саморазвивающиеся, по виду – кнопочные и текстовые, по функциональному наполнению – коммуникативные и функциональные. Чат-боты с искусственным интеллектом созданы на основе технологии, которая называется разговорным или диалоговым ИИ. К ним относятся не только «умные» чат-боты, но и голосовые помощники, такие как Алиса от Яндекса или семейство виртуальных ассистентов «Салют» от Сбера. Рассмотрим обобщенную схему алгоритма работы чат-ботов (рисунок).

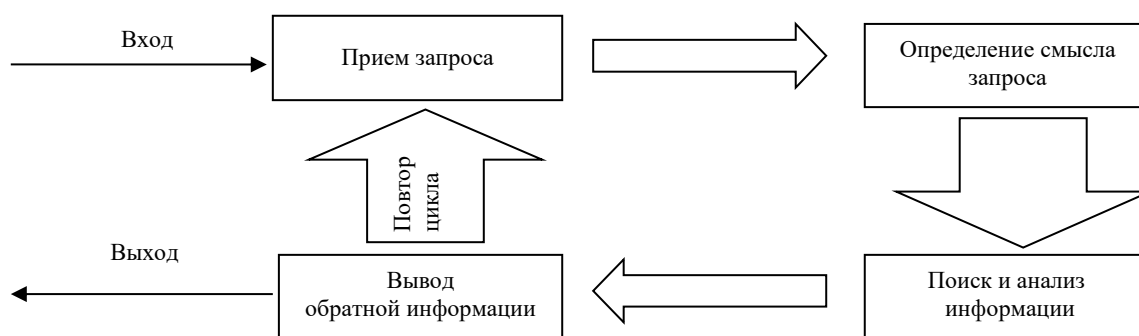


Схема алгоритма работы чат-бота



Опираясь на данные рисунка, сделаем вывод, что унифицированная схема работы чат-ботов представляет собой замкнутый цикл из четырех основных блоков, а именно: прием запроса (в данном блоке бот получает информацию от пользователя), затем следует процесс определения смысла запроса, далее – поиск, сбор и анализ запрашиваемой информации, заключительным этапом является вывод обратной информации для пользователя. Цикл может быть повторен многократно.

В зависимости от области применения и способов общения с пользователями у чат-ботов появляются новые функции и возможности. Изначально чат-боты создавались как способ общения между человеком и ботом, замещающим оператора и отвечающим на вопросы в соответствии с заложенными шаблонами. Выделяется ряд очевидных преимуществ при использовании чат-ботов с ИИ, а именно: обученные чат-боты способны понимать разговорный язык, что впоследствии позволяет интегрироваться и общаться с пользователем максимально естественно; при общении чат-бот способен поддерживать определенные темы на протяжении всей беседы, а не хаотично общаться заученными фразами; самообучение бота способствует улучшению его работы.

При применении бота в образовательном процессе ответом на запрос не всегда является текст, бот может выполнить определенное действие, например предоставить аудиальный или визуальный контент, внести изменения в календарь пользователя, запланировать встречу, поставить будильник или запустить таймер. К преимуществам использования чат-ботов в образовательной деятельности относятся:

- круглосуточная служба поддержки обучающихся, преподавателей и абитуриентов;
- облегченный процесс сбора и анализа информации;
- помощь преподавателям (подготовка материалов к занятиям, составление тестов, вопросов (при определенной настройке бота они могут быть полностью индивидуальны для каждого студента), контроль за успеваемостью, анализ успеваемости каждого студента и выстраивание индивидуальной траектории обучения) [2];
- возможность общения на любых языках (упрощенный процесс обучения иностранных студентов, помощь в изучении иностранных языков студентами);
- сбор обратной связи от студентов.
- поддержка вовлеченности студентов в процесс обучения (применение игрового подхода, таблицы рейтингов с наградами);
- помощь студентам в подготовке к занятиям (помощь в поиске материалов, объяснение сложных тем и подсказки при выполнении заданий) [3].

Существует ряд недостатков использования чат-ботов в образовательном процессе, к ним относят понижение уровня безопасности данных (чат-боты должны быть разработаны с учетом строгих мер по обеспечению конфиденциальности и безопасности, чтобы защитить информацию), возможность неверного толкования запроса пользователя, поддержка точности и актуальности предоставляемых данных (из-за некачественных, устаревших данных и/или неполных информационных ресурсов для обучения модель может придумать то, чего не существует, и ввести в заблуждение, однако данный недостаток нивелируется с помощью регулярного дообучения чат-бота) [4].

Обозначим преимущества использования чат-ботов в процессе обучения. В образовательных организациях внедрение чат-ботов с искусственным интеллектом помогает оптимизировать работу на сайте учреждения, быстрее и точнее направлять пользователя на искомые страницы. Также немаловажной является помощь ботов педагогам и преподавателям в подготовке к занятиям, составлении лекционного, семинарского и тестового материала. Применение искусственного интеллекта позволяет в короткие сроки создавать индивидуальные варианты заданий для каждого обучаемого, принимая во внимание траекторию развития студента [5]. Использование современных технологий также способствует увеличению вовлеченности студентов в процесс обучения такими способами, как: ускоренный поиск и анализ информации, круглосуточный и удаленный доступ к необходимым материалам, легкость коммуникации.

В настоящее время чат-боты становятся нормой в выстраивании учебных процессов, дистанционное обучение только ускорило этот процесс [6]. Они не могут заменить общение с реальным человеком, но способны снять часть рутины с преподавателей, студентов и административного персонала. Из этого можно сделать выводы о хороших перспективах применения чат-ботов в образовании.

### Библиографический список

1. Использование чат-ботов в образовательном процессе / А. С. Аристова, Ю. С. Безносюк, П. К. Ведикер, Н. Е. Воронович // *Цифровая трансформация общества, экономики, менеджмента и образования: II Междунар. конф.* Екатеринбург, 2020. С. 95–99.
2. AI в обучении: на что способны технологии уже сейчас? // Сбер университет. URL: [https://lib.tsu.ru/sp/assets/users/\\_smirnov/EduTech\\_49\\_web.pdf](https://lib.tsu.ru/sp/assets/users/_smirnov/EduTech_49_web.pdf) (дата обращения: 20.06.2024).
3. Язецкий Е. Ю. Чат-бот как средство сопровождения образовательного процесса // *Молодой ученый*. 2021. № 17(359). С. 17–20.
4. Вартанова К. С., Тинькова Е. В. Перспективы и проблемы использования искусственного интеллекта в образовании // *Актуальные вопросы развития современного общества: сб. науч. ст. 12-й Всерос. науч.-практ. конф.*, Курск, 21–22 апр. 2022 г. Курск: Юго-Запад. гос. ун-т, 2022. С. 119–122.
5. Considerations for adapting higher education technology courses for AI large language models: A critical review of the impact of ChatGP / Т. Omar, Н. Ali, К. Khaled [et al.] // *Machine Learning with Applications*. URL: <https://doi.org/10.1016/j.mlwa.2023.100513> (дата обращения: 20.06.2024).
6. Kooli C. Chatbots in Education and Research: A Critical Examination of Ethical Implications and Solutions // *Sustainability* 15. № 7:5614. URL: <https://www.mdpi.com/20711050/15/7/5614#B2-sustainability-15-05614> (дата обращения: 20.06.2024).

*М. В. Величко\**

старший преподаватель

*Т. А. Бобович\**

ассистент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## СРАВНЕНИЕ ЭФФЕКТИВНОСТИ ОБУЧЕНИЯ С УЧАСТИЕМ ГЕНЕРАТИВНОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И БЕЗ НЕГО

Рассматриваются особенности применения генеративного искусственного интеллекта (ГИИ) в образовании. Проводится сравнительная оценка эффективности применения ГИИ в образовании и без него.

**Ключевые слова:** генеративный искусственный интеллект, образовательная деятельность.

*M. V. Velichko\**

Senior Lecturer

*T. A. Bobovich\**

Assistant

\*St. Petersburg State University of Aerospace Instrumentation

## COMPARING THE EFFECTIVENESS OF TRAINING WITH AND WITHOUT GENERATIVE ARTIFICIAL INTELLIGENCE

The article discusses the features of using generative artificial intelligence in education. A comparative assessment of the effectiveness of using GAI in education and without it is carried out.

**Keywords:** generative artificial intelligence, educational activities.

Внедрение технологий с применением генеративного искусственного интеллекта в корне меняет принципы образования. Передовые технологии делают образовательный процесс более наукоемким и человекоцентричным. Одна из самых перспективных и инновационных технологий – генеративный искусственный интеллект (далее ГИИ). Цифровые инструменты на его базе стали такой же частью нашей жизни, как смартфоны или интернет.

От остальных вариантов искусственного интеллекта генеративный отличает возможность создавать новые данные, а не только анализировать имеющиеся. Процесс обучения генеративной модели можно описать следующим образом: из любой области собирается большой массив данных (например, миллионы изображений, предложений, звуков и т. д.), а затем по ним модель учится создавать аналогичные данные самостоятельно.

ГИИ способен создавать новый контент в виде текста, изображений, звука, который на первый взгляд может показаться человеческим [1]. Возможности ГИИ практически безграничны, что заставляет задуматься о проблемах социального, этического, правового характера.

Самыми популярными иностранными системами с ГИИ на данный момент являются:

– GPT – языковая модель для генерации текстов, ведения диалогов, ответов на вопросы, анализа данных и прогнозирования на основе данных от OpenAI;

– BERT – модель для обработки естественного языка с целью анализа текста и понимания его смысла, может применяться для задач классификации, генерации текстов от Google;

– DALL-E от OpenAI для создания изображений на основе текстового описания;

– Midjourney – создает изображения на основе текстового описания.

Из российских систем популярны:

– YandexGPT – может создавать текст на основе запроса от Yandex;

– GigaChat – мультимодальная модель, отвечает на вопросы, ведет диалог, пишет код, придумывает планы презентаций, сочиняет стихи, создает школьные эссе и другие текстовые задачи. Программа отвечает как на русском, так и на английском языках;

– Kandinsky – генеративная нейронная сеть для создания картинок на основе текстового запроса (промта), способная создавать изображения не только на основании промта, но и путем соединения изображения с текстом от Сбер.

Отличительной чертой и существенным плюсом российских сетей последнего поколения оказывается хорошее понимание русского языка с его лексическими особенностями [2].

Симбиоз ГИИ и человека открывает широкие возможности совместного обучения человека и ИИ для перспективы в дальнейшем работать над любыми проектами, позволяющими выходить за формальные рамки и принимать нестандартные решения человеком с помощью обработки огромных потоков данных ИИ.

Способность создавать что-то новое на основе имеющихся данных применяется в различных сферах деятельности человека, в том числе в образовании. Благодаря применению ИИ, по опросам IPSOS<sup>1</sup>, сферу образования ожидают значимые трансформации [3]. Достижения в области ГИИ модифицируют существующие образовательные практики, позволяют увеличить производительность труда преподавателей, автоматизируя рутинные задачи и оставляя больше времени для творческих задач.

Как и у любой технологии, у ГИИ есть достоинства и недостатки. Внедрение ГИИ в образовательный процесс несет определенные риски, связанные с увеличением разрыва между классическим и основанным на применении ГИИ подходами в образовании. Большой интерес для исследований как российских [4], так и зарубежных [5] ученых представляет применение и перспектива влияния ГИИ на образование. Отмечается как положительное, так и отрицательное влияние современных цифровых технологий на организацию учебного процесса, приводится пример сокращения трудозатрат для подготовки материалов для экзамена в два раза [6]. В другом исследовании говорится, что общее время, затраченное на подготовку материалов к занятию, составило всего 2–3 часа, включая генерацию и проверку запросов, добавление субтитров, просмотр и организацию контента [7].

Отмечается положительное влияние технологии на науку благодаря обработке больших массивов данных с возможностью обобщения и выводов, работе с текстами (позволяет улучшить понятность и читабельность). В исследованиях отмечаются не только преимущества использования ГИИ, но и новые риски и трудности. Есть опасения в потенциально неправильном использовании сгенерированной информации [8]. Руководствуясь этими опасениями, в некоторых странах стали запрещать применение ГИИ в образовательных целях [9]. Самое большое опасение вызывает рост доли имитационных процессов в образовании, когда работы генерируются с помощью ГИИ и это приводит к фальсификации и затрудняет формирование необходимого уровня знаний. В исследованиях говорится, что ChatGPT может обойти обычные инструменты обнаружения плагиата [10]. Немаловажно помнить, что модели очень зависимы от данных, на которых они обучаются. Они весьма компетентны в узких областях, но слабо отличают недостоверную информацию. Они могут совершенно убедительно выдавать несуществующую информацию, т. е. могут лгать. Например, ChatGPT попросили составить список книг и статей в документе, над которым работали. ChatGPT придумал статью с полными библиографическими данными, которая не существует, и включил ее в список [11].

Современный темп жизни и особенности восприятия информации новым поколением заставляют искать новые подходы в образовании. На рынке труда все больше возникает потребность в специалистах, знающих не только базовые основы профессии, но и умеющих креативно мыслить, решать нестандартные задачи, готовых отдавать решение рутинных задач ИИ [12]. При всех рисках и спорных моментах применения ГИИ положительно влияет на образовательный процесс, позволяет существенно сократить время на рутинные задачи, дополнить классические подходы в образовании современными инструментами, тем самым увеличивая вовлеченность студентов в образовательный процесс, делать образование максимально индивидуальным [13]. Появилась потребность в создании нового вида грамотности – ИИ-грамотности, о внедрении которой сейчас говорят в сфере образования. В связи с этим возникает потребность в формировании новых компетенций, а академические практики оценки и правила нуждаются в обновлении.

### Библиографический список

1. *Alshater M.* Exploring the role of artificial intelligence in enhancing academic performance: A case study of ChatGPT. 2022. P. 28–37.
2. *Zhai X.* ChatGPT User Experience: Implications for Education // SSRN. 2022. URL: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=4337484](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4337484) (дата обращения: 27.06.2024).
3. *Фишер Д. В., Бурмистров А. Н.* Использование искусственного интеллекта в системе образования // Неделя науки СПбПУ: матер. науч. конф. с междунар. участием, СПб., 14–19 нояб. 2016 г. Ч. 2. СПб.: С.-Петербург. политехн. ун-т Петра Великого, 2016. С. 370–372.
4. *Куликов А. А.* Влияние искусственного интеллекта на образование и общество // Россия молодая: сб. матер. XII Всерос. науч.-практ. конф. молодых ученых с междунар. участием, Кемерово, 21–24 апр. 2020 г. Кемерово: Кузбас. гос. техн. ун-т им. Т. Ф. Горбачева, 2020. С. 63114.1–63114.4.
5. *Вартанова К. С., Тинькова Е. В.* Перспективы и проблемы использования искусственного интеллекта в образовании // Актуальные вопросы развития современного общества: сб. науч. ст. 12-й Всерос. науч.-практ. конф., Курск, 21–22 апр. 2022 г. Курск: Юго-Зап. гос. ун-т, 2022. С. 119–122.
6. *Аристова Е. В.* Использование искусственного интеллекта в образовании // Вузовская наука в современных условиях: сб. матер. 57-й науч.-техн. конф., Ульяновск, 23–28 янв. 2023 года. Ч. 1. Ульяновск: Ульян. гос. техн. ун-т, 2023. С. 281–283.
7. *Маматова Г. Д.* К вопросу о роли цифровых технологий в совершенствовании высшего образования Республики Узбекистан // Современные проблемы социально-экономических систем в условиях глобализации: сб. науч. тр. ХУ Междунар. науч.-практ. конф., Белгород, 21 окт. 2021 г. / под науч. ред. Е. Н. Камышанченко, Ю. Л. Растопчиной, А. А. Швецово. Белгород: Эпицентр, 2021. С. 239–243.

<sup>1</sup> Ipsos Group S.A. (Institut Public de Sondage d'Opinion Secteur) – многонациональная маркетинговая исследовательская и консалтинговая фирма.

8. Preparing for AI-enhanced education: Conceptualizing and empirically examining teachers' AI readiness / W. Xinghua, L. Linlin, T. Seng Chee [et al.] // *Computers in Human Behavior*. 2023. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0747563223001498?via%3> (дата обращения: 26.08.2024).
9. Considerations for adapting higher education technology courses for AI large language models: Acritical review of the impact of ChatGPT / T. Omar, H. Ali, K. Khaled [et al.] // *Machine Learning with Applications*. 2024. URL: <https://www.sciencedirect.com/science/article/pii/S266682702300066X?via%3Dihub> (дата обращения: 26.08.2024).
10. *Baidoo A. D., Ansah, L.* Education in the era of generative artificial intelligence (AI): understanding the potential benefits of ChatGPT in promoting teaching and learning // *SSRN* (January 25, 2023). URL: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=4337484](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4337484) (дата обращения: 26.08.2024).
11. *Sullivan M., Kelly A., Mc Laughlan P.* ChatGPT in higher education: Considerations for academic integrity and student learning // *Journal of Applied Learning & Teaching*. 2023. Vol. 6(1). P. 1–10.
12. Transformative effects of ChatGPT on modern education: Emerging Era of AI Chatbots / Sukhpal Singh Gill, Minxian Xu, Panos Patros [et al.] // *Internet of Things and Cyber-Physical Systems*. 2023. Vol. 4. P. 19–23.
13. We Asked GPT-3 to Write an Academic Paper about Itself – Then We Tried to Get It Published URL: <https://www.scientificamerican.com/article/we-asked-gpt-3-to-write-an-academic-paper-about-itself-mdash-then-we-tried-to-get-it-published/> (дата обращения: 14.08.2023)

**В. И. Городецкий**

доктор технических наук, профессор  
АО «Эврика», Санкт-Петербург, Россия

## ИСТОЧНИКИ ЗНАНИЙ ДЛЯ ПРИЛОЖЕНИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И ПРОБЛЕМЫ ДОСТУПА К НИМ

Искусственный интеллект понимается как интеллект, проявляемый компьютером. Предлагается типизация источников знаний и проводится краткий анализ доступности знаний, скрытых в каждом из них. При этом доступность знаний рассматривается с двух точек зрения: сложности извлечения знания из источника того или иного типа и сложности применения этих знаний не только для принятия решений, но и в других задачах, например в задачах аргументации предлагаемых решений.

**Ключевые слова:** знания, искусственный интеллект.

**V. I. Gorodetsky**

Dr. Sc., Tech., Professor  
Joint-Stock Company «Eureka», St. Petersburg, Russia

## KNOWLEDGE SOURCES FOR ARTIFICIAL INTELLIGENCE APPLICATIONS AND ACCESS ISSUES

In this paper, artificial intelligence is understood as the intelligence displayed by a computer. The paper proposes a typology of these sources and provides a brief analysis of the availability of knowledge hidden in each of them. The availability of knowledge is considered from two points of view: the difficulties of extracting knowledge from a source of one type or another and the difficulty of applying this knowledge not only for decision-making, but also in other tasks, such as the problems of argumentation of proposed solutions.

**Keywords:** knowledge, artificial intelligence.

### 1. Введение

В данной работе искусственный интеллект (ИИ) понимается как интеллект, проявляемый компьютером. Он сильно отличается от интеллекта человека и других живых систем. Компьютер вычисляет решения на основе данных и знаний, которые заложены в него человеком, и знаний и данных, которые компьютер в состоянии генерировать сам в процессе работы, используя первичный запас знаний и данных, алгоритмы машинного обучения на основе данных и математические модели (цифровые двойники, ЦД) явлений, объектов или процессов реального мира. Алгоритмы компьютерного интеллекта создаются человеком и загружаются им в компьютер, или они поставляются компьютеру как сервисы со стороны инфраструктуры, которая тоже создается человеком. Именно так в данной работе интерпретируется *компьютерный интеллект*, который чаще принято называть *искусственным интеллектом*.

Как правило, ИИ трактуется как наука о получении, представлении и использовании знаний в компьютерных системах [1–3]. Качество знаний, на основе которых «работает» ИИ, их объем и достоверность определяют его возможности. В текущее десятилетие возможности ИИ-приложений существенно выросли, в частности за счет использования данных как источника знаний, за счет появления новых источников знаний и способности компьютерных программ извлекать и использовать эти знания без посредничества человека.

Современный мир ИИ и информационных технологий (ИТ) уже больше десятилетия живет в эпоху больших данных, науки о данных, больших языковых моделей и нейросетевых технологий глубокого обучения. За эти годы заметное развитие получили методы машинного обучения на основе данных, а данные как источник знаний заняли ведущее место среди других источников. Этому способствовало и то, что в этот период появились новые богатые источники данных, например цифровые двойники (ЦД), диффузионные модели, заметно возросли и стали практически безграничными ресурсы данных в Интернете. Если судить по научным публикациям и публикациям в средствах массовой информации, то в мире, включая РФ, ИИ уже достаточно глубоко интегрирован в ИТ и стал стратегической технологией.

Однако подобные мнения представляются достаточно спорными, хотя они и отражают современные тенденции в ИТ. Текущая ситуация в ИИ, особенно в части тенденций, достаточно непростая и неоднозначная. Ощущается недооценка одних направлений в нем и переоценка других. Некоторые предсказания представляются сомнительными. Настораживает также беспрецедентно быстрый рост числа ИИ-специалистов в России и в мире, а также экспертов, формирующих общественное мнение и мнение научного сообщества по современному состоянию и будущему развитию ИИ. По этой причине сейчас очень важно обсудить ориентиры развития теории и практики ИИ, понять, что в современном ИИ является фундаментально важным и перспективным и что таковым не является, что отражает объективные тенденции, а что – субъективные мнения и конъюнктурные интересы. В данной работе такая цель ставится по отношению к источникам знаний, а знания, по своей сути, являются фундаментом компьютерного интеллекта.

В работе предлагается типизация названных источников и проводится краткий анализ доступности знаний, скрытых в каждом из них. При этом доступность знаний рассматривается с двух точек зрения, а именно: а) насколько сложно извлечь знания из источника того или иного типа, например принимая во внимание вычислительную эффективность алгоритмов извлечения знаний; б) насколько сложно эти знания использовать не только для принятия решений, но и в других задачах, например в задачах аргументации предлагаемых решений.

## 2. Данные и знания: можно ли между ними провести границу?

Прежде чем обсуждать источники знаний, их свойства и возможности, следует сначала как-то очертить границы между данными и знаниями, и если они существуют, то определить где заканчиваются данные и где начинаются знания. Этот вопрос не праздный и не новый. Обсуждение этих границ, существа понятий *данные* и *знания*, различий информационных структур, используемых для их представления и различий в когнитивной сложности смысла, который может быть выражен данными, с одной стороны, и знаниями – с другой, было впервые начато в [4]. Ее автор ввел понятие *когнитивной иерархии* на множестве информационных структур, включив в их список понятия *данные*, *информация*, *знания*, *интеллект* и *мудрость* (англ. Data, Information, Knowledge, Intelligence, Wisdom, DIKIW). Эта иерархия (рис. 1) [5] в настоящее время хорошо известна под названием *Пирамида DIKIW*. Автор [4] детально описал свое понимание компонент этой иерархии, но не смог указать четкую границу между данными и знаниями, ограничившись утверждением о том, что она проходит где-то на уровне понятия *информация* пирамиды DIKIW. При этом все понятия, которые в ней выше понятия *информация*, он отнес к знаниям разного уровня когнитивной сложности.



Рис. 1. Пирамида преобразований DIKIW: «данные, информация, знания, интеллект, мудрость» [5]

На заре современной науки о данных вопрос о смысле понятий пирамиды DIKIW и о границе между данными и знаниями в ней был вновь поставлен в международном проекте США *Knowledge Map of Information Science* (*Карта знаний в информационной науке*), который выполнялся в 2003–2005 гг. Однако он не принес ничего нового по сравнению с работой [4]. Например, в трудах [6; 7], которые подводили итоги проекта, дано 130 толкований понятий пирамиды DIKIW, отражавших разные подходы к их определению. Они сформулированы 45 учеными из 16 стран. Вывод проекта состоял в том, что понятия этой пирамиды взаимосвязаны, но эти связи являются дискуссионным, равно как и их смысл. Более позднее толкование понятий этой пирамиды, приведенное, например, в недавней работе по методологии науки о данных [8], не слишком отличается от мнения авторов [6; 7]. Детальный анализ понятий *данные* и *знания*, резюмирующий указанные мнения, можно найти в [9; 10].

Основной вывод всех обозначенных публикаций, важный в контексте темы данной работы, состоит в том, что границу между данными и знаниями указать точно невозможно. Однако это и не так важно, поскольку данные могут напрямую использоваться алгоритмами принятия решений наравне со знаниями. Примерами являются алгоритмы, построенные на основе прецедентов, метода ближайших соседей и ряд других. Кроме того, сырые данные и знания, доступные в источниках, практически всегда подвергаются предварительной обработке до их использования в последующей технологии обучения, и о результате этой обработки не всегда можно судить как о данных или как о знаниях. Например, если источниками знаний являются утверждения экспертов, то они не всегда однозначно относятся к знаниям и всегда должны подвергаться предварительной обработке с целью обнаружения и устранения противоречий, некорректностей и ошибок в сырой экспертной информации. По этим причинам данные и знания следует рассматривать как равноправные с точки зрения их ценности для принятия решений в ИИ-приложениях, а фундаментальный вопрос об источниках знаний для приложений ИИ заменить на аналогичный вопрос об источниках знаний и данных.

В настоящее время в ИИ используются четыре типа источников данных и знаний (рис. 2). Они не дублируют друг друга, каждый имеет свою нишу в многообразии ИИ-приложений и область практического применения. Далее дадим их краткую характеристику.

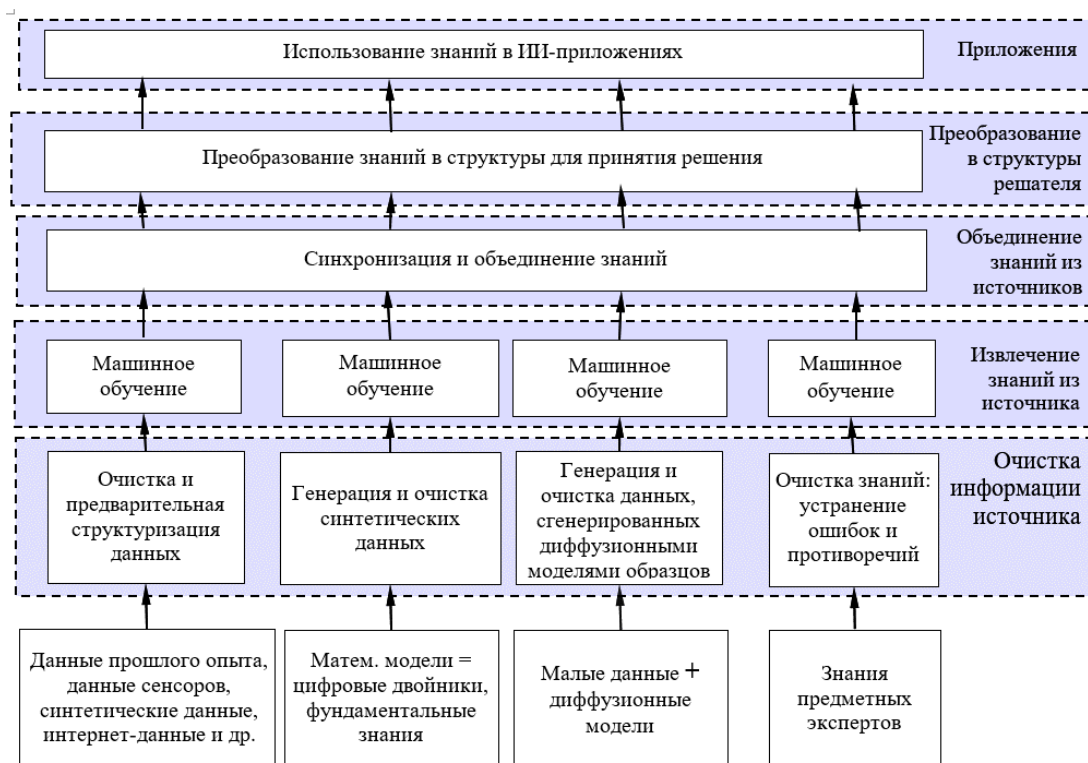


Рис. 2. Типы источников данных и знаний и поток их обработки вплоть до использования доступных знаний и данных в приложениях ИИ

### 3. Большие данные как источник знаний

*Большие данные* как источник знаний сейчас играют ведущую роль среди всех других источников, указанных на рис. 2. Именно они стимулировали развитие *науки о данных*, ставшей теоретическим и методологическим базисом для алгоритмов извлечения знаний, скрытых в больших данных. Методологические принципы науки о данных служат основой для создания алгоритмов доступа к знаниям, скрытым в данных, и их использования в приложениях, что привело к революционному развитию технологий машинного обучения, в частности нейросетевых технологий глубокого обучения и больших языковых моделей, и в итоге – к прорыву ИИ-технологий в ИТ-индустрию. При этом достижения науки о данных оказались важными также и для ряда других типов источников данных и знаний, в частности для ЦД и диффузионных моделей, которые могут использоваться для генерации синтетических данных с последующим их использованием в качестве обучающих данных в алгоритмах машинного обучения. Для того чтобы было понятно, почему большие данные стали основным источником знаний для приложений ИИ и какова в этом роль науки о данных при извлечении знаний их больших данных, сформулируем кратко базовые методологические принципы науки о данных.

1. *Знания формируются на основе данных.* В науке о данных полагается, что данные – это основной вход научного исследования, даже если имеются и другие источники, например экспертные знания о приложении, известные результаты предметной области и т. п. Но в любом варианте данные рассматриваются как основной вход, на который следует полагаться при построении модели данных. При выполнении исследования его ход не является заранее известным или предсказуемым. Стратегия исследований определяется самими данными, именно они и текущие результаты их обработки должны диктовать, что делать на очередном этапе. Данные определяют нужные методы, алгоритмы и модели. «Идеальное исследование – это процесс, который в совершенстве подгоняет друг к другу данные наблюдений, обучаемую модель и результаты, получаемые в ходе исследований. Это совсем не то, что процесс подгонки данных к заданной модели или заданной модели – к данным» [8, с. 81].

2. *Исследование данных проводится без выдвижения гипотез.* Обычно научное исследование, связанное с данными, строится так, что сначала выдвигается некоторая гипотеза, например о независимости атрибутов данных или о типе их распределения. Обычно данные используются для того, чтобы доказать и/или опровергнуть *выдвинутую* гипотезу. В методологии науки о данных никакие гипотезы о свойствах данных априори не выдвигаются. В ней полагается, что источником гипотез могут быть только сами данные, а также априори известные свойства предметной области данных. Данные первичны, и гипотезы об их модели (зависимости и связи в модели данных) должны *строиться* на основе исследования данных.

3. *Обнаружение знаний в данных не опирается на предположения о модели данных.* Процесс обнаружения основывается только на данных, в отличие, например, от методологии обнаружения знаний на основе модели. В науке о данных полагается, что эта модель неизвестна и ее нужно построить. Одна из основных задач при

этом – инжиниринг пространства атрибутов будущей модели. В традиционном подходе структура модели и ее атрибуты задаются, а данные используются для оптимизации значений выбранных атрибутов.

4. *Принятие решений базируется на результатах исследования данных и эмпирическом доказательстве.* Результаты – это гипотезы, модели, новые знания, свидетельства и факты, полученные при работе с данными и на основе данных [8]. Специалист в науке о данных исходит из данных, в отличие от других наук, работающих с данными, например статистики. В них исследователь больше заботится о решении вопросов типа «Какой алгоритм лучше и какой язык выбрать для программирования?» [9], Анализ влияния ошибок на конечный результат – еще одна из базовых задач науки о данных. Специалисты других наук часто опираются на высказывание «мусор на входе – мусор на выходе». Позиция науки о данных в этом вопросе состоит в том, что и с такими данными нужно работать.

Таким образом, большие данные как источник знаний имеют хороший теоретический и методологический фундамент, и этот фундамент продолжает интенсивно развиваться, что отражается в многочисленных научных и технологических публикациях. Более подробные сведения о данных как источнике знаний и о науке о данных как методологическом фундаменте алгоритмов доступа к знаниям, скрытым в данных, можно найти в [8; 10; 11].

#### 4. Цифровые двойники

Цифровым двойником физического объекта, процесса или другого явления называют его цифровую модель, другими словами – компьютерную программу. ЦД строится на основе фундаментальных, обычно предметно независимых знаний некоторой области научных знаний (например, математики, физики, биологии и т. п.) с частичным привлечением предметно-ориентированных знаний, характерных для приложения. ЦД используется обычно для имитационного моделирования конкретных аспектов сущностей физического мира.

Специфика ЦД как источника знаний и данных, выделяющая его в отдельный тип на множестве других источников, состоит в том, что он может быть источником как *процедурных*, так и *декларативных* знаний. Процедурные знания особенно важны в задачах предсказания поведения физической сущности. Процедурные знания, представленные в ЦД, являются основными также при решении задач типа «Что..., если...?», а эти задачи – основа стратегического планирования и предсказательной аналитики. В настоящее время в связи с развитием концепции метавселенной технология ЦД становится еще более востребованной [12], а с другой стороны, концепция ЦД за счет взаимодействия с объектами реального мира может стать еще более богатым источником знаний.

ЦД может также быть источником декларативных знаний, если ее использовать для генерации синтетических данных. Это уникальное свойство ЦД распространяет область применения науки о данных и машинного обучения на основе данных на новые классы приложений, например на те, для которых исторические данные отсутствуют. Примерами являются ЦД уникальных сложных объектов, инновационные проекты и т. п. Следует заметить, что переход от анализа математической модели к анализу данных, полученных с помощью этой модели как метод обнаружения знаний порождает специфическую методологию доступа к знаниям, скрытым в математических моделях. И эта методология имеет достаточно универсальный характер. Ее можно характеризовать термином *датафикация* математической модели, поскольку в ней математическая модель заменяется выборкой данных, полученных с ее помощью. Основное достоинство такого подхода состоит в том, что он трансформирует труднодоступные знания, скрытые в обычно сложной математической модели, в знания, скрытые в данных, доступ к которым значительно проще.

Обратим внимание на то, что ЦД физической сущности, которой еще нет в реальности (в случае разработки нового уникального объекта), – это не то же самое, что ЦД реально существующей сущности. С реально существующего объекта можно «снять» данные его работы, а с несуществующего объекта нельзя. В первом случае первичен объект реального мира, а ЦД строится для анализа новых ситуаций и выявления новых свойств этого объекта. Во втором случае ЦД первичен, и он нужен для разработки объекта.

Оценивая концепцию ЦД как источника знаний и данных, можно заключить, что она имеет зрелый теоретический фундамент, уникальную область применения и эффективный доступ к знаниям и данным, скрытым в математической модели сущности реального мира.

#### 5. Диффузионные модели

Диффузионные модели (ДМ) как средство генерации обучающих данных на основе ограниченной выборки реальных объектов по своей сути, как и ЦД, имеют целью сгенерировать выборку синтетических данных на основе математической модели, но, в отличие от ЦД, в случае ДМ математическая модель физической сущности строится на базе имеющихся примеров, а сгенерированная выборка синтетических данных дополняет малую выборку, на основе которой построена диффузионная модель.

ДМ генерации данных представляется нейронной сетью, которая обучается в архитектуре генеративной сети. С формальной точки зрения итоговая нейросеть задает распределение вероятностей на множестве генерируемых примеров выборки данных, близких к тем, которые использованы для обучения. Обучение этих моделей состоит из двух многошаговых процессов – прямого и обратного. В прямом диффузионном процессе к исходному объекту шаг за шагом добавляется гауссовский шум с различной заранее определенной переменной дисперсией, и в итоге за некоторое число шагов исходный объект преобразуется в гауссовский шум. Затем, при проходе



в обратном направлении, выполняется машинное обучение нейросетевой модели, задающей нужное распределение вероятностей. Эта модель, получая на вход гауссовский шум, генерирует на выходе объект, близкий к тому, который использован на прямом проходе. В этом процессе обучения используются данные прямого прохода.

Этот источник данных имеет теоретическое обоснование, а также алгоритмическую и инструментальную поддержку. Он получил практическое применение в последние несколько лет. В настоящее время ДМ сформировали самостоятельный кластер научных и прикладных исследований. Его теоретической основой являются Большие языковые модели, а ниша прикладных разработок включает генерацию синтетических изображений и аудио, похожих на представленный образец, генерацию изображений по словесному описанию и ряд других случаев использования, которые авторы обычно относят к компьютерному творчеству. Имеется много специализированных программных инструментов для генерации новых объектов, и ведутся активные разработки таких инструментов для работы с гибридными данными. Эта область в настоящее время активно развивается гигантами ИТ- и ИИ-индустрии уровня Google и OpenAI. В РФ это направление развивается компанией «Яндекс», институтом AIRI и рядом других компаний. Достоинство ДУ состоит в том, что они позволяют расширить выборку *малых данных*. В настоящее время ДУ используется на практике для расширения медицинских данных, например медицинских изображений. Но ничто не мешает использовать эту модель и в других приложениях.

Однако ДУ как источник данных обладает и рядом недостатков. Первый из них – вычислительная сложность. Практики утверждают, что для обучения модели, построенной на одном примере, может потребоваться порядка 20 дней достаточно мощного компьютера. Другой недостаток состоит в том, что знания, скрытые в ДУ объектов, недоступны для человека, что характерно для любых нейросетевых моделей. Однако обратим внимание на то, что эти знания теоретически могут быть извлечены из данных, сгенерированы диффузионной моделью. А это создает определенный «мостик» для использования этих данных при обучении систем объяснения решений ИИ-приложений, которые используют знания, скрытые в ДУ.

## 6. Экспертные данные

Экспертные данные до недавнего времени были основным источником знаний для ИИ-приложений. Но около 20 лет тому назад они уступили ведущую роль другим источникам, о которых шла речь ранее. Однако современные тенденции, определяемые новыми классами приложений сегодняшнего дня и ближайшего будущего, свидетельствуют о том, что эксперты вновь могут вернуться в число востребованных источников уникальных знаний для сложных ИИ-приложений.

Большой опыт работы с экспертными данными, накопленный в прежние годы, представлен в специальном разделе ИИ, который принято называть *инженерией знаний* (англ. knowledge engineering) [13]. Экспертные знания действительно обладают большой ценностью и спецификой, которая отсутствует в других источниках. Исследования психологов показали, что экспертам обычно трудно оценивать числовые значения атрибутов, но они могут достаточно уверенно сравнивать их значения в порядковых шкалах типа *легче – тяжелее, лучше – хуже, быстрее – медленнее, сильнее – слабее, более значимый – менее значимый* и т. п. А это уже практически готовые знания. Эксперты способны указывать причинно-следственные отношения между, казалось бы, достаточно отдаленными событиями или свойствами объектов, для которых построить цепочку вывода практически невозможно. Примерами являются экспертные правила, основа экспертных систем принятия решений в недалеком прошлом в течение длительного периода развития ИИ. Часто такие связи и отношения невозможно обнаружить в больших данных даже самыми современными методами машинного обучения.

Экспертные данные обычно представляют собой утверждения об отношениях, и они могут описываться более сложными информационными структурами, чем данные. В сыром виде экспертные данные – это просто множество отдельных суждений различных экспертов, которые невозможно напрямую использовать в базах знаний. Аналогично сырым данным, множество экспертных утверждений содержит ошибки, противоречия и неверные суждения, которые неизбежно появляются по разным причинам. Во-первых, эксперты, принимающие участие в опросе, как правило, имеют различные специализации, обладают разной квалификацией и опытом. Во-вторых, каждое подмножество фрагментов экспертных данных, созданных одним и тем же экспертом, может быть корректным и непротиворечивым, но объединение данных, полученных от разных экспертов, имеющих разные мнения об одном и том же, может содержать много противоречий. В-третьих, эксперты обладают известными ограничениями по восприятию и формулировке связей и зависимостей. Например, они неспособны оценивать зависимости между более чем тремя атрибутами и потому ошибаются. Другой пример, приведенный Т. Сати в [14], говорит о том, что человеку психологически трудно провести корректно парные сравнения в порядковой шкале для более чем семи атрибутов. Но реально размерности и сложность пространств экспертных данных всегда много больше тех, с которыми способен работать человек. По этим и другим причинам сырые экспертные данные требуют обработки для устранения противоречий и ошибок, которые практически всегда и в большом количестве содержатся в экспертных данных.

К сожалению, инженерия знаний в настоящее время не предлагает методов и алгоритмов решения упомянутых и ряда других задач предварительной обработки экспертных данных. Как показывает практический опыт, среди задач обработки сырых экспертных данных можно выделить, по крайней мере, три типовые задачи, кратко характеризуемые далее [15].

А. *Оценка связей между атрибутами пространства экспертных данных.* В любой системе различные факторы, определяющие состояние и поведение системы, обычно взаимосвязаны, и реальная размерность факторного пространства всегда значительно меньше общего числа факторов. Эти связи представляют важный тип знаний, который не может быть обнаружен, если их оценки в какой-то форме и хотя бы частично не отражены в экспертных данных. Именно здесь эксперты высказывают разные, как правило противоречивые, мнения. Обычно для описания связей используются когнитивные модели, например когнитивные карты [16]. Однако эта модель не определена формально, и потому в ней отсутствуют какие-либо модели формальной проверки их корректности.

Б. *Формальное описание весов (важности) различных координат пространства экспертных данных.* Пространством экспертных данных здесь называется пространство атрибутов экспертных данных, описывающих утверждения экспертов о различных свойствах объектов, явлений, событий или процессов предметной области. Например, в задачах оценки напряженности региональных конфликтов имеются такие измерения, как экономические противоречия, политические противоречия, религиозные и другие противоречия конфликтующих сторон. Оценка важности каждого аспекта конфликта при оценке напряженности конфликта в целом – это пример прикладной задачи того типа, о которой здесь идет речь. Обычно для решения таких задач используются различные подходы и приемы, развитые в теории многокритериального выбора. Среди них чаще других используется теоретически обоснованный и проверенный на обширной практике метод анализа иерархий [14]. Этот метод широко известен, в особенности специалистам теории систем. Однако современные программные инструменты, реализующие его, не в состоянии анализировать согласованность элементов матрицы парных сравнений большой размерности, и потому требуется существенное развитие его алгоритмической реализации с встроенной проверкой непротиворечивости экспертной матрицы парных сравнений.

В. *Субъективные вероятностные оценки.* Одна из форм экспертных знаний в моделях с неопределенностью – это субъективные оценки вероятностей тех или иных событий, случайных величин, их вероятностных зависимостей, аналогичных зависимостей на множестве правил и т. п. Собственная практика автора показала, что подходящей формальной моделью описания экспертных знаний такого типа может быть вероятностная модель с интервальной вероятностной мерой [17; 18]. Однако эта формальная модель пока не готова к практическому использованию и требует существенного развития как в части алгоритмической базы, так и в части инструментальной поддержки при больших размерностях пространства экспертных данных.

Резюмируя описание существа, формальной основы и возможностей практического использования экспертных данных в качестве источника знаний для приложений ИИ, следует отметить, что этот источник имеет специфическую область применения и потому не дублирует источники других типов. Знания, скрытые в экспертных данных, теоретически легко доступны, но к настоящему времени алгоритмический базис для доступа к ним пока не готов для практического использования.

### Заключение

Систематизация и анализ свойств источников знаний и данных для приложений ИИ представляется важной и актуальной проблемой, поскольку именно знания, используемые компьютерным интеллектом, определяют его возможности по спектру решаемых задач и их сложности, а также качество их решения. В данной работе проведен сравнительный анализ типовых источников знаний и данных, имеющихся в настоящее время, а также возможностей по доступу к знаниям, скрытым в источниках разных типов.

На концептуальном уровне про знания, получаемые из названных источников, нельзя в общем случае сказать, что они чем-то отличаются друг от друга, что знания, полученные из некоторого источника, в чем-то более предпочтительны по сравнению со знаниями из других источников. Поэтому в задачах, которые могут использовать несколько источников знаний и данных, актуальной становится проблема оценки качества знаний с помощью формальных метрик с понятной семантикой. Проблема использования знаний из нескольких источников (эта возможность отражена на рис. 2) хорошо известна как проблема *слияния знаний* (англ. knowledge fusion). Это сложная проблема, и она ставит много новых вопросов. И первый вопрос о корректной форме совместного использования знаний разных источников, в частности вопрос о том, как принимать во внимание различие в качестве знаний, если даже метрики оценки качества заданы в единой шкале и вычислимы. Знания, полученные из разных источников, могут быть, грубо говоря, или «об одном и том же», или «совсем о разном», или иметь общую часть. Но как это определить формально и какими могут быть стратегия и алгоритм слияния знаний в каждом случае?

Вообще говоря, проблема слияния знаний активно исследуется в ИИ уже более 25 лет. Однако появление принципиально различных источников знаний, которые обсуждались ранее, ставит много новых проблем. И они формируют важную часть общей повестки научных исследований в области ИИ.

### Библиографический список

1. Очерки истории информатики в России / ред.-сост. Д. А. Поспелов, Я. И. Фет. Науч.-изд. центр ОИГТМ СО РАН 1998. 663 с.
2. Augier M., Vendelo M. T. An Interview with Edward A. Feigenbaum, 2002. URL: [https://www.researchgate.net/publication/236904576\\_An\\_Interview\\_with\\_Edward\\_A\\_Feigenbaum](https://www.researchgate.net/publication/236904576_An_Interview_with_Edward_A_Feigenbaum) (дата обращения: 01.09.2024).

3. *Городецкий В. И., Юсупов Р. М.* Искусственный интеллект: Метафора, наука и информационная технология // Мехатроника, автоматизация, управление. 2020. Т. 21, № 5. С. 282–293.
4. *Ackoff R.* From data to wisdom // Journal of Applied Systems Analysis. 1989. № 16. P. 3–9. URL: <http://www-public.imtbs-tsp.eu/~gibson/Teaching/Teaching-ReadingMaterial/Ackoff89.pdf> (дата обращения: 01.09.2024).
5. *Dikw pyramid* // Википедия. URL: [https://en.wikipedia.org/wiki/DIKW\\_Pyramid](https://en.wikipedia.org/wiki/DIKW_Pyramid) (дата обращения: 01.09.2024).
6. *Zins C.* Conceptual Approaches for Defining Data, Information, and Knowledge // Journal of the American Society for Information Science and Technology. 2007. № 58(4). P. 479–493. URL: [http://www.success.co.il/is/zins\\_definitions\\_dik.pdf](http://www.success.co.il/is/zins_definitions_dik.pdf) (дата обращения: 01.09.2024).
7. *Rowley J.* The wisdom hierarchy: representations of the DIKW hierarchy // Journal of Information and Communication Science. 2007. № 33(2). P. 163–180. URL: <http://web.dfc.unibo.it/buzzetti/IUcorso2007-08/mdidattici/rowleydikw.pdf> (дата обращения: 01.09.2024).
8. *Cao L.* Data Science Thinking. The Next Scientific, Technological and Economic Revolution. International Publishing AG, part of Springer Nature, 2018. 367 p. (Цао Л. Образ мышления в науке о данных СПб.: Изд-во Европ. ун-та в СПб., 2022. 552 с.)
9. *Skiena S. S.* The Data Science Design Manual. Texts in Computer Science, Springer, 2017. 445 p. (Скиена С. С. Наука о данных. М.: Вильямс, 2020. 544 с.)
10. *Городецкий В. И.* Наука о данных: Методология, основные направления, проблемы и перспективы // Искусственный интеллект и принятие решений. 2022. № 3. С. 3–20.
11. *Gorodetsky V.* Three Knowledge Sources and Three Constituents of Artificial Intelligence Foundation. // Intelligent Information Technologies for Industry. Lecture Notes in Networks and Systems / Kovalev S., Kotenko I. Sukhanov A. (eds.). Vol. 776. Springer, 2023. P. 14–34.
12. All one needs to know about metaverse: A complete survey on technological singularity, virtual ecosystem, and research agenda / L. Lee, T. Braud, P. Zhou [et al.]. 2021.
13. *Гаврилова Т. А., Кудрявцев Д. В., Муромцев Д. И.* Инженерия знаний. Модели и методы: учебник. СПб.: Лань, 2016.
14. *Саати Т.* Принятие решений. Метод анализа иерархий. М.: Радио и связь, 1993.
15. *Городецкий В. И.* От инженерии знаний к науке о знаниях // Двадцать первая национальная конференция по искусственному интеллекту с международным участием (КИИ-2023). Смоленск, 2023. С. 216–230.
16. *Горелова Г. В.* Когнитивное моделирование сложных систем: Состояние и перспективы // Системный анализ в проектировании и управлении: XXV Междунар. науч. и учеб.-практ. конф. Ч. 1. СПб., 2021.
17. *Городецкий В. И., Тулупьев А. Л.* Формирование непротиворечивых баз знаний с неопределенностью // Известия РАН «Теория и системы управления». 1997. № 5.
18. *Городецкий В. И.* Интервальные вероятностные меры неопределенности в инженерии знаний // Юбилейный сборник трудов СПИИРАН, 1997.

*М. Р. Егорова\**

студент

*В. А. Миклуш\**

кандидат технических наук, доцент – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## АНАЛИЗ УРОВНЯ ЗНАНИЙ ОБУЧАЮЩИХСЯ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Рассматриваются возможности использования искусственного интеллекта (ИИ) в образовании. Также изучено применение ИИ в контексте анализа уровня знаний обучающихся и представлены методы анализа уровня знаний студентов.

**Ключевые слова:** искусственный интеллект, машинное обучение, нейронные сети, обработка естественного языка.

*M. R. Egorova\**

Student

*V. A. Miklush\**

PhD, Tech., Associate Professor – Scientific Adviser

\*St. Petersburg State University of Aerospace Instrumentation

## ANALYSIS OF THE LEVEL OF KNOWLEDGE OF STUDENTS USING ARTIFICIAL INTELLIGENCE

The paper considers the possibility of using artificial intelligence (AI) in education. The application of AI in the context of analyzing the level of knowledge of students is also considered and methods for analyzing the level of knowledge of students are presented.

**Keywords:** artificial intelligence, machine learning, neural networks, natural language processing.

### Введение

В последние годы технологии искусственного интеллекта становятся все более востребованными в разных сферах. Так как сфера образования является одним из важнейших безостановочно развивающихся направлений, становится невозможным исключать использование ИИ в данной области. Одна из ключевых задач современного образования – анализ уровня знаний обучающихся, результаты которого позволяют не только оценить эффективность учебного процесса, но и выявить слабые места в знаниях студентов. ИИ предоставляет новые возможности для решения этой задачи, позволяя обрабатывать большие массивы данных и предлагать персонализированные решения.

### Применение ИИ в образовании

В сфере образования технологии искусственного интеллекта могут использоваться на различных уровнях образовательного процесса: от создания адаптивных образовательных программ до автоматизации административных процессов в учебных заведениях. Рассматривая применение ИИ в контексте анализа уровня знаний обучающихся, можно выделить следующие направления использования [1].

1. Анализ тестовых данных: системы ИИ могут обрабатывать результаты тестов и экзаменов, выявляя закономерности и определяя, какие темы вызывают затруднения у студентов. Это сокращает время анализа большого количества данных.

2. Создание персонализированного образования: ИИ может разрабатывать индивидуальные учебные планы на основе успеваемости и интересов обучающихся, что позволяет повысить мотивацию и эффективность обучения у студентов.

3. Предсказание успеваемости: системы, основанные на ИИ, могут предсказывать, как обучающиеся будут справляться с материалом в будущем, основываясь на результатах анализа их предыдущих показателей.

4. Обратная связь: ИИ может предоставить обучающимся мгновенную обратную связь, что способствует более глубокому пониманию учебного материала и своевременной коррекции ошибок.

#### *Методы анализа уровня знаний студентов*

Существует несколько направлений, в которых развивается ИИ для анализа информации. Такие же направления могут использоваться для исследования уровня знаний обучающихся.

– Машинное обучение.

Алгоритмы, задействованные в машинном обучении, учатся искать закономерности и корреляции в больших наборах данных. На основе полученной информации и ее анализа создается прогноз и формируется оптимальное решение [2]. Говоря об использовании алгоритмов машинного обучения в процессе оценки уровня

знаний учеников, можно предположить, что при определенных настройках алгоритмов появится возможность выявить паттерны в данных об обучающихся и их успеваемости. Полученная информация поможет выявить студентов, которые испытывают трудности в усвоении материала на ранних стадиях обучения.

– Нейронные сети.

Данные модели способны обрабатывать сложные данные и выявлять неочевидные взаимосвязи [3]. Таким образом, если применять данный метод в исследовании уровня знаний обучающихся, тогда получится улучшить качество проводимого анализа и выявить более точные рекомендации. Очевидно, что чем конкретнее будут полученные результаты, тем детальнее возможно будет создать индивидуальный план и определиться с подходом для обучающихся.

– Обработка естественного языка.

Технология, позволяющая искусственному интеллекту понимать, интерпретировать и манипулировать человеческим языком и речью [4]. Благодаря такой технологии возможно создание инструментов, которые могут анализировать текстовые материалы студентов, давать им обратную связь.

### Примеры успешного применения

Многие образовательные учреждения и платформы уже применяют ИИ для анализа знаний обучающихся:

- Coursera – глобальный американский поставщик онлайн-курсов по разным направлениям [5];
- Codecademy – интерактивная онлайн-платформа для обучения языкам программирования [6];
- edX – бесплатная онлайн-платформа, нацеленная на студентов со всего мира [7];
- МАТНia – онлайн-сервис для обучения математике, который персонализирует процесс обучения для учеников средних и старших классов в зависимости от текущих результатов обучающихся [8].

Все перечисленные платформы онлайн-обучения используют ИИ для анализа успеваемости студентов и предоставления рекомендаций по курсам.

### Заключение

Использование ИИ для анализа уровня знаний обучающихся открывает новые горизонты в образовании, позволяя создавать более эффективные и персонализированные подходы к обучению. Это не только повышает качество образования, но и способствует более активному вовлечению обучающихся в процесс. Тем не менее важно помнить о некоторых этических аспектах и потенциальных рисках, связанных с использованием ИИ, таких как конфиденциальность данных и возможность алгоритмической предвзятости.

### Библиографический список

1. Искусственный интеллект в образовании: изучаем реальную практику. URL: <https://skillbox.ru/media/education/iskusstvennyu-intellekt-v-obrazovanii-izuchaem-realnuyu-praktiku/> (дата обращения: 10.08.2024).
2. Что такое машинное обучение? URL: <https://www.oracle.com/cis/artificial-intelligence/machine-learning/what-is-machine-learning/> (дата обращения: 10.08.2024).
3. *Иванько А. Ф., Иванько М. А., Сизова Ю. А.* Нейронные сети: Общие технологические характеристики // Научное обозрение. Технические науки. 2019. № 2. С. 17–23.
4. Методы обработки естественного языка. URL: <https://developers.sber.ru/help/ml/natural-language-processing-techniques> (дата обращения: 10.08.2024).
5. Coursera: офиц. сайт. URL: <https://www.coursera.org/> (дата обращения: 10.08.2024).
6. Codecademy: офиц. сайт. URL: <https://www.codecademy.com/> (дата обращения: 10.08.2024).
7. edX: офиц. сайт. URL: <https://www.edx.org/> (дата обращения: 10.08.2024).
8. Carnegie Learning: офиц. сайт. URL: <https://www.carnegielearning.com/solutions/math/mathia/> (дата обращения: 10.08.2024).

*И. Л. Коршунов\**

кандидат технических наук, доцент

*А. В. Омелян\**

кандидат технических наук

\*Санкт-Петербургский государственный экономический университет

## ПРОБЛЕМЫ ПРИМЕНЕНИЯ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ ДЛЯ РЕШЕНИЯ ЗАДАЧ РАЗЛИЧНОГО НАЗНАЧЕНИЯ

Обсуждаются возможности применения нейросетевых технологий инструмента обработки информации, позволяющего устанавливать взаимосвязь между данными, не имеющими полной функциональной зависимости. Перечисляются задачи, решаемые с применением нейросетевых технологий, и их особенности. Приводятся основные шаги методологии практического применения нейронных сетей.

**Ключевые слова:** искусственный интеллект, нейросетевые технологии, актуальные задачи, объемы вычислительных ресурсов.

*I. L. Korshunov\**

PhD, Tech., Associate Professor

*A. V. Omelyan\**

PhD, Tech.

\*St. Petersburg State University of Economics

## PROBLEMS OF APPLICATION OF NEURAL NETWORK TECHNOLOGIES FOR SOLVING PROBLEMS OF VARIOUS PURPOSES

The possibilities of application of neural network technologies of the information processing tool, allowing to establish the relationship between data that do not have a full functional dependence, are discussed. The tasks and their features solved with the use of neural network technologies are listed. The main steps of the methodology of practical application of neural networks are given.

**Keywords:** artificial intelligence, neural network technologies, current tasks, volumes of computing resources.

### Введение

В современной IT-индустрии сохраняется устойчивая тенденция по наращиванию объема внедрения технологий искусственного интеллекта и нейронных сетей в различные сферы деятельности. Международные и российские аналитические центры дают приблизительно одинаковые цифры по увеличению вложений в эту область IT-индустрии: мировой рынок решений в сфере искусственного интеллекта будет расти в среднем на 20% вплоть до 2027 г. К 2025 г 80% компаний в мире в той или иной степени будут прибегать к интеллектуальной автоматизации [1].

Одно из передовых направлений в области создания искусственного интеллекта – использование искусственных нейронных сетей. Повышение интереса к нейросетевым технологиям определяется их способностью автоматизировать решение трудноформализуемых задач, не решаемых традиционными методами в рамках информационных технологий. Нейросети можно определить как инструмент обработки информации, позволяющий устанавливать взаимосвязь между данными, не имеющими полной функциональной зависимости. В окружающей среде задач с неполной функциональной зависимостью гораздо (несоизмеримо) больше, чем задач, легко формализуемых математическим аппаратом. Задачи с полной функциональной зависимостью подлежат автоматизации алгоритмическим механизмом обработки данных, но и для их решения возможно использовать нейронные сети. Это разумно при наличии имеющихся ограничений на исходные данные, например ошибки их измерения, неполнота данных и др. Применение нейронных сетей в данной ситуации позволит получить более эффективное решение [2; 3].

С другой стороны, нейросетевые технологии не являются универсальным инструментом, способным обеспечить более успешное решение любой задачи. Чтобы понимать их роль в современной информационной индустрии, необходимо определить круг задач, для решения которых они будут эффективны. Предлагается объединить все проблемные задачи, для решения которых целесообразно использовать нейросетевые технологии, в несколько классов [4].

1. *Задачи классификации образов.* Определение принадлежности входного образа, представленного вектором признаков, одному или нескольким предварительно определенным классам.

2. *Задачи кластеризации.* Решение данного класса задач основано на подобии образов и размещении близких образов в одном кластере.

3. *Задачи аппроксимации функций.* На основе набора данных по результатам наблюдений устанавливается наиболее приближенная функциональная зависимость.

Это деление имеет некоторую условность и может быть разбито на подклассы. При планировании применения нейронной сети необходимо четко определить класс решаемой задачи, поскольку это влияет на эффективность применения технологии.

### Проблемы применения нейросетевых технологий

Несмотря на то, что нейронные сети (НС) уже стали неотъемлемой частью ИТ-индустрии и приносят реальную прибыль, их применение требует значительных ресурсов, и всегда надо соизмерять масштаб решаемой задачи и объем привлекаемых ресурсов. Успешность применения НС базируется как минимум на двух технических достижениях: появление мощных сетевых вычислений и доступность к большому объему фактографических данных.

Чтобы оценить объем требуемых ресурсов, опишем схематически механизм обработки информации в НС. Любая нейронная сеть – это набор матриц, матрицы весовых коэффициентов межслойных связей. Соответственно, механизм обработки – это последовательная матричная обработка входного вектора от первой матрицы до выходного слоя. Для решения задачи распознавания мужского и женского лица (одна из задач на международных соревнованиях НС по распознаванию изображений Imagenet) необходима сеть с десятью матрицами с тысячами коэффициентов и обучающая выборка в 10 млн изображений (для достижения оптимального значения точности распознавания). На обучение сети требуется около месяца работы высокопроизводительной сети, например Google Cloud. Если решать более сложные задачи, например использовать сеть VVG16 для распознавания изображений (победитель соревнований по распознаванию изображений в 2014 г., первая сеть, превысившая точность распознавания человека), необходим мощный ресурс сетевых вычислений. В этой сети используется входной вектор – более 50 тыс. бит, обучающая выборка более 60 млн изображений. Следовательно, планируя создание и применение НС необходимо располагать достаточно мощной вычислительной сетью или иметь доступ к вычислительному ресурсу какой-либо компании [5].

Лидером в области создания НС-приложений среди открытых систем является компания Google. Она создала среду разработки TensorFlow и библиотеку готовых сетевых конструкций Keras. Достоинство данного решения состоит в предоставлении бесплатного вычислительного ресурса и возможности использования уже готовых решений для разных типов задач без глубокого погружения в среду разработки. Данная среда позволяет использовать весь спектр НС-технологий, применяемых сегодня на практике (слои прямого распространения, сверточные, рекуррентные слои, функции активации, алгоритмы оптимизации, конверторы входных форматов и т. д.). Использование решения от компании Google становится проблематичным при решении важных прикладных задач: вся информация о задачах и обрабатываемые данные оказываются доступными сторонней организации. Это допустимо при решении учебных задач, но невозможно при решении производственных, хозяйственных, социальных задач.

Еще одна проблема практического применения НС – умение формализовать проблемную задачу в рамках НС-технологий. На сегодняшний день большинство задач, решаемых с помощью НС, реализуются в рамках уникальных проектов. Для широкого применения, помимо доступа к мощным вычислительным ресурсам, необходимо создать методологическую основу применения нейронных сетей и подготовить достаточное количество специалистов. В рамках решения этой проблемы необходимо решить ряд важных задач:

- описать показатели, определяющие принадлежность задачи к решению данной технологией (множество разнотипных входных данных, неполнота входных данных, отсутствие функциональной зависимости входных и выходных данных, конечное множество выходных решений и т. д.);
- определить принадлежность задачи к одной из групп: распознавание, кластеризация, прогнозирование;
- сформулировать задачу в терминах нейронной сети (перечень и нормализация входных данных, множество выходных решений, выбор варианта конфигурации сети);
- выбрать параметры сети: способ нормализации входных данных, выбор передаточных функций нейронов, выбор алгоритмов оптимизации при обучении;
- сформировать обучающую выборку (размах диапазона входных значений, объем обучающей выборки, состав обучающих пакетов, критерий останова обучения и т. д.).

НС являются составной частью ИТ-индустрии. Нароботан опыт и методики их применения. Существуют проблемы среды разработки и доступных вычислительных ресурсов для НС. Необходима методика применения НС.

### Библиографический список

1. Верзун Н. А., Колбанёв М. О., Татарникова Т. М. Аспекты безопасности информационно-экономической деятельности // Технологии информационно-экономической безопасности. СПб., 2016. С. 52–56.
2. Ростовцев В. С. Искусственные нейронные сети: учебник. СПб.: Лань, 2021. 216 с.
3. Нейронные сети: полный курс Саймон Хайкин. М.: Вильямс, 2005. 1104 с.
4. Платонов А. В. Машинное обучение: учеб. пособие для вузов. М.: Юрайт, 2023. 85 с.
5. Татарникова Т. М., Богданов П. Ю., Краева Е. В. Предложения по обеспечению безопасности системы умного дома, основанные на оценке потребляемых ресурсов // Проблемы информационной безопасности. Компьютерные системы. 2020. № 4. С. 88–94.

*Д. С. Лисюков\**

аспирант

*Е. А. Яковлева\**

кандидат физико-математических наук, доцент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И АНАЛИТИКИ ДАННЫХ В СИСТЕМАХ УПРАВЛЕНИЯ ОБУЧЕНИЕМ

Использование технологий искусственного интеллекта в современном мире играет важную роль, в том числе в образовательном процессе. Рассматриваются варианты использования технологий искусственного интеллекта в системах управления обучением, а также польза применения данных технологий в образовании.

**Ключевые слова:** технологии искусственного интеллекта, анализ данных, системы управления обучением.

*D. S. Lisyukov\**

PhD Student

*E. A. Yakovleva\**

PhD, Phys.-Math., Assistant Professor

\*St. Petersburg State University of Aerospace Instrumentation

## ARTIFICIAL INTELLIGENCE AND DATA ANALYTICS TECHNOLOGIES IN LEARNING MANAGEMENT SYSTEMS

The use of artificial intelligence technologies in the modern world plays an important role, including in the educational process. The article discusses the options for using artificial intelligence technologies in learning management systems, as well as the benefits of using these technologies in education.

**Keywords:** artificial intelligence technologies, data analysis, learning management systems.

Технологии искусственного интеллекта (ИИ) – неотъемлемая часть образования. Современное образование невозможно представить без цифровой среды и технологий искусственного интеллекта. Последние открывают для пользователя новые и уникальные возможности доступа к информации, предоставляют продвинутые инструменты анализа и обработки данных, позволяют не только автоматизировать процессы управления обучением, но и оптимизировать их [1]. Интеграция искусственного интеллекта в системы управления обучением расширяет спектр возможностей для улучшения не только качества обучения и повышения его эффективности, но и выявления потенциала каждого обучающегося.

Системы управления обучением (англ. Learning Management System, LMS) становятся популярнее благодаря способности автоматизации процессов обучения, а также упрощения взаимодействия между преподавателем и обучающимися. Однако для достижения высокой эффективности в этих процессах требуется использование передовых технологий, таких как искусственный интеллект и аналитика данных.

Аналитика данных играет важную роль в системе управления обучением: например, помогает преподавателям оптимизировать свои курсы путем сбора информации о том, как обучающиеся используют материалы курса и какие из его элементов являются наиболее эффективными. На рис. 1 изображен анализ структуры теста в системе дистанционного обучения ГУАП, который приводит статистику использованных в тесте вопросов по различным показателям, таким как индекс легкости, стандартное отклонение и т. д. Например, анализ такого рода позволяет исключить из теста вопросы с ошибками (они будут заметно выбиваться из общей статистики), а также обратить внимание преподавателя на легкие или сложные для студента вопросы.

Искусственный интеллект при анализе данных в системах управления обучением позволяет собирать и обрабатывать большие объемы данных: информацию об обучающихся, их успеваемость, предпочтения и поведение в системе. ИИ может прогнозировать результаты экзаменов или тестов на основе анализа ранее полученных результатов.

Однако анализ данных не единственная область использования технологий искусственного интеллекта в системах управления обучением. ИИ активно применяется в так называемых чат-ботах [2], которые служат для поиска и получения информации. Это может быть поиск как справочной информации, так и необходимой информации в материалах курса, как показано на рис. 2.



## Анализ структуры теста

Скачать табличные данные как

№		Название вопроса	Попытки	Индекс легкости	Стандартное отклонение	Балл случайного угадывания	Намеченный вес	Эффективный вес	Индекс дискриминации	Эффективность дискриминации
1		Случайный (Безопасность и подкатегории)	2045	71.87%	43.23%		2.50%	2.28%	15.38%	18.90%
2		Случайный (Безопасность и подкатегории)	2045	75.77%	41.18%		2.50%	2.16%	14.46%	17.99%
3		Случайный (Безопасность и подкатегории)	2045	74.10%	41.95%		2.50%	2.36%	18.20%	22.46%
4		Случайный (Безопасность и подкатегории)	2045	73.85%	42.34%		2.50%	2.48%	20.69%	25.54%
5		Случайный (Безопасность и подкатегории)	2045	75.97%	41.20%		2.50%	2.25%	16.43%	20.61%
		Диапазон статистики по этим вопросам <a href="#">Посмотреть детали</a>	113 - 166	29.17% - 98.55%	11.99% - 50.20%	0.00% - 50.00%	2.50% - 2.50%		0.22% - 57.23%	0.27% - 70.50%
6		Случайный (Обзор электронных образовательных ресурсов и подкатегории)	2045	82.99%	35.73%		2.50%	2.19%	19.81%	25.90%
7		Случайный (Обзор электронных образовательных ресурсов и подкатегории)	2045	84.54%	34.47%		2.50%	2.13%	19.42%	25.85%

Рис. 1. Анализ структуры теста в системе дистанционного обучения ГУАП

---

Вы искали
Очистить

sklearn

sketch

JSON

api

фэш

Системный

Рис. 2. Бот поиска информации в материалах курса

Бот такого рода является полностью автоматизированным алгоритмом заданной последовательности действия, использует в работе технологии искусственного интеллекта и машинного обучения. Высокотехнологичные боты ведут себя почти как человек: могут выдавать разные варианты ответов на поставленный вопрос, уточнять информацию или даже шутить.

Алгоритмы работы ботов бывает двух видов. Первый – основанный на заранее прописанных правилах. При общении с пользователем используются ключевые слова или фразы, прописанные в разработанном сценарии, в ответ на которые бот выдает заранее подготовленное сообщение.

Второй алгоритм более сложный и связан с использованием искусственного интеллекта и машинного обучения. При разработке ботов такого вида используются техники синтеза и распознавания речи, а также обработки естественного языка (NLP) – технологии машинного обучения, позволяющей боту понимать человеческий язык. За работу такого бота, как правило, отвечает нейронная сеть, которая самостоятельно обучается.

Как мы видим, искусственный интеллект так или иначе активно используется в образовании, в том числе в системах управления обучением. При развитии образовательной инфраструктуры рассматриваются четыре области работы искусственного интеллекта:

- 1) сбор и обработка данных для их дальнейшего анализа и обучения нейронных сетей;
- 2) внедрение технологий ИИ для улучшения качества образования и его эффективности;
- 3) выявление использования технологий ИИ в работах обучающихся;
- 4) создание искусственным интеллектом ложного контента.

В первых двух случаях технологии искусственного интеллекта работают во благо человечества и позволяют повысить эффективность образовательных процессов. Третий и четвертый случаи говорят о том, что эти технологии требуют контроля и наличия инструментов противодействия им [3]. Таким образом, некоторые системы управления обучением, такие как Moodle, уже осуществили интеграцию с сервисом анализа текста Copyleaks [4], который позволяет не только находить плагиат среди работ обучающихся во всей системе, но и вычислять работы, созданные непосредственно искусственным интеллектом. Сервис позволяет найти контент, написанный при помощи ChatGPT, с точностью поиска около 99%. При этом инструменты сервиса Copyleaks позволяют определить, какая часть работы была написана искусственным интеллектом, а какую обучающийся создал самостоятельно.

Использование технологий искусственного интеллекта – сложный и многогранный процесс, требующий постоянного контроля, обновления и адаптации как к современным технологиям, так и к потребностям пользователей. Безусловно, ИИ играет важную роль для обеспечения качества образования и повышения его эффективности, а также использования современных технологий в образовательных процессах. Однако следует помнить, что обращение к технологиям искусственного интеллекта не всегда может быть полезным для пользователя.

#### **Библиографический список**

1. *Амиров Р. А., Билалова У. М.* Перспективы внедрения технологий искусственного интеллекта в сфере высшего образования // *Управленческое консультирование*. 2020. № 3. С. 80–88.
2. *Матвеева Н. Ю., Золотарюк А. В.* Технологии создания и применения чат-ботов // *Научные записки молодых исследователей*. 2018. № 1. URL: <https://cyberleninka.ru/article/n/tehnologii-sozdaniya-i-primeneniya-chat-botov> (дата обращения: 13.08.2024).
3. *Лучшева Л. В.* Социальные проблемы использования искусственного интеллекта в высшем образовании: задачи и перспективы // *Научный Татарстан*. 2020. № 4. С. 84–89.
4. Moodle Plagiarism & AI Content Checker. URL: <https://copyleaks.com/ru/learning-management-systems/moodle-plagiarism-checker> (дата обращения: 13.08.2024).

*Н. В. Путилова*

старший преподаватель

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ОПТИМИЗАЦИЯ ПАРАМЕТРОВ ОБРАЗОВАТЕЛЬНЫХ ПРОГРАММ И ПЕДАГОГИЧЕСКОЙ НАГРУЗКИ С ИСПОЛЬЗОВАНИЕМ ИНТЕЛЛЕКТУАЛЬНЫХ ТЕХНОЛОГИЙ

Рассмотрен подход к управлению педагогической нагрузкой вуза с использованием интеллектуальных технологий для оптимизации нагрузки. Определены требования к системе оптимизации нагрузки. Предложено использование генетических алгоритмов в качестве метода оптимизации, и определена обобщенная архитектура системы, удовлетворяющая сформулированным требованиям.

**Ключевые слова:** расчет педагогической нагрузки, высшее образование, оптимизация педагогической нагрузки, генетические алгоритмы, интеллектуальные технологии.

*N. V. Putilova*

Senior Lecturer

St. Petersburg State University of Aerospace Instrumentation

## OPTIMIZATION OF EDUCATIONAL PROGRAM AND TEACHING LOAD PARAMETERS USING INTELLIGENT TECHNOLOGIES

This article discusses an approach to university teaching load management using intelligent technologies to optimize the load. The requirements for the load optimization system have been determined. The use of genetic algorithms as an optimization method is proposed and a generalized system architecture that satisfies the requirements defined above is defined.

**Keywords:** teaching load calculation, higher education, teaching load optimization, genetic algorithms, intelligent technologies.

Одна из важных составляющих образовательного процесса вуза – расчет и мониторинг педагогической нагрузки. Нормы времени и алгоритмы расчета нагрузки определяются образовательными организациями самостоятельно [1], но при этом как распределение нагрузки на преподавателей, так и суммарная педагогическая нагрузка строго регламентированы. Педагогическая нагрузка организации ограничивается как снизу, так и сверху в соответствии с локальными нормативными актами. Определение этих параметров – важная задача управления образовательным процессом. Манипулирование пределами объемов нагрузки и ее средней величиной позволяет реализовать как научные, так и образовательные траектории развития научно-педагогических работников (НПР) на разных должностях. Определение этих пределов – задача стратегическая и социальная, но при этом регламентированная нормативными документами. Максимальная нагрузка первой половины рабочего дня на одного педагогического работника составляет 900 часов в учебном году [1]. При этом количество НПР определяется количеством обучающихся в организации, и для вузов не должно превышать 1 преподавателя на 12 обучающихся [2].

Таким образом, при определенном количестве обучающихся максимально реализуемая педагогическая нагрузка является величиной фиксированной, где на каждого студента на учебный год приходится 75 часов нагрузки. Если при этом учитывать дифференциацию верхнего предела нагрузки по должностям, которая введена в большей части вузов, то максимально допустимая нагрузка при том же числе студентов будет еще меньше. Это приводит к необходимости мониторинга и управления педагогической нагрузкой. В данной статье будет рассматриваться оптимизация педагогической нагрузки на учебный год с целью сохранения заданных нижнего, среднего и верхнего объемов нагрузки на педагогического работника при фиксированной численности НПР.

В современных условиях быстро меняющегося мира постоянно появляются новые компетенции, которые необходимо сформировать у обучающихся, для того чтобы их квалификация соответствовала последним достижениям науки и техники. За последние несколько лет в образовательных программах была обновлена и расширена история, также в них были добавлены дисциплины, связанные с искусственным интеллектом и другими сквозными технологиями, разработаны дополнительные модули, связанные с беспилотными авиационными системами. Это, наряду с добавлением в содержание образовательных программ новой информации, приводит к увеличению нагрузки. Соответственно, наиболее востребованной задачей становится минимизация суммарной педагогической нагрузки с соблюдением нижнего предела.

При большом количестве образовательных программ современного вуза и параметров расчета нагрузки данная задача крайне трудоемка для решения вручную, поэтому для ее решения необходима программная система, функционирующая как система поддержки принятия решений. Она должна функционировать в рамках цифровой инфраструктуры вуза, поэтому к ней предъявляются как функциональные, так и системные требования:

– основными параметрами задачи оптимизации должны быть нормы расчета нагрузки и параметры алгоритмов расчета;

- нормы расчета нагрузки задаются с точностью до 2 знаков после запятой;
- система должна поддерживать ограничение итоговой величины нагрузки сверху и снизу, задаваемые пользователем;
- для всех параметров должна быть предусмотрена возможность задать область допустимых значений;
- система должна иметь программный интерфейс для импорта данных из системы хранения учебных планов;
- результатом оптимизации должно быть несколько различных локально оптимальных решений для принятия решений по управлению образовательным процессом;
- результаты работы системы должны быть представлены как в виде значений параметров, так и в графическом виде;
- система должна поддерживать возможности минимизации педагогической нагрузки как основную задачу, но при этом иметь возможность переключения на максимизацию нагрузки;
- поддержка дифференцирования параметров расчета нагрузки для различных уровней подготовки и форм обучения;
- в системе должна предусматриваться возможность корректировки параметров учебных планов в случае, если оптимизация с учетом изменений параметров расчета нагрузки оказалась недостаточной или неприемлемой в связи с различными социальными факторами.

Вопросы расчета и оптимизации нагрузки рассматривались в различных работах, но чаще всего оптимизация применяется в задаче распределения нагрузки [3; 4], а не расчета. Задача оптимизации нагрузки в данном случае является многомерной, при этом работа ведется только для одной целевой функции – суммарной педагогической нагрузки. Так как система планировалась в качестве облегченной системы поддержки принятия решений, для оптимизации рассматривались в первую очередь различные интеллектуальные технологии. Среди методов оптимизации была выбрана оптимизация с использованием генетических алгоритмов [5], так как они позволяют легко получить несколько вариантов решений. Нагрузка первой половины рабочего дня состоит из аудиторной нагрузки, которая отображается в расписании, и внеаудиторной нагрузки, которая к расписанию не имеет жесткой привязки. При этом суммарный объем педагогической нагрузке вуза  $W$  можно обобщенно записать в виде формулы

$$W = \sum_i^n \sum_j^m k_{ij} L_{ij},$$

где  $L_{ij}$  – нагрузка  $i$ -го вида нагрузки  $j$ -го учебного плана,  $k_{ij}$  – коэффициент участия данного вида нагрузки для данного плана  $k_{ij} \in \{0, 1\}$ .

Для каждого вида нагрузки для различных форм обучения могут использоваться различные алгоритмы и нормы расчета. С точки зрения расчета аудиторная нагрузка отличается тем, что в большей части формул результат линейно зависит от количества аудиторных часов (иногда с учетом разделения на подгруппы), а в остальных – от количества обучающихся. Во внеаудиторной нагрузке формулы более разнородны. Коэффициент  $k_{ij}$  введен для удобства контроля над видами нагрузки, специфичными для различных форм обучения, уровня подготовки или других параметров образовательной программы. Такие виды чаще всего характерны для внеаудиторной нагрузки. Несмотря на то, что часть параметров относится к определению алгоритмов расчета нагрузки, генетическое программирование не подходит для решения данной задачи, так как в первую очередь принципы расчета различных видов нагрузки основываются на анализе предметной области.

В соответствии с требованиями программный комплекс предназначен для работы в двух режимах. В первом аудиторные часы и другие свойства учебных планов образовательных программ будут статическими параметрами, а во втором статическими параметрами становятся нормы расчета нагрузки и алгоритмы расчета, а решение ищется среди характеристик учебного плана, связанных с аудиторной нагрузкой. В первом режиме кроме норм (коэффициентов) для различных видов нагрузки, отдельных для различных форм обучения и уровней подготовки, в качестве параметров оптимизации берутся также размеры подгрупп и метод округления количества подгрупп для видов занятий, подразумевающих разбиение на подгруппы. Для реализации верхних и нижних границ значений целевой функции вне зависимости от режима работы программы целесообразно использовать штрафы.

Работа в режиме изменений параметров учебного плана без полного перебора по всем дисциплинам и практикам каждого учебного плана требует хранения для каждого учебного плана статистической информации. Среди этой статистики должны быть следующие параметры для каждого семестра: число аудиторных часов без электронного обучения по каждому из видов занятий, число аудиторных часов с применением электронного обучения, количество студентов, обучающихся в семестре. Количество часов потоковых занятий необходимо считать как долю часов данной образовательной программы в общем потоке. С точки зрения архитектуры данный программный комплекс должен состоять из нескольких модулей:

- модуль настройки параметров оптимизации, диапазонов допустимых значений функций, пределов значений нагрузки;
- модуль поиска оптимального решения;
- модуль представления результатов оптимизации;
- модуль работы с учебными планами для импорта данных планов и поддержания статистики в актуальном виде.

Так как для генетических алгоритмов разработано достаточно много эффективных библиотек, целесообразно при построении модуля поиска оптимального решения использовать готовую библиотеку. В данном случае для совместимости с программой расчета нагрузки была выбрана свободно распространяемая библиотека Jenetics [6].

Создание программного комплекса для оптимизации параметров расчета нагрузки позволяет более тонко управлять образовательным процессом вуза. Такую систему можно отнести к системам поддержки принятия решений для управления нагрузкой вуза. Направления развития системы целесообразнее определить по результатам эксплуатации системы в течение нескольких лет.

#### Библиографический список

1. О продолжительности рабочего времени (нормах часов педагогической работы за ставку заработной платы) педагогических работников и о порядке определения учебной нагрузки педагогических работников, оговариваемой в трудовом договоре: приказ Министерства науки и высшего образования России от 22.12.2014 № 1601 (ред. от 13.05.2019). URL: <https://normativ.kontur.ru/document?moduleId=1&documentId=336324> (дата обращения: 26.08.2024).
2. Об утверждении плана мероприятий («дорожной карты») «Изменения в отраслях социальной сферы, направленные на повышение эффективности образования и науки»: распоряжение Правительства РФ от 30.04.2014 № 722-р. URL: <https://mintrud.gov.ru/docs/government/137> (дата обращения: 26.08.2024).
3. *Липова Э. Е., Секирин А. И.* Многокритериальный генетический алгоритм оптимизации распределения учебной нагрузки профессорско-преподавательского состава в условиях АСУ вуза // Информатика, управляющие системы, математическое и компьютерное моделирование (ИУСМКМ-2020): сб. матер. XI Междунар. науч.-техн. конф. в рамках VI Междунар. науч. форума ДНР, Донецк, 27–28 мая 2020 г. Донецк, 2020. С. 214–218.
4. Математическое моделирование и оптимизация расчета учебной нагрузки профессорско-преподавательского состава кафедры / Е. В. Болгова, Т. И. Касаткина, Р. В. Кузьменко, А. Г. Москаленко // Вестник Воронежского института ФСИИ России. 2019. № 1. С. 39–50.
5. *Скобцов Ю. А., Сперанский Д. В.* Эволюционные вычисления: учеб. пособие. 2-е изд. М.: ИНТУИТ, 2016. 429 с.
6. Jenetics. URL: <https://jenetics.io/> (дата обращения: 26.08.2024).

*А. Г. Савенко\**

старший преподаватель

*А. И. Парамонов\**

кандидат технических наук, доцент

\*Белорусский государственный университет информатики и радиоэлектроники, Минск, Республика Беларусь

## ИСПОЛЬЗОВАНИЕ ИНТЕЛЛЕКТУАЛЬНОЙ ЦИФРОВОЙ ПЛАТФОРМЫ В ОБРАЗОВАТЕЛЬНОМ ПРОЦЕССЕ

Проведен анализ проблемы организации образовательного процесса в учреждении высшего образования и ее существующих решений. Предложено комплексное решение для организации процесса адаптивного электронного обучения, которое может быть использовано как дополнение к организации классического образовательного процесса. Обозначены ключевые задачи, в решении которых могут быть использованы технологии искусственного интеллекта. Приведено описание разработанных программных решений для решений поставленных задач.

**Ключевые слова:** образовательный процесс, адаптивное обучение, машинное обучение, интеллектуальный анализ данных.

*A. G. Savenko\**

Senior Lecturer

*A. I. Paramonov\**

PhD, Tech., Associate Professor

\*Belarusian State University of Informatics and Radioelectronics, Minsk, Republic of Belarus

## USING AN INTELLIGENT DIGITAL PLATFORM IN THE EDUCATIONAL PROCESS

The paper analyzes the problem of organizing the educational process in university and its existing solutions. A comprehensive solution for organizing the adaptive e-learning process is proposed, which can be used as an addition to the organization of the classical educational process. Main tasks are identified, in the solution of which artificial intelligence technologies can be used. A description of the developed software solutions for solving the tasks is given.

**Keywords:** Educational Process, Adaptive Learning, Machine Learning, Data Mining.

### Введение

В настоящее время в ходе цифровой трансформации бизнес-процессов всей мировой экономики в различные сферы человеческой деятельности активно внедряются уже не просто цифровые технологии как средство автоматизации процессов, а все более перспективные и сложные технологии искусственного интеллекта. Их использование в образовательном процессе также становится динамичным трендом, чему способствует такие преимущества, как: повышение качества подготовки специалистов, рациональное использование человеческих ресурсов в процессе обучения, повышение инклюзивности обучения, повышение экономической эффективности и др. [1–3]. Технологии искусственного интеллекта в образовательном процессе могут быть использованы для решения различных задач, как непосредственно при обучении, так и в производственных процессах учреждений образования (как в целом, так и в структурных подразделениях: кафедрах, учебно-методическом отделе и т. д.).

В данной работе представлен опыт кафедры информационных систем и технологий Института информационных технологий Белорусского государственного университета информатики и радиоэлектроники (ИСиТ ИИТ БГУИР) по разработке, внедрению и использованию в образовательном процессе технологических решений и цифровых инструментов с элементами искусственного интеллекта.

### Использование искусственного интеллекта в процессе обучения

Одной из наиболее эффективных моделей обучения является адаптивная [4], а наиболее перспективными и современными инструментами обучения – системы электронного обучения, которые могут эффективно использоваться как в традиционных формах получения образования, так и в дистанционной. На кафедре ИСиТ ИИТ БГУИР разработано комплексное электронное средство обучения «Скорина», общая функциональная схема которого показана на рисунке. В целом «Скорина» реализуется как интеллектуальная адаптивная цифровая платформа (ИАЦП).



Общая функциональная схема ИАЦП

Технологии искусственного интеллекта используются в моделях адаптации и представлены машинным обучением для построения индивидуальной образовательной траектории обучаемых и интеллектуальным анализом качества образовательного контента.

Первоначальное построение образовательной траектории происходит путем реализации адаптивного поиска по объектам и критериям, содержащимся в модели обучаемого. С этой точки зрения модель организации данных должна «обучаться» и накапливать также данные, отсутствующие в ИАЦП, но необходимые для получения релевантного результата. Например, на момент прохождения обучаемым входной аттестации модель обучаемого уже содержит данные о том, что он владеет навыками работы с RDBMS Oracle. Соответственно, ИАЦП должна понимать, что это объектно-реляционная система управления базами данных, а далее, опираясь на эту информацию и владея знаниями, что основной дисциплиной с соответствующими компетенциями в рамках курса обучения выступает «Системы управления базами данных» (СУБД), должна предложить учащемуся к изучению те дисциплины, которые предполагают наличие компетенций в области СУБД.

Для реализации данного механизма первостепенна подготовка данных, содержащихся во всех моделях ИАЦП. Поскольку для построения индивидуальной образовательной траектории входными данными выступают поисковые объекты и список критериев их поиска модели обучаемого, то они должны быть максимально конкретными для того, чтобы алгоритму машинного обучения (формирования обобщений критериев поиска) было проще выявить нужные обобщения и классы, к которым данные критерии относятся. Выходными данными обучения выступают непосредственно критерии поиска и список обобщений, к которым относятся данные критерии. На первом этапе машинного обучения дополняется каждый входной критерий каким-либо его определением или характеристикой на естественном языке. На втором этапе полученное из стороннего источника данных (например, электронной энциклопедии) описание на естественном языке разбивается на отдельные части и выбираются ключевые лексемы (токенизируются). Процесс формирования обобщений и обучения базы данных автоматизирован и не привязан к конкретному типу или схеме источника данных для формирования обобщений.

Интеллектуальный анализ качества учебного контента предназначен для выявления и совершенствования материалов учебного контента, объективно вызывающих трудности у студентов при изучении дисциплин. Как правило, обучаемые справляются с изучением учебных дисциплин по-разному. Это может быть обусловлено как различной базовой подготовкой учащихся, так и их индивидуальными особенностями. Однако если большинство обучаемых испытывают затруднения при ответе на один или одни и те же вопросы контрольного тестирования, то это может свидетельствовать о недостатках методики преподавания, изложения материала и качестве образовательного контента. Следовательно, существует необходимость улучшения определенной части учебного контента. Исходными данными для выявления таких причинно-следственных связей может выступать статистика успеваемости обучаемых по изучаемым дисциплинам (модулям или блокам). Алгоритм интеллектуального анализа обрабатывает такие данные, как время, затраченное на прохождение контрольного теста, успеваемость обучаемых по другим модулям дисциплины, успеваемость по другим дисциплинам и успеваемость конкретного обучаемого во временном срезе. При этом из статистической выборки исключаются данные, объективно не связанные с качеством образовательного контента. В случае установления причинно-следственных связей между низкой успеваемостью студентов по изучаемому модулю дисциплины и качеством учебного контента идентифицируются конкретные части образовательного контента, нуждающиеся в совершенствовании, и предоставляются эксперту для принятия решения.

Таким образом, предложенные модели и их программно-алгоритмическая реализация устраняют ряд недостатков существующих систем контроля и управления обучением.

## Использование искусственного интеллекта в делопроизводстве

Организация и реализация образовательного процесса сопровождается множеством информационных потоков и значительным документооборотом. В современных системах менеджмента качества учреждений образования предполагается переход к цифровому документообороту с использованием различных инструментов автоматизации. Однако анализ современных подходов и методов решения задачи автоматизации документооборота показал, что человеческий фактор все еще значительно влияет на качественные показатели делопроизводства. В этой связи на кафедре ИСиТ ИИТ БГУИР разработана автоматизированная информационная система электронного документооборота с элементами искусственного интеллекта (АИС «Цифровая кафедра»), которая позволяет решить проблемы контроля за работой персонала и повышения качества используемой документации. Помимо основных функциональных возможностей, предусмотренных в подобного рода инструментах, в системе «Цифровая кафедра» решаются такие задачи, как автоматический поиск по базе документов с использованием алгоритмов распознавания текста, автоматическое создание и редактирование электронных версий документов путем распознавания фото-, скан-копий бумажных документов. В ходе обработки документов система самостоятельно определяет авторство, назначение и другие параметры документа, исходя из анализа его содержимого и поставленной цели. Дополнительно с применением методов интеллектуального анализа данных решаются задачи классификации и ранжирования документов.

### Заключение

Предложенное комплексное решение ИАЦП позволит заменить постиндустриальную модель обучения, распространенную в странах СНГ, на более эффективную адаптивную модель, что повысит эффективность подготовки кадров в системе образования и сократит затраты ресурсов, необходимых для реализации образовательного процесса. Кроме того, адаптация процесса обучения индивидуально к каждому обучаемому либо к группе обучаемых позволит расширить возможности инклюзивного образования лиц с ограниченными возможностями здоровья. Использование АИС «Цифровая кафедра» в делопроизводстве образовательного процесса позволит сократить затраты ресурсов, которые необходимы для обеспечения его надлежащего качества, и освободить персонал для решения других творческих задач.

### Библиографический список

1. *Суский А. А., Савенко А. Г.* Преимущества и перспективы внедрения нейронных сетей в образовательный процесс, как инструмент повышения качества подготовки специалистов // Высшее техническое образование: проблемы и пути развития: матер. IX Междунар. науч.-метод. конф., Минск, 1–2 нояб. 2018 г. / редкол.: В. А. Богущ [и др.]. Минск: БГУИР, 2018. С. 454–456.
2. *Савенко А. Г.* Искусственный интеллект как инструмент повышения качества образовательного процесса лиц с особыми потребностями // Информационные системы и технологии: матер. 57-й науч. конф. аспирантов, магистрантов и студентов, Минск, 19–23 апр. 2021 г. / Белорус. ун-т информатики и радиоэлектроники, Ин-т информ. технологий; редкол.: А. А. Охрименко. Минск: БГУИР, 2021. С. 41–43.
3. *Савенко А. Г.* Элементы искусственного интеллекта в адаптивных системах управления обучением для реализации инклюзивного образовательного процесса // Непрерывное профессиональное образование лиц с особыми потребностями: сб. ст. IV Междунар. науч.-практ. конф., Минск, 9–10 дек. 2021 г. / Белорус. гос. ун-т информатики и радиоэлектроники; редкол.: А. А. Охрименко [и др.]. Минск, 2021. С. 237–241.
4. *Brusilovsky P., Eklund J., Schwarz E.* Web-based education for all: a tool for development adaptive courseware // Computer networks and ISDN systems. 1998. № 30(1-7). P. 291–300.



**В. Ю. Строганов\***

доктор технических наук, профессор

**Д. В. Строганов\***

доктор технических наук, профессор

\*Московский государственный технический университет имени Н. Э. Баумана

## ФОРМАЛЬНЫЕ МОДЕЛИ НЕЧЕТКИХ МНОЖЕСТВ И НЕЧЕТКОЙ ЛОГИКИ В СИСТЕМЕ ПОДГОТОВКИ ИНДИВИДУАЛЬНЫХ ОБРАЗОВАТЕЛЬНЫХ ПРОГРАММ

Анализируются вопросы формирования индивидуального учебного плана (УП). В качестве критерия его эффективности рассматривается его логическая связность, которая определена через СЕД (семантические единицы данных, знаний, информации), которые определяются в модулях дисциплин УП. Количественные оценки меры связности предлагается оценивать через доли пересекающихся входных СЕД одного модуля и выходных СЕД другого, которые принимают значения от 0 до 1. В результате модули УП и тесты формализуются через нечеткие множества и нечеткие отношения, что позволяет на основании результатов тестового контроля обучаемого сформировать для него индивидуальную образовательную траекторию.

**Ключевые слова:** учебный план, нечеткие множества, нечеткие отношения, семантические единицы данных, композиция нечетких отношений.

**V. Yu. Stroganov\***

Dr. Sc., Tech., Professor

**D. V. Stroganov\***

Dr. Sc., Tech., Professor

\*Bauman Moscow State Technical University

## FORMAL MODELS OF FUZZY SETS AND FUZZY LOGIC IN THE SYSTEM OF PREPARATION OF INDIVIDUAL EDUCATIONAL PROGRAMS

The article considers the issues of forming an individual curriculum (UC). As a criterion for the effectiveness of the plan, its logical coherence is considered, which is defined through the SED (semantic units of data, knowledge, information), which are defined in the modules of the disciplines of the UC. It is proposed to estimate the quantitative assessment of the measure of coherence through the shares of intersecting input SED of one module and output SED of another, which take values from 0 to 1. As a result, the UC modules and tests are formalized through fuzzy sets and fuzzy relations, which allows, based on the results of the test control of the student, to form an individual educational trajectory for him.

**Keywords:** curriculum, fuzzy sets, fuzzy relations, semantic units of data, composition of fuzzy relations.

### Введение

Одна из основных задач формирования эффективного учебного плана – разработка механизма и инструментальных средств создания логически связного учебного контента с возможностью количественной оценки этой связности [1]. В общем случае можно говорить, о связности как дисциплин, так и модулей УП. Далее будем рассматривать связность модулей как более общий случай. Каждый модуль в работе рассматривается как некоторое преобразование входных СЕД в его выходные, т. е.

$$M: \text{СЕД}^{\text{IN}} = (\text{СЕД}^{\text{IN}}_1, \dots, \text{СЕД}^{\text{IN}}_n) \Rightarrow \text{СЕД}^{\text{OUT}} = (\text{СЕД}^{\text{OUT}}_1, \dots, \text{СЕД}^{\text{OUT}}_m). \quad (1)$$

Взаимосвязь модулей УП определяется через их связность по СЕД (рис. 1). Пусть  $GM = (MM, EM)$  – граф межмодульной связности, где  $MM = \{M_m\}$ ,  $m = 1 \dots |MM|$  – множество модулей,  $EM = EM_{m_1, m_2} = \{M_{m_1}, M_{m_2}\}$  – множество пар модулей.  $EM_{m_1, m_2} = 1$ , если СЕД введенные в модуле  $m_1$  используются в модуле  $m_2$ .




Рис. 1. Межмодульная связность по СЕД<sup>IN</sup> и СЕД<sup>OUT</sup>

Будем использовать двухуровневую индексацию СЕД, а именно  $СЕД_{m,n}^{IN}$  и  $СЕД_{m,k}^{OUT}$ , где первый индекс определяет индекс модуля, а второй – индекс СЕД в модуле. Для описания объединений множеств примем обозначения:  $СЕД_m^{IN} = \bigcup_s СЕД_{m,s}^{IN}$  – все входные СЕД модуля  $m$ ;  $СЕД^{IN} = \bigcup_m СЕД_m^{IN}$  – входные СЕД всех модулей;  $СЕД_m^{OUT} = \bigcup_s СЕД_{m,s}^{OUT}$  – все выходные СЕД модуля  $m$ ;  $СЕД^{OUT} = \bigcup_m СЕД_m^{OUT}$  – выходные СЕД всех модулей.

### Количественная оценка связности

Далее на основе построения частотных характеристик СЕД в работе ставится задача формирования количественной оценки связности различных модулей. Пусть  $NOut_i = \text{card}(СЕД^{OUT}_i)$  – количество выходных СЕД  $M_i$ ;  $Nin_i = \text{card}(СЕД^{IN}_i)$  – количество входных СЕД  $M_i$ ;  $NOut_{i,j}$  – количество выходных СЕД  $M_i$ , используемых в качестве входных СЕД  $M_j$ ;  $NIn_{i,j}$  – количество входных СЕД  $M_j$ , которые используют выходные СЕД  $M_i$ .

При УП с согласованными ссылками выполняется условие  $NOut_{i,j} = NIn_{i,j}$ . При этом  $Pin_{i,j} = \frac{Nin_{i,j}}{Nin_i}$  соответствует

доле входных СЕД  $M_j$  для  $M_i$ . Но у входных СЕД  $M_j$  имеет место лишь один базовый. Поэтому сумма долей по остальным модулям будет равна 1, т. е.  $\forall M_i \sum_j Pin_{i,j} = 1$ . В результате получаем граф межмодульной связности (рис. 2), где дуги взвешены количественной оценкой необходимости предыдущих модулей для изучения данного.

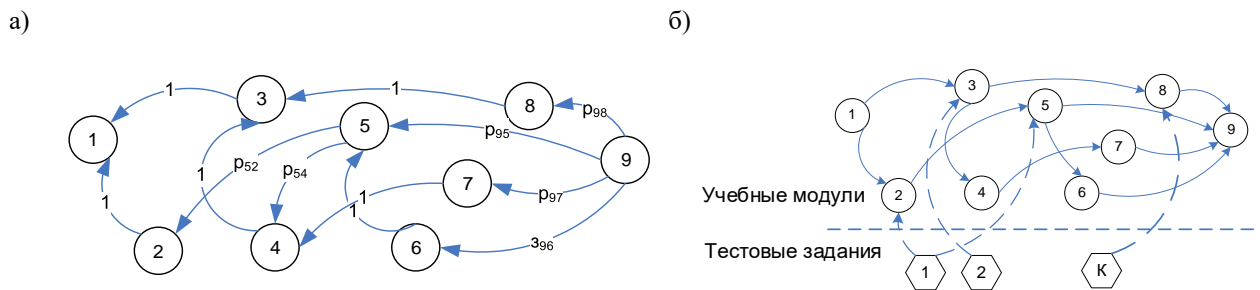


Рис. 2. Графы связности модулей (а), тестовых заданий и модулей (б)

Имея такую меру межмодульной связности, можно перейти к формальной постановке связности в виде нечеткого графа, что позволяет использовать весь спектр методов нечетких множеств. Таким образом, формально получено нечеткое отношение

$$\underline{MM} = \{(M_1, M_2|p_{11}), \dots, (M_i, M_j|p_{ij}), \dots, (M_m, M_{m-1}|p_{m,m-1})\}. \quad (2)$$

Кроме того, по связности СЕД аналогичным образом можно определить степень связности ТЗ (тестовых заданий) с модулями [2]:

$$\underline{TM} = \{([T_1, M_1]|\mu_{11}), \dots, ([T_{k1}, M_{k2}]|\mu_{k1k2}), \dots, ([T_i, M_m]|\mu_{im})\}. \quad (3)$$

Лингвистическая переменная ответа на ТЗ определена на отношении обучаемых (О) к тестовым заданиям (О×Т), а отношение связности ТЗ и модулей определено на (Т×У). Это позволяет формально подойти к композиции (О×Т)°(Т×У), задающей нечеткую оценку принадлежности  $M_i$  индивидуальной траектории  $PM(O) = (PM_1(O), \dots, PM_N(O))$ , где  $PM_i(O)$  представляет необходимость включения модуля  $M_i$  ( $0 \leq PM_i(O) \leq 1$ ) в УП. Для этого реализуется формальная композиция  $\underline{T}$  и нечеткого отношения  $\underline{TM}$ .

### Композиция отношений связности

Реализация операции композиции по технике вычислений является аналогом матричного произведения с заменой суммирования на  $\max$  и произведения на  $\min$ . Для других видов композиции необходимо, чтобы замена операции  $\min$  на бинарную операцию «\*» также обладала свойствами ассоциативности и монотонного неубывания по каждому аргументу. Особое место среди таких композиций занимает « $\max$ -»-композиция, для которой результат выражается как  $\mu_{R1-R2}(x, z) = \max_y [\mu_{R1}(x, y) \cdot \mu_{R2}(y, z)]$ .

Пусть нечеткое значение переменной  $\underline{X}$  задано функцией принадлежности  $\mu_{\underline{X}}(x)$ . Также задано нечеткое отношение  $\underline{R}_{XY}$  на множестве  $X \times Y$  (рис. 3). Требуется определить функцию принадлежности  $\mu_{\underline{Y}}(x)$  нечеткого результата функционального преобразования  $\underline{Y}$ .

Для построения нечеткого образа  $\underline{Y}$  выполняются следующие шаги.

**Шаг 1.** Расширяем функцию принадлежности  $\mu_{\underline{X}}(x)$  для  $\underline{X}$  до цилиндрического продолжения  $\mu_{\underline{X}}(x,y)$ :  $\forall y \mu_{\underline{X}}(x,y) = \mu_{\underline{X}}(x)$  (см. рис. 3). Полученная функция двух аргументов представляет функцию принадлежности нечеткого отношения  $\underline{R}_{XX}$ .

**Шаг 2.** Для полученного нечеткого отношения  $\underline{R}_{XX}$  и заданного  $\underline{R}_{XY}$  применяется одно из правил композиции нечетких отношений, например «*max-min*»-композиции  $\mu_{\underline{R}_1 \bullet \underline{R}_2}(x, z) = \max_y(\min(\mu_{\underline{R}}(x, y), \mu_{\underline{L}}(y, z)))$ . В результате получаем новое отношение  $\underline{R}_{YY}$ , функция принадлежности которого также имеет цилиндрическую форму.




Рис. 3. Композиция отношений  $\underline{R}_{XX}$  и  $\underline{R}_{XY}$

**Шаг 3.** Полученная композиция отношений  $\underline{R}_{YY}$  проецируется на ось  $OY$ , в результате чего получается функция принадлежности  $\mu_Y(y)$  искомой нечеткой величины  $\underline{Y}$ .

На основе приведенного алгоритма композиции получаем нечеткую переменную включения учебного модуля в индивидуальную образовательную траекторию:

$$\underline{M} = \{(M_1|p_1), (M_2|p_2), \dots, (M_n|p_n)\}. \quad (4)$$

Однако для понимания некоторого модуля, включенного в индивидуальный УП, могут использоваться не только модули, включенные в результате тестового контроля, но и модули с опосредованным пересечением СЕД, т. е. если СЕД<sub>1</sub> модуля 1 необходим для понимания СЕД<sub>2</sub> модуля 2, который в свою очередь необходим для понимания, а СЕД<sub>3</sub> модуля 3, то СЕД<sub>1</sub> модуля 1 необходим для понимания СЕД<sub>3</sub> модуля 3, но с несколько другой степенью. Для моделирования такой ситуации в статье предлагается использовать операцию транзитивного замыкания нечеткого множества, т. е., помимо нечеткой переменной  $\underline{M}$ , необходимо формирование композиции этой переменной с транзитивным замыкаем нечеткого отношения  $\underline{MM}$  [3].

Пусть  $\underline{R}$  – нечеткое отношение и  $\underline{R} \subseteq E \times E$  – носитель нечеткого отношения. Будем последовательно вычислять, например, «*max-min*»-композиции этого отношения на себя  $\underline{R} \bullet \underline{R} \subseteq \underline{R}$ . Предположим, что  $\underline{R}^2 \subseteq \underline{R}, \dots, \underline{R}^{k+1} \subseteq \underline{R}^k$ . Из этого следует, что  $\underline{R}^k \subseteq \underline{R}$ .

Пусть  $\downarrow \underline{MM}$  – транзитивное замыкание нечеткого отношения  $\underline{MM}$ . Таким образом, последний шаг в формировании индивидуальной образовательной траектории заключается в формировании композиции нечеткой переменной  $\underline{M}$  и транзитивного замыкания  $\downarrow \underline{MM}$ . Данная композиция выполняется аналогично композиции нечеткой переменной включения тестовых заданий и нечеткого отношения тестовых заданий  $\underline{T}$  и учебных модулей  $\underline{TM}$ . Таким образом, получаем результирующую нечеткую переменную  $\underline{U}$ , которая представляет нечеткую индивидуальную траекторию.

Для перехода к детерминированной траектории необходимо задать уровень значимости  $\alpha$  и сформировать из нечеткой переменной  $\underline{U}$  переменную  $U$ , которая является переменной  $\alpha$ -уровня нечеткой переменной  $\underline{U}$ .

### Библиографический список

1. Stroganov V., Tsvetkov Y. Methodology for the Curriculum Structuring, Formation and Analysis Based on a Quantitative Assessment of Logical Connectivity // ITM Web of Conferences. 2020. Vol. 35.
2. Дуплик С. В. Модель адаптивного тестирования на нечеткой математике // Открытое и дистанционное образование. 2004. № 4(16). С. 78–88.
3. Горбаченко В. И., Ахметов Б. С., Кузнецова О. Ю. Интеллектуальные системы: нечеткие системы и сети: учеб. пособие для вузов. 2-е изд., испр. и доп. М.: Юрайт, 2023. 105 с.

**В. Ю. Строганов\***

доктор технических наук, профессор

**Д. В. Строганов\***

доктор технических наук, профессор

\*Московский государственный технический университет имени Н. Э. Баумана

## МОДЕЛИ АДАПТИВНОГО ТЕСТОВОГО КОНТРОЛЯ И МЕТОДЫ ОЦЕНКИ ИХ ЭФФЕКТИВНОСТИ НА ОСНОВЕ КРИТЕРИЕВ ОШИБОЧНОЙ КЛАССИФИКАЦИИ

Рассмотрены задачи построения количественных оценок эффективности процедур компьютерного тестового контроля, в том числе адаптивных. Для формализации адаптивных процедур предложена их формализация в виде цепей Маркова. В качестве базовой концепции моделирования ответов тестируемого используется IRT-теория. Предложена модель, построенная по методу Монте-Карло, которая позволяет оценить вероятности ошибочной классификации тестируемых для заданной дискретизации шкалы уровня знаний и сложности тестовых заданий.

**Ключевые слова:** компьютерный тестовый контроль, адаптивные механизмы тестового контроля, марковская цепь, вероятность ошибочной классификации.

**V. Yu. Stroganov\***

Dr. Sc., Tech., Professor

**D. V. Stroganov\***

Dr. Sc., Tech., Professor

\*Bauman Moscow State Technical University

## ADAPTIVE TEST CONTROL MODELS AND METHODS FOR ASSESSING THEIR EFFECTIVENESS BASED ON MISCLASSIFICATION CRITERIA

The article considers the problems of constructing quantitative assessments of the effectiveness of computer test control procedures, including adaptive ones. To formalize adaptive procedures, their formalization in the form of Markov chains is proposed. IRT theory is used as a basic concept for modeling the test taker's responses. A model constructed using the Monte Carlo method is proposed, which allows estimating the probabilities of erroneous classification of test takers for a given discretization of the knowledge level scale and test task complexity.

**Keywords:** computer test control, adaptive test control mechanisms, Markov chain, probability of erroneous classification.

### Введение

Для формирования модели оценки качества процедур тестового контроля в качестве базовой используется IRT-теория, которая задает вероятность правильного ответа на задание заданной сложности тестируемым с заданным уровнем знаний.

В данной теории строится формальная модель условной вероятности правильного выполнения  $i$ -м испытуемым с уровнем знаний  $\Theta_i$  различных по сложности заданий теста, считая  $\Theta_i$  параметром  $i$ -го тестируемого а  $\beta_j$  – независимой переменной. В этом случае условная вероятность будет функцией латентной переменной  $\beta$ :

$$P_i\{x_{ij} = 1|\Theta_i\} = f(\Theta_i - \beta) \quad i = 1..N. \quad (1)$$

В работе полагается, что основным аспектом повышения эффективности тестового контроля является адаптивный подбор направленности и сложности ТЗ (тестовых заданий) на каждом этапе их предъявления [1; 2], т. е.  $\beta^{(k+1)} = \text{Fun}(\beta^{(k)}, S^{(k)}, k = 1..K)$ , где  $\beta^{(k)}$  – сложность ТЗ,  $S^{(k)}$  – ответ на ТЗ; **Fun** – некоторая функция формирования параметров ТЗ на следующем шаге тестирования.

Если на каждом шаге тестового контроля ответ тестируемого не зависит от результатов предыдущих ответов, то формально данный процесс можно представить в виде цепи Маркова [3], в которой состояния представляют классы тестовых заданий определенного уровня сложности, а переходные вероятности определяются на основании соотношения сложности ТЗ и уровня знаний.

### Построение цепи Маркова

Для марковской цепи (рис. 1) наиболее простые адаптивные процедуры вероятности перехода на более низкий уровень сложности определяются как  $q_i = 1 / \left[ 1 + \exp \frac{\alpha}{\sigma} (\theta - \beta_i) \right]$ , где  $\theta$  – уровень знаний тестируемого, а на более высокий –  $p_i = 1 - q_i$ .




Рис. 1. Марковская цепь процедуры адаптивного теста

Для такой МЦ стационарные вероятности определяются как  $\pi_i = \pi_0 \exp\left(\sum_{k=1}^i (\Theta - \beta_k)\right)$ ,  $i = \overline{1, I}$  (рис. 2),  $\pi_0$  представляет нормирующую константу.




Рис. 2. Стационарные распределения МЦ для различных уровней знаний

Одно из объяснений эффективности такой процедуры связано с тем, что большую часть всего тестирования сложность заданий находится на уровне знаний тестируемого, т. е. вероятность правильного ответа  $1/2$ .

### Ошибочные классификации

В рамках оценки эффективности адаптивной процедуры предложен алгоритм, основанный на подходе повторных испытаний по методу Монте-Карло. Для каждого заданного уровня знаний и предложенной процедуры тестового контроля на основе ИРТ-модели разыгрываются ответы тестируемого. Затем по методу максимального правдоподобия [4] для полученной цепочки ответов вычисляется уровень знаний, для которого эта цепочка имеет максимальную вероятность. То есть каждому истинному уровню знаний ставится в соответствие классификационный. Такая процедура повторяется достаточно большое количество раз. В результате получается матрица ошибочной классификации (таблица)  $\Phi = \|a_{ij}\|$ , где элемент  $a_{ij}$  определяет долю классификационных уровней знаний  $j$ , которые назначаются истинному уровню знаний  $i$ .

### Матрица ошибочных классификаций

№	1	2	3	4	5	6	7	8
1	0,93	0,07	0	0	0	0	0	0
2	0,06	0,90	0,04	0	0	0	0	0
3	0	0,08	0,88	0,04	0	0	0	0
4	0	0	0,09	0,88	0,03	0	0	0
5	0	0	0	0,09	0,85	0,06	0	0
6	0	0	0	0	0,06	0,85	0,09	0
7	0	0	0	0	0	0,03	0,88	0,09
8	0	0	0	0	0	0	0,03	0,89

Проведен ряд экспериментов по сравнительному анализу эффективности различных тестов. Для различных структур тестов, а также различной параметризации адаптивных тестов построены матрицы ошибочных классификаций.

Для визуализации матрицы ошибочных классификаций имеются различные представления. Например, для различных тестов можно построить графики, представляющие долю ошибочных классификаций. На рис. 3 приведены результаты моделирования по разработанному алгоритму для различных структур тестов, т. е. в которых есть только легкие ТЗ (L), ТЗ средней степени сложности (M), только сложные ТЗ (C), и для предложенной адаптивной процедуры (A).




Рис. 3. Ошибочные классификации для различных тестов

В результате показано, что L-тесты практически не различают хорошо подготовленных, C-тесты – плохо подготовленных. В то же время при том же количестве ТЗ адаптивный тест дает значительно лучшие результаты по классификации обучаемых.

#### Библиографический список

1. Яворский В. В., Ашкенова Ш. А., Баширов А. В. Модели адаптивного компьютерного тестирования // Международный журнал экспериментального образования. 2016. № 7. С. 39–41. URL: <https://expeducation.ru/ru/article/view?id=10279> (дата обращения: 31.08.2024).
2. Чумакова Е. В., Корнеев Д. Г., Гаспарян М. С. Разработка метода адаптивного тестирования на основе нейротехнологий // Открытое образование. 2022. Т. 26, № 2. С. 4–13.
3. Марковская математическая модель динамического адаптивного тестирования активного агента / Н. В. Бровка, П. П. Дьячук, М. В. Носков, И. П. Перегудова // Информатика и образование. 2018. № 10(299). С. 29–35.
4. Адаптивная модель тестирования нескольких компетенций на основе алгоритма Байеса / В. Н. Гусятников, Т. Н. Соколова, А. И. Безруков, И. В. Каюкова // Современные наукоемкие технологии. 2022. № 1. С. 40–46.

**В. В. Фомин\***

доктор технических наук, профессор

**И. К. Фомина\*\*\***

кандидат технических наук, доцент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

\*\*Государственный университет морского и речного флота имени адмирала С. О. Макарова, Санкт-Петербург, Россия

## ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ В АЛГОРИТМАХ ВОЗРАСТНОЙ ГРАДАЦИИ ШКОЛЬНОЙ ЛИТЕРАТУРЫ

Разработана оригинальная методика автоматической классификации текстов по уровню сложности в зависимости от возраста читателя на русском языке. Она учитывает стиль письма и основана на цифровой модели извлечения синтаксических и морфологических естественно-языковых частотных индексов текстов. Также представлена технология применения алгоритмов машинного обучения по классу деревьев решений для извлечения закономерностей классификации и формирования логической модели знаний. Приведены результаты серии экспериментов, которые оценивают эффективность предложенного цифрового решения для автоматической возрастной градации, а также для оценки уровня сложности текстов в художественной литературе, рекомендованной для чтения в школе.

**Ключевые слова:** возрастная градация, методы машинного обучения, естественно-языковые цифровые модели, text-mining, школьная литература.

**V. V. Fomin\***

Dr. Sc., Tech., Professor

**I. K. Fomina\*\*\***

PhD, Tech., Assistant Professor

\*St. Petersburg State University of Aerospace Instrumentation

\*\*Admiral Makarov State University of Maritime and Inland Shipping, St. Petersburg, Russia

## APPLICATION OF MACHINE LEARNING METHODS IN AGE GRADING ALGORITHMS FOR SCHOOL LITERATURE

An original method for automatic classification of texts by complexity level depending on the age of the reader in Russian has been developed. It takes into account the writing style and is based on a digital model for extracting syntactic and morphological natural language frequency indices of texts. The technology for using machine learning algorithms for the class of decision trees to extract classification patterns and form a logical knowledge model is also presented. The results of a series of experiments are presented that evaluate the effectiveness of the proposed digital solution for automatic age grading, as well as for assessing the complexity level of texts in fiction recommended for reading at school.

**Keywords:** age gradation, machine learning methods, natural language digital models, text mining, school literature.

С развитием интернет-технологий и увеличением объема и доступности информации, активным внедрением цифровых технологий в образовательный процесс возрастает важность контроля качества цифрового контента. Значительный потенциал повышения эффективности внедрения цифрового обучения заложен в методах анализа текстового образовательного материала, его информационной сложности, исследованиях факторов влияния на образовательный процесс [1; 2].

Одна из задач анализа сложности текстового материала на естественном языке – возрастная градация [2–4]. Возрастная градация литературы в школе способствует развитию критического мышления и навыков анализа у учащихся, позволяет адаптировать обучение к потребностям, интересам и способностям учеников разных возрастов, их образовательному уровню подготовки, учитывать особенности когнитивного и эмоционального развития школьников.

Цель исследований – повышение эффективности компьютерной интеллектуальной поддержки при обработке естественно-языковых текстов и экспертной возрастной градации школьной литературы.

Поиск универсального интегрального показателя уровня возрастной сложности, который позволил бы однозначно определить степень удобочитаемости в цифровом виде, привел к появлению ряда эмпирических метрик, в том числе [2; 5]: Flesch-Kincaid Grade Level (FKGL) основана на количестве слов в предложении, длине слов и сложности предложений; Coleman-Liau Index (CLI) учитывает количество сложных слов в предложении; SMOG Index разработана для анализа сложности текста на английском языке и основана на длине слов, количестве предложений и общем уровне сложности; Dale-Chall предоставляет числовую оценку сложности понимания при чтении англоязычного текста. Эмпирические метрики позволяют численно и в общем виде характеризовать степень сложности текста.

Алгоритмы извлечения из текста различных лингвистических показателей с расширением до эвристических метрик и законов, полученных эмпирическим путем, стали основой для вычислительных методов возрастной градации [2; 3; 6]. Достоинством этих алгоритмов является большое количество формализованных профессиональных характеристик (тошнота, водность, лексическое разнообразие, плотность слов и т. д.) и разработанные эффективные статистические модели. Метрики сложности текста привязаны к английскому языку с опорой на частотные тематические словари. При анализе иноязычного текста необходимо создание новых метрик с учетом специфики языка, исторических, социальных, терминологических и других изменений в естественном языке, литературе.

В последние десятилетия с появлением нейросетевых языковых моделей (BERT, Open AI, GPT и др.) достигнута высокая точность в задачах классификации текста и извлечения информации [4; 7]. При всех неоспоримых достоинствах этих моделей они имеют ряд очевидных недостатков, в том числе: достаточно сложные в использовании настройки; ресурсоемкие алгоритмы на базе искусственных нейронных сетей; сложные для интерпретации, понимания и объяснения.

Исследования авторов [8; 9] лежат в области text-mining, поиска закономерностей в задачах тематической и стилистической классификации русскоязычных текстов, совершенствования моделей представления текста. Приоритет отдан наиболее упрощенной модели представления текста в виде набора частотно-морфологических и ряда частотно-синтаксических показателей. В качестве базового классификатора используется метод «дерева решений» (DT). Он позволяет сформировать логическую модель знаний, которая предоставляет возможность интерпретировать и анализировать получаемые закономерности, а также создавать независимые от репозитория и облачных технологий алгоритмы и программы автоматизированного распознавания текстов. Применяемые в экспериментах другие методы машинного обучения служат дополнительным аналитическим материалом для оценки и сравнения потенциального повышения качества классификации.

Проведем проверку применимости разработанной модели к системе классификации по «сложности» рекомендованной к изучению художественной и научно-популярной литературы в школьном возрасте с градацией по трем уровням.

**Формирование и маркировка репозитория текстов.** Для формирования репозитория текстов использовались электронные библиотеки с детской, школьной художественной литературой и факультативной литературой по истории, философии для старших классов. Каждый текст представляет собой ограниченный ознакомительный фрагмент издания, не требующий лицензии.

Количество объектов в генеральной выборке 300. Выборка сбалансирована, разбиение и маркировка произведены по трем классам сложности по 100 объектов в каждом: младшая школа (рекомендована до 5-го класса); средняя школа (с 5-го по 9-й класс); старшая школа (рекомендована с 9-го по 11-й класс).

**Исходные установки классификации.** Метод «дерево решений» (TD) машинного обучения: алгоритм классификации CART, ограничения по дереву – 8 узлов. Метод «искусственные нейронные сети» ANN: алгоритм классификации **многослойный перцептрон (MLP)**, двухслойный, количество нейронов в скрытых слоях 50–10. Тестовая выборка 30% от генеральной. Перекрестная проверка (кросс-валидация), кратность проверки 4.

**Эксперимент 1.** Количество параметров 55.

TD. Результаты проведения перекрестной проверки: [0.84; 0.88; 0.84; 0.90], 0.87 точность со стандартным отклонением 0.02. Обобщенный отчет тестирования представлен в табл. 1.

Таблица 1

Обобщенный отчет тестирования TD (55 параметров)

Класс сложности	precision	recall	f1-score	support
Младшая школа	0.84	0.87	0.85	30
Средняя школа	0.81	0.83	0.82	30
Старшая школа	1.00	0.93	0.97	30
accuracy			0.88	90

ANN. Результаты проведения перекрестной проверки: [0.90; 0.94; 0.87; 0.90], 0.90 точность со стандартным отклонением 0.03. Обобщенный отчет тестирования представлен в табл. 2.

Таблица 2

Обобщенный отчет тестирования ANN (55 параметров)

Класс сложности	precision	recall	f1-score	support
Младшая школа	0.86	0.93	0.89	27
Средняя школа	0.93	0.86	0.89	29
Старшая школа	1.00	1.00	1.00	34
accuracy			0.93	90

Результаты эксперимента демонстрируют достаточно точный результат (accuracy = 0.88) для TD и потенциально скрытые закономерности для улучшения точности по результатам моделирования ANN (accuracy = 0.93).



**Эксперимент 2.** Количество параметров 345. Увеличение параметров за счет коллокации (биграмм) частей речи.

TD. Результаты проведения перекрестной проверки: [0.84; 0.85; 0.91; 0.90], 0.88 точность со стандартным отклонением 0.03. Обобщенный отчет тестирования представлен в табл. 3.

Таблица 3

**Обобщенный отчет тестирования TD (345 параметров)**

Класс сложности	precision	recall	f1-score	support
Младшая школа	0.82	0.90	0.86	30
Средняя школа	0.89	0.80	0.84	30
Старшая школа	1.00	1.00	1.00	30
ассурасу			0.90	90

ANN. Результаты проведения перекрестной проверки: [0.91; 0.93; 0.92; 0.74], 0.88 точность со стандартным отклонением 0.08. Обобщенный отчет тестирования представлен в табл. 4.

Таблица 4

**Обобщенный отчет тестирования ANN (345 параметров)**

Класс сложности	precision	recall	f1-score	support
Младшая школа	0.81	0.93	0.86	27
Средняя школа	0.88	0.79	0.84	29
Старшая школа	1.00	0.97	0.99	34
ассурасу			0.90	90

Результаты эксперимента показывают, что расширение параметров модели за счет коллокации не повлияло на точность классификации.

### Заключение

Проведены исследования по совершенствованию методов цифровой обработки русскоязычных текстов в развитии проблематики стилистической классификации в задачах возрастной градации с опорой на морфологическую и синтаксическую структуры с включением алгоритмов и моделей машинного обучения. Разработаны модель, компьютерная программа, методика возрастной градации школьной литературы с применением частотно-морфологического, интеллектуального анализа, который значительно менее требователен к вычислительным ресурсам, чем современные языковые модели глубокого обучения.

Автоматическая система возрастной градации может значительно ускорить процесс классификации, маркирования, цензурирования литературных произведений, помочь преподавателям и обучающимся более эффективно управлять своими учебными ресурсами, формировать рекомендации по улучшению качества образования.

### Библиографический список

1. Мизернов И. Ю., Гращенко Л. А. Анализ методов оценки сложности текста // Новые информационные технологии в автоматизированных системах. 2015. № 18. С. 572–581.
2. Лапошина А. Н., Лебедева М. Ю. Текстометр: онлайн-инструмент определения уровня сложности текста по русскому языку как иностранному // Русистика. 2021. Т. 19, № 3. С. 331–345.
3. Образцы тестовых блоков по уровням. Русский язык повседневного общения для взрослых и детей школьного возраста // Государственный институт русского языка им. А. С. Пушкина. URL: <https://www.pushkin.institute/certificates/cct/tests-online/> (дата обращения: 02.07.2024).
4. Классификация текстов по уровням CEFR с использованием методов машинного обучения и языковой модели BERT / Н. С. Лагутина, К. В. Лагутина, А. М. Бредерман, Н. Н. Касаткина // Моделирование и анализ информационных систем. 2023. Т. 30, № 3. С. 202–213.
5. Solovyev V., Ivanov V., Solnyshkina M. Assessment of reading difficulty levels in Russian academic texts: Approaches and metrics // Journal of Intelligent & Fuzzy Systems. 2018. Vol. 34(5). P. 3049–3058.
6. Лексические параметры учебного текста (на материале текстов учебного корпуса русского языка) / Е. В. Мартынова, М. И. Солнышкина, А. Ф. Мерзлякова, Д. Ю. Гизатулина // Филология и культура. 2020. № 3(61). С. 72–80.
7. Голубев А. А., Лукашевич Н. В. Исследование моделей нейронных сетей типа bert для анализа тональности текстов на русском языке // Научно-техническая информация. Серия 2: Информационные процессы и системы. 2021. № 1. С. 32–41.
8. Фомин В. В., Фомина И. К. Применение интеллектуального анализа для возрастной градации естественно-языковых текстов // Информатизация образования и науки. 2024. № 2(62). С. 78–90.
9. Фомин В. В., Фомина И. К., Осочкин А. А. Информационная технология организации системы классификации текстов // Информатизация образования и науки. 2022. № 2(54). С. 27–44.

# РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНЫХ ИНТЕРФЕЙСОВ

УДК 004.9; 373.51

*Л. Н. Бalezin\**

инженер

*Д. Ф. Виноградов\**

студент

*М. Д. Крейзо\**

студент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ РАСПОЗНАВАНИЯ РЕЧИ

Произведена разработка локальной системы транскрипции речи на основе библиотеки Whisper [1] от OpenAI, которая решает проблему транскрипции в условиях ограниченного или отсутствующего Интернета и гибкости настроек в сравнении с облачными аналогами. Система включает модули для обработки медиафайлов, транскрипции и сохранения результатов, обеспечивая необходимую точность. Представлены блок-схема алгоритма, тесты системы, подведены итоги и обозначены перспективы дальнейшего развития.

**Ключевые слова:** распознавание речи, искусственный интеллект, машинное обучение, Whisper, локальная обработка данных.

*L. N. Balezin\**

Engineer

*D. F. Vinogradov\**

Student

*M. D. Kreizo\**

Student

\*St. Petersburg State University of Aerospace Instrumentation

## USING ARTIFICIAL INTELLIGENCE FOR SPEECH RECOGNITION

A local speech transcription system has been developed based on the Whisper library [1] from OpenAI, which solves the problem of transcription in conditions of limited or absent Internet and flexibility of settings in comparison with cloud analogues. The system includes modules for processing media files, transcription and saving results, ensuring high accuracy. A block diagram of the algorithm, system tests are presented, the results are summarized and prospects for further development are outlined.

**Keywords:** speech recognition, artificial intelligence, machine learning, Whisper, local data processing.

Цель данной работы – разработка системы автоматической транскрипции речи, которая обеспечивает локальную обработку данных с использованием современных технологий искусственного интеллекта.

Большинство технологий распознавания речи базируется на облачной инфраструктуре, что не позволяет использовать их в условиях ограниченного или отсутствующего Интернета и может быть решающим фактором при выборе системы транскрипции. Основные проблемы, которые решает предлагаемая система, – простота использования, высокая точность распознавания речи, и гибкость настроек. Система позволяет автоматизировать обработку аудиофайлов и интегрироваться с различными форматами данных, что упрощает их дальнейшую интеграцию в различные системы.

Рассмотрим различные системы распознавания речи.

– DeepSpeech предлагает офлайн-распознавание с поддержкой русского языка, но точность средняя, и требуется серьезная настройка.

– Kaldi обеспечивает очень высокую точность, но требует сложной настройки и больших ресурсов. Это мощное офлайн-решение, но сложное в использовании.

– Яндекс SpeechKit и Tinkoff VoiceKit – облачные решения с высокой точностью, но требуют постоянного интернет-подключения.

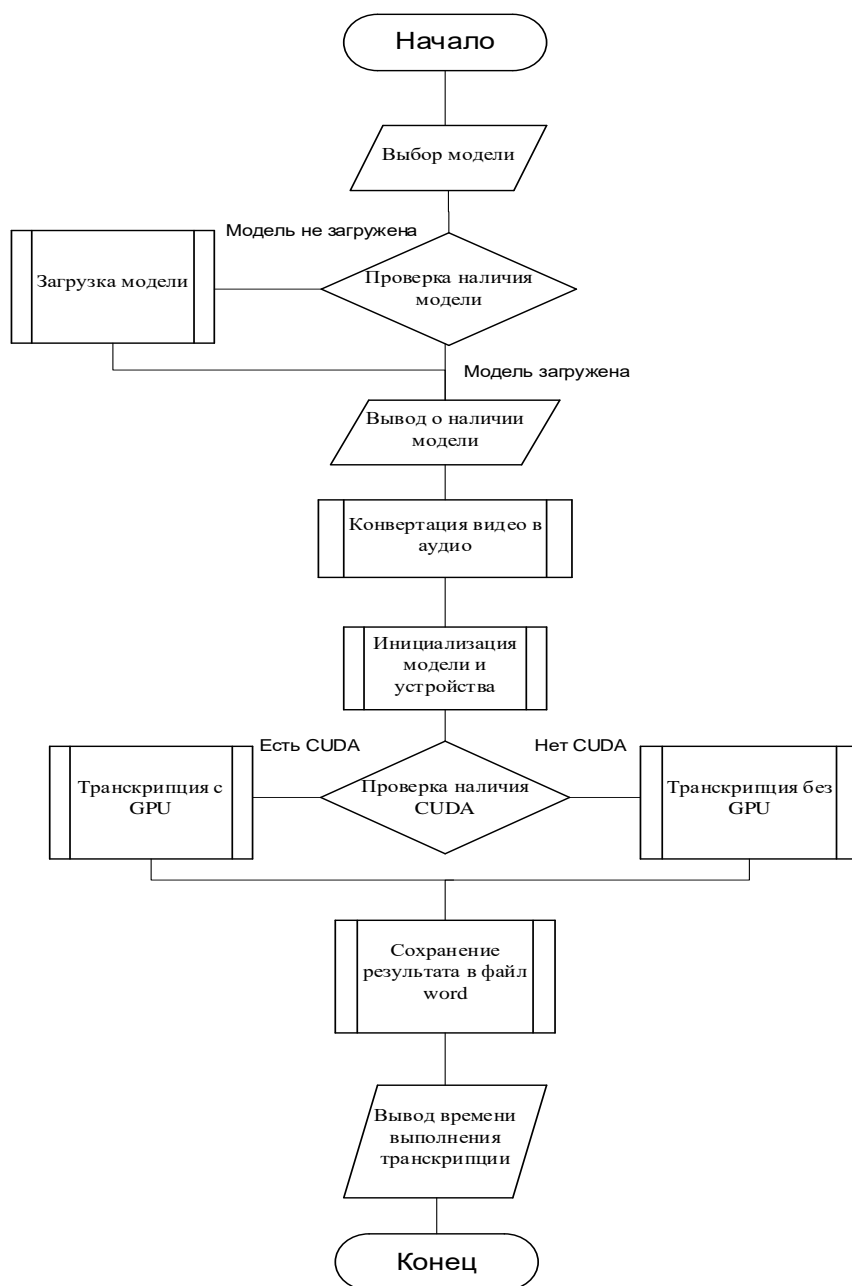
– Whisper [1] от OpenAI – библиотека для автоматического распознавания речи без подключения к Интернету, основанная на нейросетях и разработанная OpenAI. Отличается высокой точностью и универсальностью, легко интегрируется с различными системами и библиотеками, поддерживает GPU для ускорения обработки, что делает Whisper удобным и универсальным решением для задач распознавания речи.

После сравнения описанных продуктов для системы распознавания речи была выбрана библиотека Whisper. Кратко подытожим ключевые проблемы, которые система решает, основываясь на рассмотрении аналогов:

- гибкость настроек – локальная система на основе Whisper позволяет адаптировать параметры под конкретные задачи;
- отсутствие зависимости от интернет-соединения – позволяет работать с данными в любых условиях;
- простота использования – в отличие от многих других систем, Whisper не требует для своей работы глубокой настройки зависимостей, что позволяет легко развернуть данную систему на необходимом устройстве.

### Разработка архитектуры системы

Основная архитектура включает модули загрузки и обработки медиафайлов, модуль транскрипции и модуль сохранения результатов. Система может принимать как и аудио-, так и видеофайлы, конвертируя их в аудио для дальнейшей транскрипции. Для обработки медиафайлов использовалась библиотека MoviePy [2], а для сохранения текста в файлы – python-docx [3]. Полный алгоритм изложен в блок-схеме на рисунке.



Блок-схема алгоритма работы системы распознавания речи

В рамках проекта была реализована функция преобразования речи в текст с использованием моделей различного размера из библиотеки Whisper от OpenAI. Эти модели различаются по количеству параметров, что влияет на их точность и производительность: чем больше размер модели, тем выше точность распознавания, но при этом увеличиваются требования к вычислительным ресурсам и времени работы.

– Tiny – самая маленькая и быстрая модель, но с наименьшей точностью. Подходит для задач с ограниченными ресурсами.

– Base – немного точнее, чем Tiny, при этом также достаточно быстрая.

– Small – модель с хорошим балансом между точностью и скоростью, подходит для большинства задач.

– Medium – более точная модель, требует больше ресурсов и времени на обработку.

– Large – самая точная, но и самая медленная модель, лучше всего подходит для сложных задач, где важна максимальная точность.

Выбор модели зависит от требований к точности и доступных вычислительных ресурсов.

### Объединение и тестирование

Все модули системы были объединены в программу, которая автоматизирует процесс транскрипции. Для определения точности в работе используется Word Error Rate (WER) – метрика для оценки точности систем распознавания речи. Она вычисляется как отношение суммы ошибок вставки, замены и пропуска к общему количеству слов в правильном тексте:

$$WER = \frac{I + S + D}{N},$$

где  $I$  – количество вставок;  $S$  – количество замен;  $D$  – количество пропусков;  $N$  – общее количество слов в правильном тексте. После нахождения метрики мы вычтем WER из общего количества слов, получив точность распознавания речи.

Было произведено тестирование разных моделей на трех отрезках речи в 100 слов без использования GPU, после чего было взято среднее значение результатов. Тестирование проводилось на ПК с процессором Intel Core i7-9700F, видеокартой NVIDIA GTX 1660 Ti и 16 ГБ оперативной памяти DDR4. Начиная с модели Medium, система дает большую точность распознавания речи, около 97% что можно считать хорошим результатом.

Также было проведено сравнение (таблица) времени обработки с использованием GPU с технологией CUDA и без него на трех отрезках речи в 100 слов с использованием модели Large, после чего было взято среднее значение результатов. Время обработки с GPU составило 234 с против 895 без использования GPU.

### Сравнение моделей

Модель	Точность, %	Время исполнения, с
Tiny	81	9
Base	85	27
Small	92	62
Medium	97	296
Large	99	895

### Заключение

Проект разработки системы автоматической транскрипции речи на основе библиотеки Whisper от OpenAI продемонстрировал высокую точность и скорость транскрипции. Одно из ключевых преимуществ – локальная обработка данных, что обеспечивает выполнение транскрипции независимо от подключения к Интернету. Гибкость системы позволяет выбирать между различными моделями, оптимизируя баланс между точностью и скоростью работы в зависимости от задач и ресурсов. Автоматизация рутинных процессов транскрипции значительно сокращает время и трудозатраты, а интеграция с популярными библиотеками, такими как MoviePy, обеспечивает совместимость с различными форматами данных. Проведенные тесты на наборах данных подтвердили высокую точность распознавания. При использовании GPU значительно ускоряется процесс обработки. Проект продемонстрировал потенциал дальнейшего развития, включая возможности расширения функционала системы.

### Библиографический список

1. Introducing Whisper. URL: <https://openai.com/index/whisper/> (дата обращения: 26.07.2024).
2. Описание проекта MoviePy. URL: <https://pypi.org/project/moviepy/> (дата обращения: 26.07.2024).
3. Библиотека Python-docx. URL: <https://python-docx.readthedocs.io/en/latest/> (дата обращения: 28.07.2024).
4. Кому и для чего нужен PyTorch. URL: <https://blog.skillfactory.ru/glossary/pytorch/> (дата обращения: 28.07.2024).

*М. В. Ильиных\**

студент

*Е. Л. Турецкая\**

кандидат технических наук, доцент – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ПЕРСПЕКТИВЫ ВНЕДРЕНИЯ ГОЛОСОВЫХ ПОМОЩНИКОВ В ИНТЕРФЕЙСЫ ГРАФИЧЕСКИХ РЕДАКТОРОВ

Рассмотрены возможности внедрения технологии голосового помощника в интерфейсы графических редакторов и выделены следующие преимущества их использования: быстрый доступ к функциям и командам; доступность для пользователей с ограниченными возможностями; увеличение рабочего пространства за счет минимизации визуальных элементов интерфейса. Также показаны проблемы, которые сопровождают процесс внедрения. Приведен пример результата голосового запроса с помощью расширения VoiceWave в нейросети Leonardo.Ai.

**Ключевые слова:** голосовой интерфейс, голосовой помощник, искусственный интеллект.

*M. V. Ilyinykh\**

Student

*E. L. Turnetskaya\**

PhD, Tech., Associate Professor – Scientific Adviser

\*St. Petersburg State University of Aerospace Instrumentation

## PROSPECTS OF IMPLEMENTING VOICE ASSISTANTS IN GRAPHIC EDITORS' INTERFACES

The possibilities of introducing voice technology into the interfaces of graphic editors are considered and the following advantages of their use are highlighted: quick access to functions and commands; accessibility for users with disabilities; increasing the workspace by minimizing visual elements of the interface. The problems that accompany the implementation process are also shown. An example of voice query result using VoiceWave extension in Leonardo.Ai neural network is presented.

**Keywords:** voice interface, voice assistant, artificial intelligence.

Разработчики графических редакторов совершенствуют алгоритмы работы инструментов, внедряют новые функции, инструменты, плагины. На данный момент пользователи продолжают осваивать недавнее нововведение в редакторах – искусственный интеллект (ИИ) [1]. Искусственный интеллект вошел в жизнь человека ярко и уверенно. Сейчас это новшество используют не только для генерации текста, картинок и сообщений в чат-ботах. Нейросети помогают оптимизировать аналитику всех данных, с которыми работает человек в обычной жизни. Отдельной веткой прогресса можно назвать появление голосовых помощников, в которых так же используется ИИ [2].

Голосовой помощник – это программа, в которой реализованы такие технологии, как распознавание голоса, обработка языка/речи, искусственный интеллект, а также синтез голоса для точного и эффективного выполнения задач по запросу пользователя. Голосовое управление – следующая эволюция человеко-машинного взаимодействия благодаря достижениям в области облачных вычислений, искусственного интеллекта (ИИ) и интернета вещей (IoT). В последние годы активное использование смартфонов привело к появлению голосовых помощников, таких как Siri от Apple, Google Assistant, Cortana от Microsoft, Алиса от «Яндекс» и Alexa от Amazon [3]. Голосовой интерфейс необходим для IoT-устройств, лишенных сенсорных возможностей. Помимо смартфонов, голосовые помощники теперь встроены в устройства, оснащенные микрофоном и динамиком для общения с пользователями, которые называются «умными колонками».

Облачные платформы позволяют использовать голосовые помощники в миллионах домов. Голосовые помощники полагаются на облачную архитектуру, поскольку данные приходится пересылать туда-сюда в централизованные центры обработки данных. Большая часть вычислений и обработки данных искусственного интеллекта происходит как раз в облаке, а не в самом устройстве. Основная идея заключается в том, что пользователь делает запрос через устройство с голосовым управлением, затем голосовой запрос передается в облако, и здесь голос преобразуется в текст путем обработки частотной характеристики. Затем текстовый запрос проходит анализ и обработку, и после обработки получаем ответ в текстовом виде. Наконец, текстовый ответ проходит через облако и преобразуется в голос, который передается обратно пользователю.

Условно можно выделить три вида голосовых помощников.

1. Голосовые помощники общего назначения.

К этой категории относятся такие ассистенты, как Siri, Google Assistant, Алиса от «Яндекс» и Alexa от Amazon. Эти голосовые помощники помогают в решении повседневных задач обычного потребителя. Они подвергаются постоянным исследованиям и разработкам, сопровождаемым многочисленными исправлениями и обновлениями, чтобы донести до потребителя передовые технологии.

## 2. Голосовые помощники в приложениях.

Внедряются в приложения ведущих компаний, чтобы создать чрезвычайно плавный и удобный для пользователя интерфейс. Эти помощники специально настраиваются в соответствии с продуктами/услугами, предлагаемыми каждой компанией. В результате потребитель получает действительно персонализированный и бесшовный опыт.

## 3. Собственные ассистенты.

Голосовые помощники, принадлежащие таким компаниям, как Apple и Microsoft, но включаемые в другие приложения по требованию.

Голосовое взаимодействие часто быстрее, чем набор текста или навигация по меню [4]. Обеспечивая более разговорный и персонализированный подход, голосовые пользовательские интерфейсы (VUI) способствуют большей вовлеченности и удовлетворенности пользователей при разработке пользовательского интерфейса. Пользователи могут взаимодействовать с приложениями с голосовым управлением, занимаясь другими делами, что повышает производительность и многозадачность. Голосовые интерфейсы могут адаптироваться к особенностям речи и предпочтениям пользователей, предлагая персонализированный опыт, который улучшается с течением времени [5].

В апреле 2024 г. стал доступен веб-сервис с генеративной моделью ИИ Adobe Firefly [6]. В ее возможности входит написание позитивных и негативных запросов для генерации изображений, скачивание изображения, изменение пропорций, элементы управления стилями, различные применяемые эффекты, параметры света, цвета, композиции и интенсивности стиля. Эта нейросеть также предоставляет возможность генеративного изменения заливки, наложения текстовых эффектов и генерацию векторных изображений. Сейчас разработчики Adobe Firefly работают над возможностями преобразования 3D-моделей и эскизов в изображения.

Основными ключами внедрения технологии голосового управления являются алгоритмы обработки естественного языка и искусственный интеллект для анализа и интерпретации данных, что подтверждает возможность внедрения голосовых помощников в интерфейсы графических редакторов. После релиза программного пакета Adobe с генеративным ИИ открываются новые возможности в области голосового взаимодействия. Рассматривая вероятность внедрения голосовых помощников в интерфейсы графических редакторов, можно выделить следующие *преимущества*.

- Быстрый доступ к функциям и командам.

Безусловно, многие дизайнеры, в особенности опытные, работают в редакторах, используя комбинации клавиш («горячие» клавиши) для увеличения скорости работы. Но количество клавиш, как и гибкость руки, ограничено, поэтому иногда все равно приходится потратить время для вызова определенной функции или активации плагина. Время, потраченное на поиск необходимого функционала, сократится с голосовым управлением, тем самым увеличит продуктивность.

- Доступность для пользователей с ограниченными возможностями.

Возможность голосового управления снизит нагрузку на органы зрения, а также минимизирует использование рук при работе, что привлечет людей с ограниченными возможностями и приведет к сокращению возникновения туннельного синдрома у сотрудников офиса.

- Увеличение рабочего пространства за счет минимизации визуальных элементов интерфейса.

Так как пропадет необходимость наличия всех панелей инструментов перед глазами, вкладок и дополнительных окон, рабочее пространство (холст, монтажная область) станет больше, пользователь сосредоточится на работе, а нагрузка на графический интерфейс будет снижена.

Вместе с преимуществами необходимо рассмотреть и потенциальные *ограничения*.

- Техническая терминология.

В каждом графическом редакторе имеется свой словарь терминов, которые обязательно нужно будет внести в голосовые сценарии. Из-за специфической терминологии могут возникнуть проблемы при распознавании запросов пользователей.

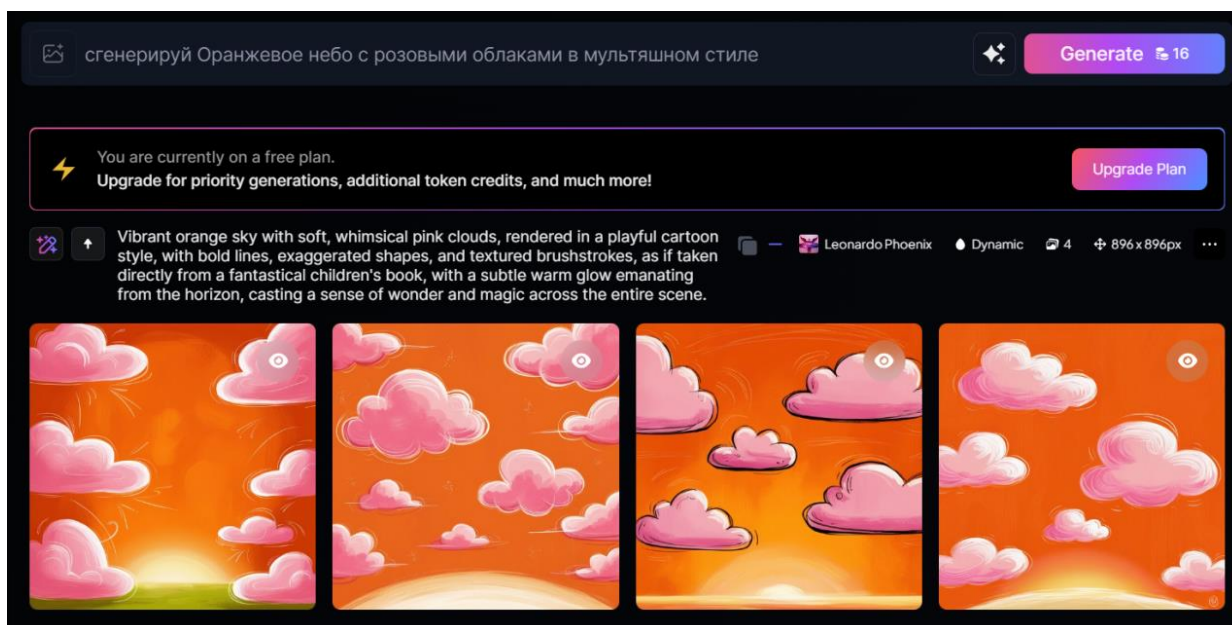
- Проблемы с производительностью.

Команды голосового управления могут требовать какое-то время на обработку входящего запроса, что может замедлить рабочий процесс по сравнению с простым нажатием мыши.

- Отказ пользователей от голосового управления.

Не все пользователи положительно относятся к переменам из-за нежелания тратить время на переобучение, недоверия к системе безопасности или предпочтений к использованию обычными мышками. Усилить нежелание переходить на голосовой интерфейс может необходимость в точных формулировках задач, от которых зависит результат.

На данный момент альтернативой голосовому помощнику в графических редакторах могут служить расширения браузера для голосового ввода в совокупности с онлайн-сервисами генерации изображений или голосовой ввод в чате с Алисой от Яндекса. На рисунке представлен результат голосового запроса с помощью расширения VoiceWave в нейросети Leonardo.Ai [7–8].



*Генерация изображения по голосовому запросу*

В данном случае был распознан запрос о генерации изображения оранжевого неба с розовыми облаками в стиле мультфильма на русском языке. Нейросеть перевела запрос на английский язык, добавив больше описания в подходящем запросе стиле. Результат получился достойным. Минусом существующих альтернатив является лишь частичное голосовое управление, так как остается необходимость вручную взаимодействовать с элементами интерфейса. Из-за этого отсутствует возможность моментального редактирования генерируемого контента и изменения параметров генерации, что ведет к снижению продуктивности.

#### **Библиографический список**

1. *Bahaa M.* The Impact of Artificial Intelligence on the Graphic Design Industry // *Arts and Design Studies*. 2023. P. 1–9 с.
2. *Terzopoulos G., Satratzemi M.* Voice Assistants and Smart Speakers in Everyday Life and in Education // *Informatics in Education*. 2020. P. 473–490.
3. *Matthew B. Hoy.* Alexa, Siri, Cortana, and More: An Introduction to Voice Assistants // *Medical Reference Services Quarterly*, 2018. P. 81–88.
4. *Cohen M.* Voice User Interface Design. Addison-Wesley Professional, 2004. 336 p.
5. *Preston So.* Voice Content and Usability. A book apart, 2021. 131 с.
6. Adobe Creative Cloud – Adobe Firefly // Adobe. URL: <https://www.adobe.com/products/firefly.html> (дата обращения: 26.08.2024).
7. VoiceWave: голосовое управление для ChatGPT. URL: <https://voicewave.xyz/ru/> (дата обращения: 26.08.2024).
8. Leonardo.Ai: нейросеть на основе искусственного интеллекта для генерации изображений. URL: <https://app.leonardo.ai/> (дата обращения: 26.08.2024).

*Д. А. Космынин\**

студент

*Е. К. Григорьев\**

старший преподаватель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## МЕТОД РАСПОЗНАВАНИЯ СИНТЕЗИРОВАННОЙ РЕЧИ НА ОСНОВЕ ВЫЧИСЛЕНИЯ ЭНТРОПИИ АУДИОСИГНАЛА

Предложен метод распознавания синтезированной речи, основанный на вычислении энтропии аудиосигнала, где ось ординат сигнала разбивается на  $n + k$  интервалов так, что  $n$  интервалов находится на сегменте  $[\min_{\text{среднее}}; \max_{\text{среднее}}]$ , а  $k$  интервалов расположены так, что нулевой и  $n + k - 1$  интервалы включают глобальный минимум и глобальный максимум соответственно и затем вычисляется энтропия по Шэннону. Выявлено, что энтропия синтезированной речи всегда существенно выше энтропии записи реальной речи, а также синтезированная речь более целостно заполняет значениями почти все доступные интервалы, причем форма этого распределения слабо изменяется от записи к записи. Вероятность попадания в интервалы значений оригинальной речи ведет себя более хаотично и имеет большую долю незаполненных интервалов по краям.

**Ключевые слова:** синтезированная речь, спуффинг, энтропия Шэннона, классификация.

*D. A. Kosmyinin\**

Student

*E. K. Grigoriev\**

Senior Lecturer

\*St. Petersburg State University of Aerospace Instrumentation

## METHOD OF RECOGNITION OF SYNTHESIZED SPEECH BASED ON CALCULATION OF AUDIO SIGNAL ENTROPY

In the work proposed method of recognition of synthesized speech, based on calculation of audio signal entropy, where the axis of the signal is divided into  $n + k$  intervals so that  $n$  intervals are on a segment  $[\min_{\text{average}}; \max_{\text{average}}]$ , and  $k$  intervals are so, that the zero and  $n + k - 1$  intervals include the global minimum and global maximum respectively, and then calculate the Shannon entropy. It was found that the entropy of synthesized speech is always significantly higher than the entropy of real speech, and also synthesized speech more integrally fills almost all available intervals with values, and the form of this distribution varies slightly from recording to recording. The probability of getting into the value intervals of the original speech behaves more chaotic and has a large proportion of empty spaces at the edges.

**Keywords:** synthesized speech, sphinging, Shannon's entropy, classification.

### Введение

В настоящее время генерация синтезированной при помощи искусственного интеллекта (ИИ) речи вышла на высокий уровень благодаря, во-первых, быстрой эволюции моделей глубокого обучения, а во-вторых, большому количеству данных для тренировки подобных моделей. Однако вместе с ростом качества синтезированной речи растет и количество кибер-атак, совершаемых с помощью синтетического голоса, что предъявляет особые требования к системам, в которых обеспечение конфиденциальности личных данных пользователей играет критическую роль.

Для решения указанной проблемы предложены несколько подходов в области распознавания синтезированной речи, которые условно можно разделить на использующие модели машинного обучения и использующие только математические свойства аудиосигнала.

Один из способов распознавания синтезированной речи с использованием моделей машинного обучения – задача классификации аудиосигнала на основе свойств оконного преобразования Фурье [1], с помощью которого вычисляются свойства обучающей выборки, такие как константное Q-преобразование, мел-частотные кепстральные коэффициенты и линейные частотные кепстральные коэффициенты. Впоследствии на данной выборке происходит тренировка моделей на основе сверточных нейронных сетей. Основными недостатками такого подхода являются громоздкость вычислений свойств обучающей выборки, зависимость кепстральных коэффициентов от уровня громкости записи и их потенциальное искажение случайными шумами. Среди достоинств можно выделить относительно высокие показатели надежности обнаружения синтезированной речи.



Известен также способ определения синтезированной речи методами биспектрального анализа, предложенный в [2]. Он требует значительных вычислительных ресурсов для преобразования спектральной мощности в биспектр, его последующей нормализации и усреднения.

Среди новых методов необходимо отметить подход к распознаванию синтезированной речи, основывающийся на обучении модели-трансформера на свойствах кусочных мел-спектрограмм [3]. Полученные методом окна Ханнинга мел-спектрограммы разбиваются на отдельные равные части и конвертируются в 768-мерное векторное пространство, являющееся обучающей выборкой. Нетрудно видеть, что подобные преобразования создают ощутимую нагрузку на ЭВМ.

Представляется перспективным подход идентификации говорящего по голосу, содержащий в основе метод вычисления энтропии аудиосигнала [4]. Среди его достоинств – отсутствие вычислительно затратной предобработки и уникальность значений энтропии для разных дикторов, в качестве недостатка следует отметить неравномерность интервалов элементарных сообщений.

Все указанные подходы обладают отдельными преимуществами, однако не решают проблему полностью, являясь лишь некоторыми из вспомогательных средств при борьбе с кибератаками, использующими синтезированную речь. Таким образом, отсутствие эффективного универсального решения подтверждает актуальность поиска новых подходов к распознаванию синтезированной речи.

Цель настоящей работы – предложение модифицированного метода распознавания синтезированной речи на основе вычисления энтропии аудиосигнала.

### Модифицированный метод вычисления энтропии аудиосигнала

Предлагаемый метод вычисления энтропии аудиосигнала является модифицированной версией метода, предложенного в [4]. Первоначально выполняется расчет средних экстремумов и производится предобработка сигнала (рис. 1). Ось ординат сигнала разбивается на  $n + k$  интервалов так, что  $n$  интервалов находится на сегменте  $[\min_{\text{среднее}}; \max_{\text{среднее}}]$ , а  $k$  интервалов расположены так, что нулевой и  $n + k - 1$  интервалы включают глобальный минимум и глобальный максимум соответственно. В отличие от оригинального метода вычисления энтропии, модифицированный метод разбивает ось абсцисс сигнала на  $m$  равных сегментов, для каждого из которых отдельно вычисляется энтропия. Итоговое значение вычисляется по формуле

$$H(X) = \frac{1}{M} \sum_{i=1}^M H(x_i).$$

В основу предлагаемого метода положено фундаментальное понятие теории информации – энтропия, мера, несущая в себе средний уровень неопределенности в измеряемой случайной величине. Для того чтобы вычислить энтропию, используется формула Шеннона:

$$H(X) = -\sum_{i=1}^n p_i \log_2 p_i, \quad (1)$$

где  $p_i$  – вероятность появления  $i$ -го элементарного сообщения.

Функция энтропии Шеннона обладает рядом важных свойств, такие как неотрицательность и ограничение сверху, зависящее от количества  $n$  элементарных сообщений. В общем случае для величины выполняется следующее неравенство:

$$H(X) = -E[\log_2 p_i] = \sum_{i=1}^n p_i \log_2 \frac{1}{p_i} \leq \log_2 \sum_{i=1}^n 1.$$

В случае если все элементарные события равновероятны, энтропия сигнала будет равна логарифму с основанием 2 от количества сообщений  $n$ .

Однако прежде чем приступить к вычислению энтропии, из сигнала необходимо предварительно удалить части, не несущие в себе полезной информации. Для предобработки сигнала используется метод средних экстремумов, позволяющий удалять фрагменты сигнала, на которых средние минимум и максимум меньше некоторого порогового значения  $\epsilon$ .

Формальная запись закона выглядит следующим образом:

$$S_{out} = \left\{ S_p \subseteq S : \left| \min_{\text{среднее}}(S_p) \right| + \max_{\text{среднее}}(S_p) > 2\epsilon \right\}, \epsilon > 0,$$

где  $S$  – множество всех значений сигнала,  $S_p$  – подмножество значений сигнала на некотором интервале,  $\min[\max]_{\text{среднее}}$  – средние минимум и максимум сигнала на этом интервале. Результат обработки показан на рис. 1.




Рис. 1. Входной сигнал (сверху) и результат предобработки (снизу)

После предварительной обработки вычисляется энтропия Шеннона для дискретного сигнала по следующему алгоритму.

1. Строится огибающая минимумов и максимумов функции, и вычисляются средние значения минимума  $\min_{\text{среднее}}$  и максимума  $\max_{\text{среднее}}$  сигнала.
2. Сегмент  $[\min_{\text{среднее}}; \max_{\text{среднее}}]$  разбивается на  $n$  равных частей, каждая из которых является элементарным сообщением.
3. Множество элементарных сообщений дополняется необходимым количеством отрезков  $k$  оси  $Y$  так, чтобы значения глобального минимума и максимума входили в крайние отрезки, тогда общее количество элементарных сообщений равно  $n + k$ .
4. Значения дискретного сигнала предварительно сортируются, и определяется принадлежность каждого из них к одному из отрезков по оси  $Y$ .
5. Вычисляется энтропия по формуле (1).

Натуральные числа  $n$  и  $k$ , определяющие количество разбиений, выбираются произвольно. По определению энтропии, чем больше число разбиений, тем больше значение функции  $H(X)$ , однако при росте  $n$  и  $k$  скорость роста  $H(X)$  значительно замедляется при  $n + k > 100\,000$ .

При экспериментальном сравнении энтропии четырех пар 5- и 25-секундных аудиосигналов синтезированного и реального голосов, произносящих одну и ту же фразу, график роста энтропии от количества разбиений  $n + k$  имеет существенные различия, как это показано на рис. 2 и 3. Фразы для анализа представлены в табл. 1 и 2.

Таблица 1


#### 5-секундные фразы, произносимые ИИ и реальным человеком

№ фразы	Текст
1	I would have been here sooner but the bus kept stopping for other people to get on it
2	Wait, what is wrong with you two? He was talking about television during their date night
3	There's no denying that I have feelings for you that can't be explained in any other way.
4	That was tricky because when it comes to alcohol, she generally means business.


## 25-секундные фразы, произносимые ИИ и реальным человеком

№ фразы	Текст
1	Alice was beginning to get very tired of sitting by her sister on the bank, and of having nothing to do: once or twice she had peeped into the book her sister was reading, but it had no pictures or conversations in it, "and what is the use of a book," thought Alice "without pictures or conversation?" So she was considering in her own mind, as well as she could, for the hot day made her feel very sleepy and stupid, whether the pleasure of making a daisy-chain would be worth the trouble of getting up and picking the daisies, when suddenly a White Rabbit with pink eyes ran close by her
2	Because of this natural empathy with the characters, our brains process the reading of stories differently from the way we read factual information. Our brains don't always recognise the difference between an imagined situation and a real one so the characters become 'alive' to us. What they say and do is therefore more meaningful. This is why the words and structures that relate a story's events, descriptions and conversations are processed in this deeper way.
3	As a child, I loved sitting on my grandfather's lap while he read me stories. I remember most of them even though I am now a grandparent, too! As a child, I was blissfully unaware that, as I listened to the stories, I was also learning new words and ways in which those new words combined to communicate ideas and life lessons. A good story encourages us to turn the next page and read more. We want to find out what happens next and what the main characters do and what they say to each other.
4	We may feel excited, sad, afraid, angry or really happy. This is because the experience of reading or listening to a story is much more likely to make us 'feel' that we are part of the story, too. Just like in our 'real' lives, we might love or hate different characters in the story. Perhaps we recognise ourselves or others in some of them. Perhaps we have similar problems.


а)



б)



в)



г)




Рис. 2. Сравнение энтропии реального (оранжевый) и синтезированного (синий) сигнала для 5-секундных записей

В процессе эксперимента было выявлено, что энтропия синтезированной речи всегда существенно выше энтропии записи реальной речи, как показано на рисунках 2, 3, независимо от громкости аудиозаписи. Также, если графически отобразить распределение вероятностей, как показано на рис. 4, попадания значения сигнала по интервалам, полученным в результате разбиения оси ординат на  $n + k$  частей, то у синтезированного голоса наблюдается характерное «замирание» вероятности в окрестностях нуля, чего не происходит у реального сигнала.

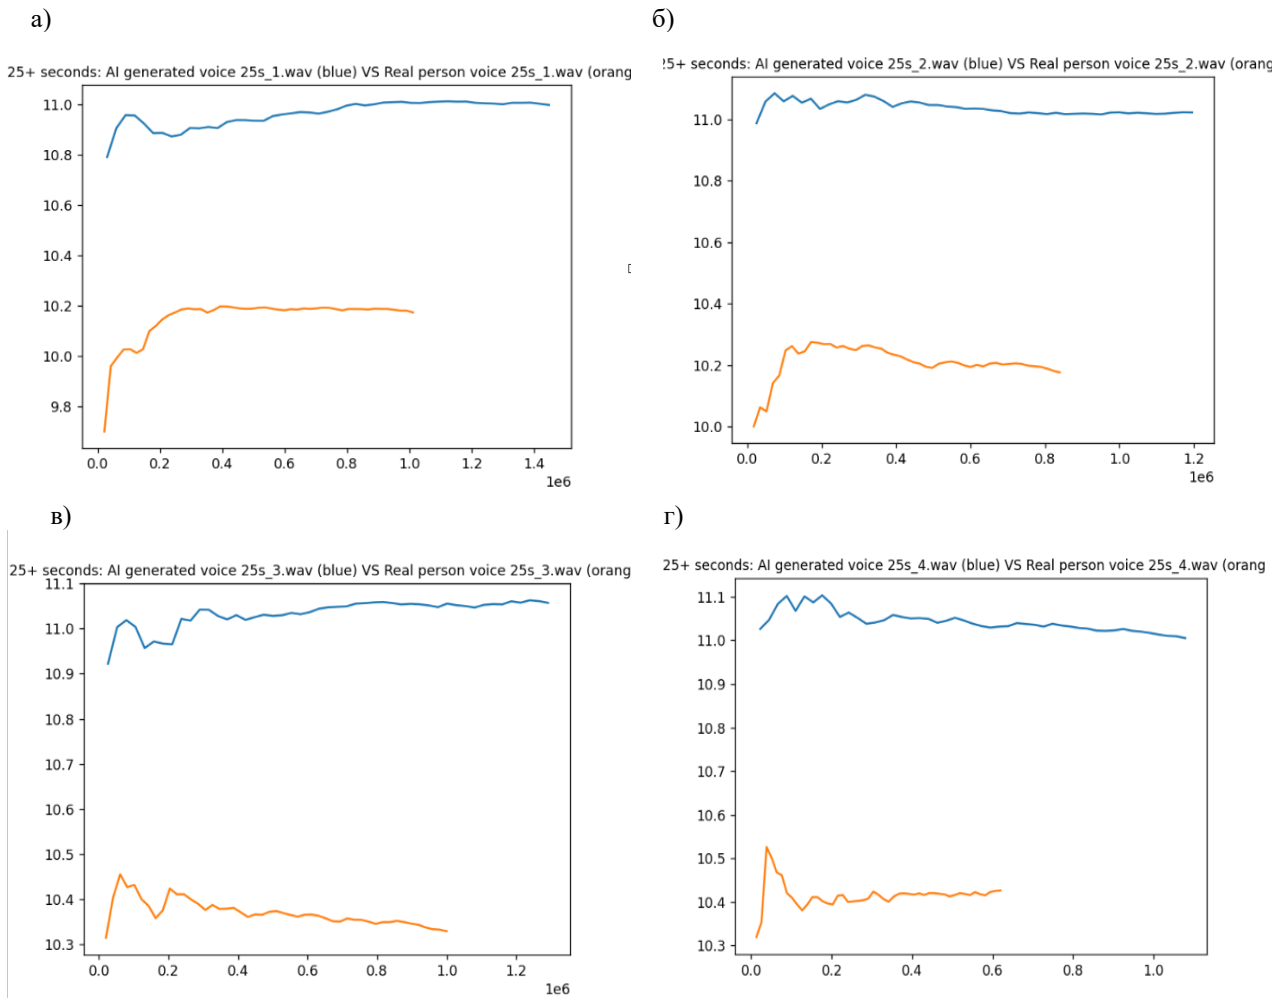


Рис. 3. Сравнение энтропии реального (оранжевый) и синтезированного (синий) сигнала для 25-секундных записей

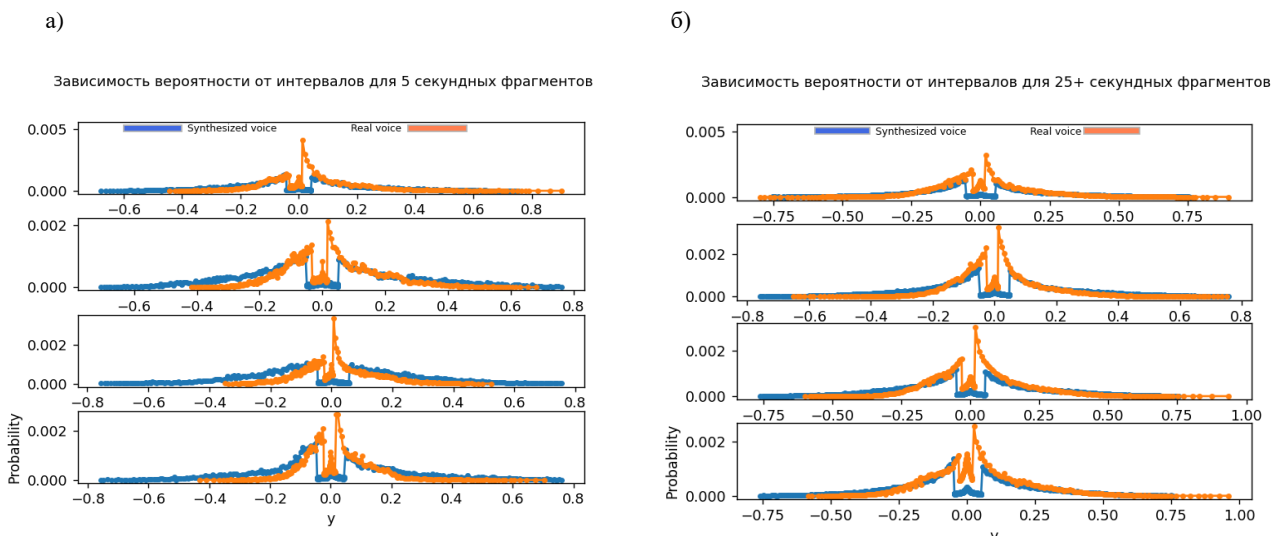


Рис. 4. Зависимость вероятности попадания значения сигнала в интервал от середины каждого интервала

На рис. 4 продемонстрировано, что синтезированная речь более целостно заполняет значениями почти все доступные интервалы, причем форма этого распределения слабо изменяется от записи к записи. Вероятность попадания в интервалы значений оригинальной речи ведет себя более хаотично и имеет большую долю незаполненных интервалов по краям, т. е., говоря статистическим языком, имеет меньший «выброс» значений сигнала относительно средних экстремумов, нежели синтетическая речь.

### Заключение

В ходе работы была предложена модификация метода подсчета энтропии сигнала. Были проведены тесты предлагаемого метода для использования в качестве средства противодействия кибератакам с использованием подмены голоса. Основными достоинствами предлагаемого решения являются отсутствие предварительной многоуровневой обработки, независимость от громкости, а также простые математические вычисления, лежащие в его основе. Значения энтропии для разных сегментов сигнала, полученные в результате обработки, могут использоваться в качестве как вспомогательного средства для анализа входного сигнала, так и свойств обучающей выборки для обучения моделей ИИ, решающих задачи кластеризации свойств реальной и синтетической речи.

Эмпирически были выявлены значимые особенности, присущие только синтетической речи, что при дальнейшем изучении может быть заложено в основу более продвинутых и универсальных систем противодействия кибератакам с использованием подмены голоса.

### Библиографический список

1. *Yang J., Das R. K.* Long-term high frequency features for synthetic speech detection // *Digit. Signal Process.* 2020. Vol. 97. P. 102622.
2. *AlBadawy E., Lyi S., H. Farid H.* Detecting AI-Synthesized Speech Using Bispectral Analysis // *CVPR Workshop.* 2019. P. 104–109.
3. *Compression Robust Synthetic Speech Detection Using Patched Spectrogram Transformer / A. K. S. Yadav, Z. Xiang, K. Bhagtani [et al.].* 2024. URL: <http://arxiv.org/abs/2402.14205> (дата обращения: 07.09.2024).
4. *Суворова В. А., Шкаранута А. П.* Разработка и возможности применения алгоритма вычисления энтропии звуковой волны // *Вестник Пермского университета.* 2016. Вып. 1(32).

*С. М. Курьян\**

директор

*М. А. Петрушкевич\**

генеральный директор

*Е. А. Селиванова\**

кандидат психологических наук, доцент

\*АО «Нейросети», Москва, Россия

## ТЕХНОЛОГИЯ NDEX5 КАК КОГНИТИВНЫЙ СЕРВИС АНАЛИЗА ПАТТЕРНОВ ПОВЕДЕНИЯ В ОНЛАЙН-РЕЖИМЕ

Рассмотрена технология NDEX5 как инструмент когнитивного анализа поведения в онлайн-режиме. Показано, что эффективность и точность данной технологии делают ее ценным инструментом для анализа больших данных и прогнозирования поведения пользователей в цифровых средах. Полученные данные являются перспективными для анализа паттернов поведения в офлайн-режиме, определения организаторов и исполнителей проектов, оценки работоспособности и ответственности субъектов взаимодействия в профессиональной среде.

**Ключевые слова:** искусственный интеллект, когнитивный анализ, поведение человека.

*S. M. Kuryan\**

Chief

*M. A. Petrushkevich\**

Chief Executive Officer

*E. A. Selivanova\**

PhD, Psychology, Associate Professor

\*Joint-Stock Company «Neural Networks», Moscow, Russia

## NDEX5 TECHNOLOGY AS A COGNITIVE SERVICE FOR ONLINE BEHAVIOR ANALYSIS

The paper considers NDEX5 technology as a tool for cognitive behavior analysis in online mode. It is shown that the efficiency and accuracy of this technology make it a valuable tool for big data analysis and user behavior prediction in digital environments. The data obtained are promising for analysis of patterns of offline behavior, identification of project organizers and executors, assessment of the efficiency and responsibility of the actors of interaction in the professional environment.

**Keywords:** artificial intelligence, cognitive analysis, human behavior.

Необходимость выстраивания продуктивного взаимодействия человека и цифровых систем, онлайн-сервисов, искусственного интеллекта (ИИ) сегодня ни у кого не вызывает сомнения. В век цифровых технологий человечество сталкивается как с новыми вызовами, так и с продуктивными, креативными находками, значительно упрощающими процессы решения многих задач. В современных условиях когнитивные сервисы, интеллектуальные помощники, цифровые персонажи активно применяются практически в каждой сфере науки и практики: образовании, медицине, бизнесе, культуре, промышленности и пр. Они автоматизируют рутинные функции специалистов, обеспечивают систематизацию информации, упрощают консалтинговую деятельность, оптимизируют разработку документов, облегчают процессы научных исследований и пр.

Ученые раскрывают широкий спектр сфер применения искусственного интеллекта, подчеркивая, что его можно эксплуатировать в обеспечении кибербезопасности путем выполнения таких функций, как: биометрическая аутентификация, ускорение обнаружения угроз, быстрое реагирование на атаки, создание динамической среды аутентификации и пр. [1]. Выделяются особенности применения ИИ в медицине для «изучения механизмов развития сахарного диабета, оптимизации методов его диагностики, профилактики и лечения» [2, с. 165]. Особенно много работ посвящено применению ИИ в области образования: для обеспечения индивидуализации обучения, адаптации его под потребности конкретной личности [3]. Отмечается, что ИИ не сможет полностью заменить педагога, но успешно используется в прогнозировании достижений обучающихся, проверке выполненных заданий, организации обратной связи [4]. В книге Г. С. Осипова описываются многочисленные направления применения ИИ в различных отраслях и сферах: представление знаний, автоматизация рассуждений, машинное обучение, интеллектуальный анализ данных, интеллектуальные программные агенты, обработка естественного языка, мягкие вычисления и пр. [5].

Кроме того, ученые и практики видят перспективы когнитивных сервисов в области осуществления психологических разработок. Специалисты описывают технологии, включающие ИИ и позволяющие анализировать

особенности восприятия информации пользователями систем видеоконференцсвязи [6]. Определяются пути оптимизации работы психолога в этой части [7], исследуются аффективные состояния пользователей виртуальной среды [8]. В результате делается вывод, что когнитивные сервисы могут существенно упростить процесс анализа паттернов поведения субъектов и предложить эффективные решения по оптимизации их деятельности. ИИ может использоваться в оценке функциональных и эмоциональных состояний личности, ее когнитивной активности, интеллектуальной и речевой продуктивности. В основном данные исследования и технологические разработки проводятся за рубежом.

В данной статье рассмотрим одну из отечественных технологий ИИ, которая представляет собой видео-конференц-связь (ВКС) с мгновенной аналитикой поведения NDEX5. Эта технология выступает когнитивным сервисом анализа пяти индексов поведения пользователей: внимательности, вовлеченности, эмоциональности, рассеянности и усталости. Индекс внимательности показывает степень сосредоточенности пользователя, индекс вовлеченности – уровень активного участия и его заинтересованность в воспринимаемой информации. Индекс эмоциональности определяет интерес и наличие положительных эмоций, возникающих в процессе коммуникации у участников онлайн-коммуникации. Индекс усталости сигнализирует о степени утомления пользователей ВКС, а индекс рассеянности – об их склонности к отвлечению.

Указанные индексы обозначаются на боковой панели системы, могут фиксироваться в скрытом и открытом режиме, давая участникам ВКС и прежде всего ее ведущему информацию о степени вовлеченности всех субъектов в рабочий процесс дистанционного взаимодействия. Удобство интерфейса ВКС NDEX5 связано с наличием цветовой индикации уровня выраженности индексов, которые определяют показатели по каждому пользователю в среднем и по всем участникам ВКС. Это позволяет ведущему при снижении вовлеченности аудитории оперативно подобрать действенные инструменты повышения ее интереса к транслируемой информации. Индексы считываются с помощью компьютерного зрения, анализируя сетку маски лица через видеокамеру, расположенную на компьютере, планшете или телефоне. С помощью ИИ рассчитываются расстояния между точками на лице, которые показывают через невербальные признаки (расположение уголков губ, бровей, направленность взгляда, ширину зрачков и пр.) описанные когнитивные индексы, применяемые для анализа паттернов поведения личности.

ВКС NDEX5 предоставляет возможность провести постаналитику когнитивных индексов для формирования обобщенного отчета о проведенном разовом мероприятии или результативности комплекса встреч. Этому способствует наличие дашборда, который обеспечивает комплексную систематизацию всех встреч на рассматриваемой платформе и показывает их эффективность. Результаты предоставляются по каждому субъекту, по всем встречам в средних значениях и по индексам в общем. Используя определенные фильтры и настройки, организатор конференций может получить для себя нужную информацию, выгрузку необходимой аналитики.

Уникальность данной ВКС заключается, кроме прочего, в возможности вести видеофиксацию каждой встречи и включать функцию speech-2-text. В результате все коммуникации фиксируются, а в последующем имеется возможность их суммаризации и автоматического формирования протокола встреч. При системном применении данной ВКС на одной и той же выборке пользователей появляется возможность провести анализ паттернов их поведения в онлайн-режиме. Данные паттерны выступают основаниями для прогнозирования моделей поведения в офлайн-режиме и наделения субъектов определенными полномочиями.

Во-первых, имеется возможность определить наиболее заинтересованных пользователей, участников встреч, которые демонстрируют высокие уровни вовлеченности и внимательности и низкие уровни рассеянности и усталости. Кроме этого, можно выявить пользователей с повышенной коммуникативной активностью и продуктивностью, которые не являются пассивными пользователями, а демонстрируют заинтересованность в профессиональных дискуссиях. Как правило, это одни и те же субъекты. Практика анализа паттернов их поведения показывает, что данные персоналии могут стать в дальнейшем руководителями проектов, организаторами мероприятий, спикерами встреч и пр.

Во-вторых, можно определить пользователей со средним уровнем активности и включенности во встречи, которые показывают средние значения по всем индексам: внимательности, вовлеченности, рассеянности и утомляемости (или низкие по последним двум индексам). Также они проявляют меньшую коммуникативную активность, но явно не игнорируют профессиональные встречи. Анализ паттернов их поведения показывает, что данные субъекты выступают хорошими исполнителями поставленных им задач. Они качественно реализуют вменяемые им функции, как правило, не срывают сроки проектов, ответственно подходят к работе. Однако они не стремятся занять лидирующие позиции и чувствуют себя комфортно в роли исполнителей, а не организаторов.

В-третьих, определяется третья категория субъектов, которые показывают низкие индексы вовлеченности и внимательности, отсутствие или слабую речевую активность и высокие индексы рассеянности и усталости. Данные субъекты в дальнейшем обнаруживают свою слабую состоятельность в реализации проектов. Они, как правило, сами покидают проекты или увольняются, отстраняются от руководства (рисунок). Индекс эмоциональности является вспомогательным, а не основным для анализа паттернов поведения, потому не рассматривается подробно в данной статье.



#### Взаимосвязь паттернов поведения пользователей с индексами их активности в ВКС NDEX5

Таким образом, систематическое, пролонгированное применение ВКС NDEX5 позволяет не только анализировать модели поведения пользователей в онлайн-режиме, но и прогнозировать их деятельность и уровень ответственности при решении разных задач при выполнении проектов. Представленные выводы сделаны на основе двухлетнего анализа паттернов поведения пользователей технологии NDEX5, включающей искусственный интеллект, отображающей когнитивную активность участников онлайн-встреч. Математические расчеты и выводы представлены в других публикациях авторов.

Технология ВКС NDEX5 обладает значительными преимуществами по сравнению с традиционными методами анализа данных. Ее когнитивный подход предоставляет более точное и оперативное понимание сложных паттернов поведения в реальном времени: онлайн-режиме и офлайн-активности субъектов. Эти выводы имеют особую важность в контексте быстро меняющихся и динамичных систем онлайн-пространства.

Технология NDEX5 представляет собой мощный инструмент когнитивного анализа поведения в онлайн-режиме. Ее эффективность и точность делают ее ценным инструментом для анализа больших данных и прогнозирования поведения пользователей в цифровых средах. Полученные данные являются перспективными для анализа паттернов поведения в офлайн-режиме, определения организаторов и исполнителей проектов, оценки работоспособности и ответственности субъектов взаимодействия в профессиональной среде.

#### Библиографический список

1. *Афанасьева Д. В.* Применение искусственного интеллекта в обеспечении безопасности данных // Известия Тульского государственного университета. Технические науки. 2020. № 2. С. 151–154.
2. *Климонтов В. В., Бериков В. Б., Сайк О. В.* Искусственный интеллект в диабетологии // Сахарный диабет. 2021. № 24(2). С. 156–166.
3. *Кузиев Б.* Искусственный интеллект в образовании // Mechatronika va robototexnika: muammolar va rivojlantirish istiqbollari. 2023. Т. 1, № 1. С. 14–17.
4. *Дробахина А. Н.* Информационные технологии в образовании: искусственный интеллект // Проблемы современного педагогического образования. 2021. № 70-1. С. 125–128.
5. *Осинов Г. С.* Методы искусственного интеллекта. М.: ФИЗМАТЛИТ, 2011. 296 с.
6. Artificial intelligence in psychology: How can we enable psychology students to accept and use artificial intelligence? / S. Gado, R. Kempen, K. Lingelbach, T. Bipp // Psychology Learning & Teaching. 2022. Vol. 21, № 1. P. 37–56.
7. *Gupta A., Balasubramanian V.* Daisee: Towards user engagement recognition in the wild // Journal of latex class files. 2015. Vol. 14, № 8.
8. *Tao J., Tan T.* Affective computing: A review // International Conference on Affective computing and intelligent interaction. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005. P. 981–995.



*Н. И. Мирошниченко*

ассистент

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ РАСПОЗНАВАНИЯ ЭМОЦИЙ ПО ГОЛОСУ: СОВРЕМЕННЫЕ ПОДХОДЫ И ПЕРСПЕКТИВЫ РАЗВИТИЯ

Разработка алгоритмов для идентификации эмоций по голосу человека представляет собой важное направление искусственного интеллекта (ИИ) и обработки звука. Такие алгоритмы открывают новые возможности для автоматизации взаимодействия между человеком и компьютером, улучшая качество обслуживания в различных сферах, включая психологию, безопасность и интерактивные технологии. Точные системы распознавания эмоций могут значительно повысить эффективность услуг и обеспечить более глубокое понимание эмоционального состояния пользователей. Рассматриваются исследования, посвященные разработке алгоритмов для распознавания эмоций по голосу и перспективы их развития.

**Ключевые слова:** искусственный интеллект, распознавание эмоций, голосовые сообщения, нейронные сети, спектрограммы, эмоциональные кривые, алгоритмы классификации.

*N. I. Miroshnichenko*

Assistant

St. Petersburg State University of Aerospace Instrumentation

## USING ARTIFICIAL INTELLIGENCE TO RECOGNIZE EMOTIONS BY VOICE: MODERN APPROACHES AND DEVELOPMENT PROSPECTS

The development of algorithms for identifying emotions by human voice is an important area in the field of machine learning and sound processing. Such algorithms open up new possibilities for automating human-computer interaction, improving the quality of service in various fields, including psychology, security and interactive technologies. Accurate emotion recognition systems can significantly improve the efficiency of services and provide a deeper understanding of the emotional state of users. The article discusses research on the development of algorithms for recognizing emotions by voice and their prospects for development.

**Keywords:** artificial intelligence, emotion recognition, voice messages, neural networks, spectrograms, emotion curves, classification algorithms.

### Введение

Современные технологии искусственного интеллекта кардинально преобразуют множество сфер человеческой деятельности, и одна из наиболее интересных областей применения этих технологий – распознавание эмоций по голосу. Эта задача представляет собой важную веху на пути создания более совершенных и интуитивных систем взаимодействия между человеком и машиной. Возможность эффективно идентифицировать эмоциональное состояние человека по его голосу открывает новые горизонты для улучшения пользовательского опыта в различных приложениях – от автоматических систем обслуживания клиентов и психотерапевтических технологий до интерактивных развлекательных продуктов и систем безопасности.

Современные подходы к распознаванию эмоций по голосу опираются на передовые алгоритмы машинного обучения и глубокие нейронные сети, которые способны анализировать акустические характеристики речи, такие как тональность, тембр, скорость речи и паузы. Эти технологии стремительно развиваются, обеспечивая все более точное и быстрое определение эмоциональных состояний. Однако, несмотря на значительные достижения, перед исследователями и разработчиками все еще стоит множество задач и вызовов, включая разнообразие акцентов и языков, сложность интерпретации контекста и обеспечение приватности данных [1].

### Современные подходы распознавания эмоций по голосу при помощи искусственного интеллекта

Существует множество методов распознавания эмоций по голосу, которые показывают разную эффективность в зависимости от набора данных. Например, студентка М. М. Котыга из Российского государственного социального университета провела исследование, направленное на анализ и идентификацию эмоций в коротких голосовых сообщениях продолжительностью до 3 с. В ходе работы было выделено 8 категорий эмоций, таких как гнев, страх, счастье и скука, и разработан датасет, содержащий более 3000 записей. Для обработки данных использовались аудиофайлы в формате WAV (Waveform Audio File Format), что позволило сохранить высокое качество звуковых характеристик.

Методология исследования включала создание датафрейма, содержащего ссылки на звуковые файлы и их соответствующие эмоциональные метки. Анализ данных показал, что спектрограммы разных эмоций значительно различаются, что стало основой для дальнейшего извлечения признаков, таких как скорость пересечения нуля, спектральный центроид и коэффициенты кепстральной частоты. Эти признаки легли в основу алгоритма классификации эмоций.

Для обучения модели использовалась библиотека Keras, которая обеспечивает простоту работы с нейронными сетями и модульность системы. В результате экспериментов удалось достичь точности распознавания эмоций на уровне 96,5%, что свидетельствует о высокой эффективности предложенного подхода [2].

Исследователи могут использовать различные характеристики для оценивания звуковых дорожек с целью дальнейшего сравнения. В статье студентки В. В. Семенюк из Донецкого национального университета исследуется эффективность использования сверточных нейронных сетей для распознавания эмоционального состояния человека по его голосу. Автор предложила использовать дополнительные характеристики, такие как коэффициенты мел-кепстра (MFCC), которые учитывают волновую природу звука и психофизическое восприятие, для дальнейшего улучшения точности распознавания.

Студентка разработала экспериментальный проект, в основе которого лежит метод звуковых отпечатков. Этот метод позволяет преобразовывать аудиофайлы в изображения спектрограмм, которые затем подаются на вход сверточной нейронной сети для анализа. Для обучения сети использовалась эталонная база данных, состоящая из 4500 аудиозаписей, в которых профессиональные актеры выражали различные эмоции. В ходе экспериментов проводился анализ по двум типам классификации: по трем основным классам эмоций (позитивные, негативные и нейтральные) и по восьми более детализированным классам (агрессия, спокойствие, отвращение, страх, счастье, нейтральное состояние, печаль, удивление).

Результаты показали, что наибольшая точность распознавания достигалась для негативных эмоций (более 80%), в то время как нейтральные эмоции распознавались хуже всего (около 50%). Среди конкретных эмоций лучшими показателями отличились страх (более 80%), спокойствие (75) и отвращение (70%). Самые низкие результаты были зафиксированы для эмоции печали (15%). Таким образом, продемонстрировано успешное применение нейронных сетей и машинного обучения для распознавания эмоций по голосу [3].

Помимо научных статей с обучением моделей и демонстрацией результатов, уже существует рабочее программное обеспечение для измерения эмоций абонента мобильного телефона. Оно применяет алгоритм, основанный на оценке амплитуды звуковой волны для определения численного значения эмоций. Этот метод позволяет строить эмоциональные кривые как для абонента, так и для мобильного устройства и не зависит от языка. Программа анализирует голосовые записи, вычисляет и визуализирует эмоциональные кривые. Эксперименты демонстрируют уникальность эмоциональных профилей каждого абонента на различных примерах голосовых записей. Преимущества разработанного алгоритма включают простоту настройки и независимость от языка произнесенных фраз. Однако основным недостатком заключается в отсутствии возможности распознавания конкретных эмоций [4].

### **Перспективы распознавания эмоций по голосу при помощи искусственного интеллекта**

Распознавание эмоций по голосу с использованием искусственного интеллекта имеет значительный потенциал и перспективы в различных сферах. В образовательных платформах оно может использоваться для адаптации учебного материала в зависимости от эмоционального состояния студентов, делая процесс обучения более эффективным. Распознавание эмоций позволит голосовым ассистентам, таким как Siri, Google Assistant, или Алиса, адаптироваться к эмоциональному состоянию пользователя. Например, они смогут выявлять раздражение или усталость и, соответственно, подстраивать тон и содержание своих ответов, что сделает взаимодействие с ними более естественным. Кроме того, распознавание эмоций по голосу может помочь в выявлении ранних признаков депрессии, тревожных расстройств и других психических заболеваний. Это может быть использовано как дополнительный инструмент для врачей. Также данная технология может использоваться в области безопасности и правопорядка. В правоохранительных органах технологии могут применяться для анализа эмоционального состояния подозреваемых или свидетелей, что может помочь в расследованиях, а в системах безопасности для выявления потенциальных угроз на основе анализа голоса.

### **Заключение**

Разработка алгоритмов для распознавания эмоций по голосу имеет значительное практическое значение. Эти алгоритмы могут быть использованы не только для автоматизации взаимодействия между человеком и компьютером, но и для реальных приложений в жизни, таких как мониторинг эмоционального состояния в различных ситуациях.

Для дальнейшего развития этих систем рекомендуются:

- 1) интеграция с другими сенсорами – использование данных с других сенсоров, таких как видеорекамеры и устройства для мониторинга физиологических показателей, может повысить точность и надежность определения эмоций [5];
- 2) улучшение методов извлечения признаков – применение более сложных методов для извлечения и анализа эмоциональных признаков, таких как глубокое обучение и аналитика больших данных, может повысить чувствительность и точность систем или создание адаптивных систем, которые могут учитывать индивидуальные особенности и контекстные факторы, улучшит их применимость в реальных условиях [6];
- 3) расширение и разнообразие данных – набор данных должен включать широкий спектр голосов и эмоциональных состояний, что поможет создать более универсальные и надежные модели [7].

### Библиографический список

1. *Богданова Д. П.* Распознавание эмоций по речевому сигналу // E-Scio. 2021. № 6(57). С. 416–425.
2. *Котыга М. М.* Распознавание эмоций в коротких голосовых сообщениях с использованием нейронных сетей // Научный альманах Центрального Черноземья. 2022. № 1-10. С. 85–91.
3. *Семенов В. В.* Исследование эффективности применения нейронных сетей для распознавания эмоций человека по его речи // Автоматизированные системы управления и информационные технологии: матер. Всерос. науч.-техн. конф.: в 2 т., Пермь, 09–11 июня 2021 г. Т. 1. Пермь: Перм. нац. исслед. политех. ун-т, 2021. С. 4–7.
4. *Михайлов В. О.* Программная реализация измерения эмоций абонента мобильного телефона // Современные проблемы науки и образования. 2012. № 5. С. 98.
5. *Чернятьев А. Л.* Цифровая аналитика эмоций: пилотажное исследование распознавания эмоций человека с помощью сенсоров мобильных устройств // Вестник Костромского государственного университета. Серия: Педагогика. Психология. Социокинетика. 2021. Т. 27, № 4. С. 200–207.
6. *Чуб В. С.* Извлечение признаков рекуррентными нейронными сетями из больших объемов данных // За нами будущее: взгляд молодых ученых на инновационное развитие общества: сб. науч. ст. 3-й Всерос. молодеж. науч. конф., Курск, 03 июня 2022 г. Т. 2. Курск: Юго-Зап. гос. ун-т, 2022. С. 536–539.
7. *Гараев Н. Р.* Обзор методов расширения наборов данных для задач классификации // Альманах научных работ молодых ученых Университета ИТМО: матер. XLIX науч. и учеб.-метод. конф., СПб., 29 янв. 2020 г. Т. 3. СПб.: Нац. исслед. ун-т ИТМО, 2020. С. 69–74.

*Т. В. Митрофанова\**

кандидат физико-математических наук

*С. С. Сорокин\**

кандидат педагогических наук

\*Чувашский государственный университет им. И. Н. Ульянова, Чебоксары, Россия

## ИСПОЛЬЗОВАНИЕ GIGACHAT ПРИ МОДЕЛИРОВАНИИ БИЗНЕС-ПРОЦЕССОВ В НОТАЦИИ BPMN

Рассмотрено применение диалоговой AI-модели GigaChat для моделирования бизнес-процесса. Показано, что для моделирования программного обеспечения в нотации BPMN функциональность GigaChat ограничена, имеет различные синтаксические и семантические недостатки. GigaChat может использоваться аналитиком для генерации по описанию новых и улучшению существующих бизнес-процессов, что помогает лучше работать с данными и проектировать системы, значительно повышая эффективность и сокращая время работы.

**Ключевые слова:** языковые модели, GigaChat, бизнес-процесс, BPMN.

*T. V. Mitrofanova\**

PhD, Phys.-Math.

*S. S. Sorokin\**

PhD, Pedagogy

\*Chuvash State University named after I. N. Ulyanov, Cheboksary, Russia

## USE OF GIGACHAT IN BUSINESS PROCESS MODELING IN BPMN NOTATION

The paper considers the use of GigaChat dialog AI-model for business process modeling. It is shown that for software modeling in BPMN notation the functionality of GigaChat is limited, has various syntax and semantic shortcomings. GigaChat can be used by analytics to generate new and improved business processes, which helps you work better with data and design systems, significantly improving efficiency and reducing time.

**Keywords:** language models, GigaChat, business process, BPMN.

Большинство экспертов сходятся во мнении, что большие языковые модели (LLM), такие как те, что используются в чат-ботах с искусственным интеллектом, произведут революцию в способах разработки программного обеспечения, однако анализу текущего состояния LLM в отношении моделирования программного обеспечения уделялось мало внимания [1].

Количество вакансий с требованием наличия навыков работы с нейросетями за год выросло в России более чем в 10 раз, следует из данных платформы онлайн-рекрутинга hh.ru и ИТ-компании EvApps [2]. Для системного анализа чат-боты с искусственным интеллектом могут: создавать описания бизнес-процессов, спецификации функций; писать user story и use cases; описывать объекты предметной области и структуру базы данных; строить модели состояний; рисовать диаграммы классов и диаграммы последовательности; специфицировать нефункциональные требования и проектировать API [3]. Поэтому при изучении дисциплины «Моделирование и проектирование информационных систем» студенты III курса факультета информатики и вычислительной техники отрабатывают навыки, полученные в ходе изучения дисциплины с GigaChat. Отметим, что использование чат-бота не отменяет самостоятельного критического осмысления студентами заданий и результатов, которые получаются с применением GigaChat.

GigaChat – диалоговая AI-модель от Сбера, которая отвечает на вопросы, сочиняет тексты, пишет код и рисует картинки. В мире моделирования бизнес-процессов нотация BPMN выделяется своей способностью превращать сложные процессы в комплексные диаграммы. Однако GigaChat не умеет создать изображение или визуализацию в нотации BPMN. В связи с этим исследуем текущие возможности GigaChat для выполнения задач моделирования и оказания помощи системным аналитикам в ИТ-компаниях.

Начнем с создания основных шагов бизнес-процесса. Цель состоит в том, чтобы попросить GigaChat описать процесс аренды автомобиля в нотации BPMN (рис. 1–2).

— Действуй как системный аналитик. Опиши словесно основные шаги задачи в терминах нотации BPMN. 8 мая  
Задача:  
Разработка сайта аренды авто-мобилей различного класса: А, В, С, D, E и F и т.д.  
Неавторизованный пользователь может посмотреть на данном сайте каталог предлагаемых автомобилей, их основные характеристики.  
Получить информацию о доступности определенного автомобиля на интересующие даты.  
Оставить заявку на аренду может только авторизованный пользователь.

*Рис. 1. Запрос к GigaChat для описания шагов бизнес-процесса*

— Основные шаги задачи в терминах нотации BPMN могут быть описаны следующим образом:

1. **Получение информации о доступности автомобиля** - Пользователь входит на сайт и просматривает каталог автомобилей, выбирает интересующий его автомобиль и проверяет его доступность на определенные даты.
2. **Регистрация пользователя** - Неавторизованный пользователь проходит процесс регистрации, в ходе которого указывает свои персональные данные, включая ФИО, паспорт, водительские права, номер телефона и другие необходимые данные.
3. **Создание заявки на аренду автомобиля** - Авторизованный пользователь создает заявку на аренду выбранного автомобиля, указывая даты аренды и дополнительные комментарии.
4. **Отправка заявки на обработку** - Сформированная заявка отправляется оператору на обработку.
5. **Уточнение деталей с оператором** - Оператор связывается с пользователем, чтобы уточнить детали и подтвердить намерения.
6. **Подтверждение заявки пользователем** - Если пользователь согласен с условиями аренды, он подтверждает заявку.
7. **Изменение статуса заявки** - Статус заявки в личном кабинете пользователя изменяется, и становится доступна функция оплаты аренды автомобиля онлайн.
8. **Оплата аренды автомобиля** - Пользователь оплачивает аренду автомобиля через сайт с использованием банковской карты.
9. **Обновление статуса заявки** - Изменение статуса заявки происходит автоматически после оплаты аренды.
10. **Бронирование автомобиля** - Автомобиль бронируется для пользователя на указанные даты.
11. **Возврат автомобиля** - По окончании срока аренды автомобиль возвращается в гараж компании.

Рис. 2. Описание основных шагов бизнес-процесса GigaChat

На рис. 2 видим, что не были учтены альтернативные сценарии при построении алгоритма бизнес-процесса. Напишем запрос «Переделай основные шаги с учетом альтернативных сценариев». После ввода GigaChat выводит основные шаги с учетом альтернативных сценариев. С помощью этой информации можно получить общее представление о бизнес-процессе, представленном в постановке задачи.

Далее попросим написать название всего процесса и действующих ролей в системе (запрос «Опиши, как можно назвать процесс и какие действующие роли есть в данной задаче»), так как термины нотации BPMN «пул» и «дорожка» GigaChat не знакомы (рис. 3).

- Какие пулы и дорожки должны быть в данной схеме 8 мая в 15:34
- Извините, но я не совсем понимаю, о каких "пулах и дорожках" идет речь в контексте данной схемы. Можете, пожалуйста, уточнить ваш вопрос?

Рис. 3. Запрос, содержащий термины BPMN, и ответ GigaChat

Для того чтобы понять какие задачи должны быть у каждой роли, напишем запрос «Опиши, какие задачи выполняет каждая роль в виде списка» (рис. 4).

— Для каждой роли распределение основных шагов будет выглядеть следующим образом:

**Роль: Пользователь**

1. Просмотр каталога автомобилей и проверка доступности.
2. Регистрация на сайте, указание персональных данных.
3. Создание заявки на аренду автомобиля, указание дат аренды и дополнительных комментариев.
4. Подтверждение заявки после связи с оператором.
5. Оплата аренды автомобиля онлайн.

**Роль: Оператор**

1. Обработка поступивших заявок.
2. Связь с пользователем для уточнения деталей и подтверждения намерений.
3. Обновление статуса заявки в CRM-системе.

**Роль: Система**

1. Предоставление интерфейса для пользователей и оператора.
2. Интеграция с CRM-системой для обмена данными.
3. Автоматическое изменение статуса заявки после оплаты аренды.

Рис. 4. Распределение задач по действующим ролям

После проверки полученных результатов будущий аналитик-студент может самостоятельно нарисовать бизнес-процесс в одном из инструментов для разработки бизнес-процессов в нотации BPMN.

Таким образом, наши результаты показывают, что для моделирования программного обеспечения в нотации BPMN функциональность GigaChat ограничена, имеет различные синтаксические и семантические недостатки. GigaChat может использоваться аналитиком для генерации по описанию новых и улучшению существующих бизнес-процессов, что помогает лучше работать с данными и проектировать системы, значительно повышая эффективность и сокращая время работы.

#### Библиографический список

1. On the assessment of generative AI in modeling tasks: an experience report with ChatGPT and UML / J. Cámara, J. Troya, L. Burgueño, A. Vallecillo // Software and Systems Modeling. 2023. № 22. P. 1–13.

2. Рожков Р., Липатова Л. Бизнес ловит кадры в нейросети: как растет число вакансий с опытом работы с ИИ // Forbes. URL: <https://www.forbes.ru/tekhnologii/497061-biznes-lovit-kadry-v-nejroseti-kak-rastet-cislo-vakansij-s-opytom-raboty-s-ii> (дата обращения: 08.05.2024).

3. Курьянов Ю. ChatGPT в работе аналитика // Analyst days. URL: <https://analystdays.ru/ru/talk/106715> (дата обращения: 08.05.2024).

*А. Р. Салиева\**

аспирант

*Н. А. Верзун\**

кандидат технических наук, доцент

*М. О. Колбанёв\**

доктор технических наук, профессор – научный руководитель

\*Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина)

## ОБУЧЕНИЕ С ПОДКРЕПЛЕНИЕМ В ЗАДАЧАХ АКУСТИЧЕСКОГО РАСПОЗНАВАНИЯ В ЛОГИСТИКЕ

Рассмотрены основные направления, методы и перспективы применения акустического распознавания в логистике. Проводится обзор способов решения задач распознавания звуков с применением методов машинного обучения с подкреплением, описываются их достоинства и недостатки. Рассмотрена схема системы распознавания речи.

**Ключевые слова:** логистические процессы, акустическое распознавание, обучение с подкреплением, машинное обучение, акустическая модель, языковая модель.

*A. R. Salieva\**

PhD Student

*N. A. Verzun\**

PhD, Tech., Associate Professor

*M. O. Kolbanev\**

Dr. Sc., Tech., Professor – Scientific Adviser

\*St. Petersburg Electrotechnical University «LETI»

## REINFORCEMENT LEARNING IN TASKS OF ACOUSTIC RECOGNITION IN LOGISTICS

The article considers the main directions, methods and prospects of acoustic recognition application in logistics. The methods of solving the problems of sound recognition with the use of computer-based learning techniques are reviewed, their advantages and disadvantages are described. The scheme of speech recognition system is considered.

**Keywords:** logistic processes, acoustic recognition, reinforcement training, machine learning, acoustic model, language model.

### Введение

Акустическое распознавание играет важную роль в оптимизации логистических процессов, позволяя автоматизировать различные задачи управления цепочками поставок, от складского учета до транспортировки грузов [1]. Помимо традиционных методов машинного обучения и глубоких нейронных сетей, все большее внимание привлекают методы обучения с подкреплением (Reinforcement Learning, RL) в контексте акустического распознавания, которые особенно перспективны для решения сложных задач в динамических средах, характерных для логистики. Обучение с подкреплением позволяет системам адаптироваться к изменяющимся условиям и оптимизировать поведение на основе обратной связи от среды, что особенно ценно в условиях шумных и непредсказуемых сред. Технологии акустического распознавания применимы в различных аспектах логистической деятельности: управление складом, транспортировка грузов, мониторинг оборудования, автоматизация документооборота. Исследования в этом направлении находятся на пересечении нескольких областей знаний: акустика, обработка сигналов, машинное обучение и логистический менеджмент.

### Основные направления применения акустического распознавания в логистике

*Голосовое управление складскими операциями.* Системы голосового управления позволяют сотрудникам склада выполнять свои задачи без необходимости отвлекаться на ручной ввод данных, что значительно повышает производительность труда и снижает количество ошибок, что особенно важно в условиях высокой интенсивности работы [2];

*Мониторинг состояния оборудования.* Акустические датчики находят широкое применение в мониторинге состояния логистического оборудования, помогая обнаруживать аномалии в работе техники на ранних стадиях, что позволяет предотвратить поломки и оптимизировать процесс технического обслуживания. Например, компания SKF разработала систему акустического мониторинга подшипников, которая выявляет неисправности на ранних этапах, снижая время простоя оборудования на 30–40% [3];

*Акустическая идентификация и отслеживание грузов.* Современные технологии позволяют использовать акустические метки и сенсоры для идентификации и отслеживания грузов в режиме реального времени, что открывает новые возможности для повышения прозрачности и точности логистических процессов [4].

**Исходными данными систем акустического распознавания** в логистике могут быть:

- аудиосигналы, записанные микрофонами (речь операторов, звуки работающего оборудования);
- акустические сигналы, полученные с помощью специализированных сенсоров (вибрации, ультразвук);
- метаданные, связанные с аудиозаписями (время, местоположение, идентификатор устройства);
- контекстная информация (текущая операция, статус оборудования, данные о грузе).

**Выходные данные** систем акустического распознавания в логистике:

- распознанный текст команд или информации, произнесенной оператором;
- классификация состояния оборудования (нормальное функционирование, аномалия, критическая ошибка);
- идентификационные данные груза или оборудования;
- заполненные формы документов на основе распознанной речи;
- предупреждения и оповещения о потенциальных проблемах, основанные на акустическом анализе.

### Методы и алгоритмы акустического распознавания в логистике

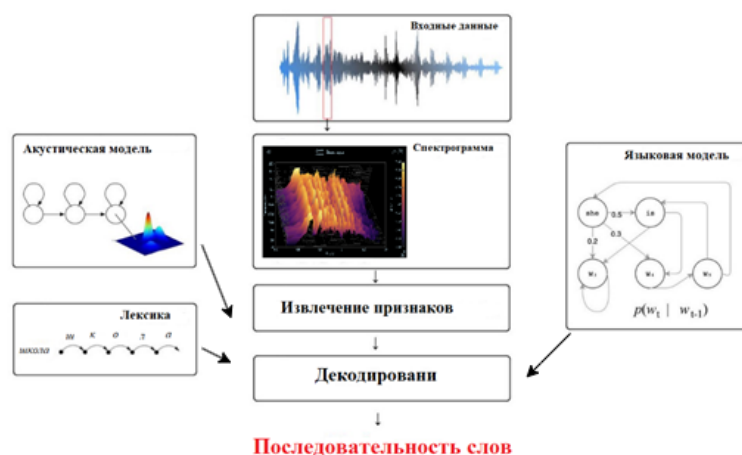
В настоящее время для решения задач акустического распознавания в логистике применяются глубокие нейронные сети, показывающие высокую эффективность в задачах распознавания речи и акустических событий. В таблице приведен обзор способов решения задач распознавания звуков.

**Способы решения задач распознавания звуков, их достоинства и недостатки**

№	Название алгоритма	Сфера применения	Достоинства	Недостатки	Описание
1	Скрытые Марковские модели (HMM)	Распознавание команд	Эффективны, хорошо изучены	Ограниченное моделирование зависимостей	Классический метод распознавания речи на основе статистики
2	Сверточные нейронные сети (CNN)	Обработка спектрограмм	Эффективны для спектрограмм, устойчивы к шуму	Пропускают долговременные зависимости	Специализированы на данных с сеточной топологией, например на изображениях или спектрограммах
3	Глубокие нейронные сети (DNN)	Распознавание речи и акустических сигналов	Высокая точность, сложные признаки	Требуют много ресурсов, склонны к переобучению	Обрабатывают сложные паттерны в акустических данных
4	Рекуррентные нейронные сети (RNN) и LSTM	Последовательные данные	Улавливают долговременные зависимости	Проблемы с исчезающим градиентом, медленное обучение	Разработаны для последовательностей, сохраняют информацию о предыдущих входах
5	Трансформеры	Последовательности данных, речь	Эффективность, параллельная обработка	Высокая вычислительная сложность, требуют много данных	Нейросети с механизмом внимания, эффективны для обработки последовательностей

В логистике при создании систем голосового управления и мониторинга [5] применяют сверточные нейронные сети для обработки спектрограмм и выделения акустических признаков. Они широко используются в системах акустического мониторинга оборудования [6], рекуррентные нейронные сети хорошо подходят для обработки последовательных данных, что делает их полезными в задачах распознавания речи и анализа временных рядов акустических сигналов [7].

Основная цель внедрения акустического распознавания в логистике – повышение эффективности, точности и скорости выполнения логистических операций путем автоматизации процессов, связанных с обработкой звуковой информации. В качестве примера рассмотрим схему автоматического распознавания речи – процесс преобразования речевого сигнала в текст. На рисунке показаны основные этапы этого процесса.



Автоматическое распознавание речи



Все начинается с входного речевого сигнала, представленного в верхней части рисунка в виде осциллограммы – графика колебаний звуковой волны во времени. Речевой сигнал преобразуется в спектрограмму, визуально отображающую частотные характеристики звука в зависимости от времени. Следующий шаг – извлечение акустических признаков. Система анализирует спектрограмму и выделяет ключевые характеристики, включая мел-частотные кепстральные коэффициенты (MFCC) и их производные. Эти признаки – основа для дальнейшего анализа. Центральную роль в процессе играют три взаимосвязанных компонента.

**Акустическая модель**, представленная скрытой марковской моделью (НММ), определяет вероятности соответствия между акустическими сигналами и языковыми единицами.

**Языковая модель**, изображенная в виде графа слов с вероятностями, оценивает вероятность появления различных последовательностей слов в языке.

**Лексика** связывает акустическую и языковую модели, показывая, как слова разбиваются на фонемы (например, слово «школа» на фонемы [ш], [к], [о], [л], [а]).

На этапе декодирования система интегрирует информацию из всех трех компонентов, чтобы найти наиболее вероятную последовательность слов, соответствующую входному сигналу. Финальный результат – последовательность слов, с наибольшей вероятностью соответствующая исходному речевому сигналу. Математически это выражается формулой

$$W^* = \arg \max [P(W | X)],$$

где  $W$  – последовательность слов, а  $X$  – акустический вход. Оптимальная последовательность слов  $W^*$  находится путем максимизации произведения вероятности акустической модели  $P(X|W)$  и вероятности языковой модели  $P(W)$ . Таким образом рисунок показывает, как различные компоненты ASR взаимодействуют друг с другом, «превращая» речевой сигнал в текст [8].

#### **Общая формула для акустического распознавания:**

$$W^* = \arg \max P(W | X) = \arg \max P(X | W) P(W),$$

где условная вероятность  $P(W|X)$  отражает шанс того, что последовательность  $W$  соответствует наблюдаемому акустическому сигналу  $X$ ; акустическая модель, представленная как  $P(X|W)$ , оценивает вероятность генерации конкретного сигнала  $X$  при заданной последовательности слов  $W$ ; языковая модель  $P(W)$  предоставляет оценку априорной вероятности появления определенной последовательности слов  $W$ , не учитывая особенности акустического сигнала.

#### **Заключение**

Акустическое распознавание имеет большой потенциал для оптимизации логистических процессов. По мере развития технологий и алгоритмов ожидается более широкое внедрение систем акустического распознавания в различные аспекты управления цепочками поставок. Эти методы обещают значительно повысить адаптивность и эффективность систем в реальных условиях. Комбинация методов обучения с подкреплением с традиционными подходами к акустическому распознаванию может привести к созданию гибридных систем, сочетающих преимущества обоих подходов. Такие системы могут быть особенно эффективны в решении сложных задач, таких как оптимизация маршрутов доставки с учетом акустической обратной связи от транспортных средств и окружающей среды.

#### **Библиографический список**

1. Развитие науки и научно-образовательного трансфера логистики / И. Л. Андреевский, И. Д. Афанасенко, С. Е. Барыкин [и др.]; под науч. ред. д-ра экон. наук, проф. В. В. Щербакова. СПб.: СПбГЭУ, 2019. 220 с.
2. Ludwig H., Schmidt T., Kühn M. Voice user interfaces in manufacturing logistics: a literature review // International Journal of Speech Technology. 2023. Т. 26, Vol. 3. P. 1–13.
3. Jombo Gbanaibolou, Zhang Yu. Acoustic-Based Machine Condition Monitoring—Methods and Challenges // Eng-Advances in Engineering. 2023. Vol. 4, № 1. P. 47–79.
4. Smart logistics based on the internet of things technology: an overview / Yangke Ding, Mingzhou Jin, Sen Li, Dingzhong Feng // International Journal of Logistics Research and Applications. 2021. Vol. 24, № 4. P. 323–345.
5. Deep Neural Networks for Acoustic Modeling in Speech Recognition / G. Hinton, L. Deng, D.g Yu [et al.] // IEEE Signal Processing Magazine. 2012. 1 Nov. P. 321–341.
6. Application of Deep Learning in Fault Diagnosis of Rotating Machinery / Wei Cui, Guoying Meng, Aiming Wang [et al.] // Processes. 2021. Vol. 9, № 6. P. 1–22.
7. Graves A., Mohamed A.-R., Hinton G. Speech Recognition with Deep Recurrent Neural Networks. URL: arXiv:1303.5778 [cs.NE]. 2013. 22 March.
8. Arabic Speech Recognition: Advancement and Challenges / A. Rahman, Md. M. Kabir, M. F. Mridha [et al.] // IEEE Access. 2024. Vol. 12. P. 1–15.

**Я. И. Сенина\***

студент

**Н. Н. Григорьева\***

старший преподаватель – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## **АВТОМАТИЗАЦИЯ СИНТАКСИЧЕСКОГО ФОРМАТИРОВАНИЯ ТЕКСТА, СОСТАВЛЕННОГО НА ОСНОВЕ РАСПОЗНАВАНИЯ РЕЧИ**

Рассмотрены подходы к автоматизации синтаксического форматирования текста, составленного на основе распознавания речи, с использованием современных технологий обработки естественного языка.

**Ключевые слова:** синтаксическое форматирование, распознавание речи, модели глубокого обучения.

**Ya. I. Senina\***

Student

**N. N. Grigoryeva\***

Senior Lecturer – Scientific Adviser

\*St. Petersburg State University of Aerospace Instrumentation

## **AUTOMATION OF SYNTACTIC FORMATTING OF TEXT COMPOSED BASED ON SPEECH RECOGNITION**

In the course of the work, approaches to automating syntactic formatting of text composed based on speech recognition were considered using modern natural language processing technologies.

**Keywords:** syntactic formatting, speech recognition, deep learning models.

### **Введение**

Автоматизация синтаксического форматирования текста, полученного путем распознавания речи, является важным аспектом в улучшении взаимодействия людей между собой. Современные системы распознавания речи позволяют быстро и качественно преобразовывать устную речь в текстовый формат, что существенно облегчает процесс создания и обработки текстовой информации [1]. Однако тексты, полученные таким путем, требуют дополнительной обработки: обработка слов-паразитов, устранение ошибок интерпретации и неформальный стиль изложения.

В данной статье анализируется применение технологий обработки и генерации текста на основе моделей глубокого обучения для улучшения качества текста, полученного через системы распознавания речи.

### **Требования к системе**

Главными требованиями к системе были качественное распознавание речи и корректность полученного на выходе текста. Текст, полученный после распознавания речи, должен быть исправлен и отформатирован так, чтобы он был понятен и соответствовал литературным стандартам. При анализе проблем форматирования текста были выявлены необходимость в автоматическом исправлении ошибок и замене слов-паразитов на более подходящие выражения и потребность в переходе от разговорного стиля к более формальному.

### **Архитектура разрабатываемой системы**

Разработанная система включает четыре ключевых модуля:

- 1) распознавания речи;
- 2) предварительной очистки текста;
- 3) синтаксического форматирования;
- 4) постобработки.

#### *Модуль распознавания речи*

Отвечает за преобразование устной речи в текстовый формат. Для этого используется библиотека SpeechRecognition вместе с Google Web Speech API, которые позволяют эффективно и точно конвертировать аудиосигналы в текстовые данные. Данные технологии обеспечивают высокую точность и надежность распознавания речи, благодаря продвинутым алгоритмам машинного обучения и большим объемам данных, на которых они обучаются.

### *Модуль предварительной очистки текста*

После получения текста из модуля распознавания речи он требует предварительной очистки: токенизация, стемминг (поиск основы слова, учитывающий морфологию исходного слова), удаление слов-паразитов и неформальных выражений, которые во многом искажают смысл и снижают уровень читаемости текста. Для выполнения стемминга используется RussianStemmer, что позволяет преобразовать слова к их корневой форме, что позволяет уменьшить вариативность и упростить дальнейшую обработку. Таким образом, после первичной обработки текст становится более «чистым» и формальным, что упрощает последующие обработку и восприятие.

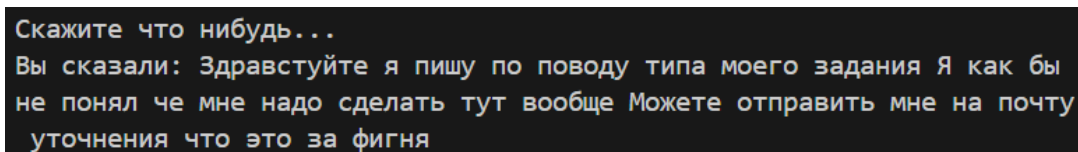
### *Модуль синтаксического форматирования*

Следующим этапом в обработке текста является синтаксическое форматирование с использованием библиотеки spaCy, которая включает модели глубокого обучения. Модель глубокого обучения – это тип модели машинного обучения, в котором используются многослойные нейронные сети, которые самостоятельно обучаются на большом наборе данных [2]. Благодаря модулю spaCy выполняется синтаксический анализ текста, выявляются и исправляются грамматические ошибки, а также проверяется согласование частей речи. Благодаря предоставленному модулем подробному анализу структуры предложения, улучшается синтаксическая и семантическая правильность текста.

### *Модуль постобработки*

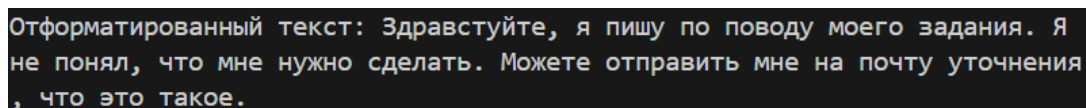
Для выполнения этапа постобработки используется модель глубокого обучения t5-base (Text-To-Text Transfer Transformer). T5 применяется для генерации текста, что позволяет улучшить стиль и формулировки, преобразуя текст в более литературную форму и существенно повышает уровень читаемости текста. Этот этап включает формирование окончательной версии текста с учетом поставленных требований.

Использование данной системы позволяет существенно повысить качество текста, полученного благодаря распознаванию речи. Работа всех четырех модулей направлена на улучшение читабельности текста и приведения его к соответствующим требованиям современных стандартов. По рис. 1, 2 видно, что система удачно определила и удалила слова-паразиты, верно сегментировала текст на смысловые предложения и улучшила стиль предложений.



Скажите чтонибудь...  
Вы сказали: Здравствуйте я пишу по поводу типа моего задания Я как бы не понял че мне надо сделать тут вообще Можете отправить мне на почту уточнения что это за фигня

*Рис. 1. Текст, полученный благодаря распознаванию речи*



Отформатированный текст: Здравствуйте, я пишу по поводу моего задания. Я не понял, что мне нужно сделать. Можете отправить мне на почту уточнения, что это такое.

*Рис. 2. Текст, полученный после обработки*

В условиях стремительного развития технологий и роста объемов данных, связанных с текстовой информацией, автоматизация процессов обработки и форматирования текста становится неотъемлемой частью эффективного управления информацией. В частности, распознавание речи и интеграция этого в текстовые системы открывают новые горизонты для улучшения взаимодействия между людьми и между человеком и машиной. Однако текст, полученный в результате распознавания речи, часто является непригодным для восприятия и требует значительных усилий для приведения его к литературной форме и устранения ошибок, что делает автоматизацию этих процессов особенно актуальной.

Использование описанной системы может облегчить жизнь человека в современных условиях, где существует необходимость взаимодействия с другими людьми посредством текстовой информации, будь то в рабочей или учебной среде. В условиях высокой нагрузки и плотного графика не всегда есть время на самостоятельную корректировку и форматирование текста. Автоматизация этих процессов позволяет существенно сэкономить время и силы, обеспечивая качественный результат с минимальными затратами на ручную работу.

### **Библиографический список**

1. Методы и модели автоматического распознавания речи: учеб. пособие / И. С. Кипяткова, А. А. Карпов, С. В. Кулешов, А. А. Зайцева. СПб: СПб ФИЦ РАН, 2021. 116 с.
2. Вейдман С. Глубокое обучение. Легкая разработка проектов на Python. СПб.: Питер, 2021. 272 с.

*Е. А. Черкашин\**

младший научный сотрудник

*А. А. Зайцева\**

кандидат технических наук – научный руководитель

\*Санкт-Петербургский Федеральный исследовательский центр Российской академии наук

## МЕТОДЫ НЕЙРОСЕТЕВОЙ ОБРАБОТКИ ВИДЕОДАНЫХ ДЛЯ ПОСТРОЕНИЯ МОДЕЛИ ПОВЕДЕНИЯ БИОЛОГИЧЕСКИХ ОБЪЕКТОВ

Рассматриваются подходы к нейросетевой обработке видеоданных для построения модели поведения биологических объектов. Проведена классификация поведенческих состояний биологических объектов на примере коров беспривязного содержания, на основе марковских моделей разработано формализованное представление модели поведения с использованием видеоданных.

**Ключевые слова:** нейросетевая обработка, видеоданные, модель поведения.

*E. A. Cherkashin\**

Junior Research Employee

*A. A. Zaytseva\**

PhD, Tech. – Scientific Adviser

\*St. Petersburg Federal Research Center of the Russian Academy of Sciences

## NEURAL NETWORK VIDEO PROCESSING TECHNIQUES FOR BUILDING A MODEL OF THE BEHAVIOR OF BIOLOGICAL OBJECTS

The paper considers approaches to neural network processing of video data for building a model of biological objects. Classification of behavioral states of biological objects was carried out using the example of cows of unattached content, based on Markov models developed a formalized representation of the behavior model using video data.

**Keywords:** neural network processing, video data, behavior model.

Современные достижения в области нейронных сетей и обработки данных привели к значительным изменениям в различных областях науки и техники, включая анализ видеоданных. Одна из перспективных областей применения этих технологий – моделирование поведения биологических объектов, что позволяет автоматизировать процессы наблюдения и анализа, обеспечивая более точное и оперативное реагирование на изменения в состоянии животных. Например, системы на основе искусственного интеллекта могут выявлять отклонения в поведении или здоровье животных задолго до появления видимых симптомов, что способствует своевременному вмешательству и снижению рисков заболеваний [1; 2].

Традиционные методы анализа поведения биологических объектов, основанные на наблюдении и ручной классификации, имеют ряд ограничений, таких как субъективность и ограниченная пропускная способность, и в основном не обеспечивают точности и масштабируемости. В этом контексте использование технологий искусственного интеллекта позволяет преодолеть эти ограничения, обеспечивая непрерывный и автоматический мониторинг, который предоставляет более точные и объективные данные. В работе рассматривается задача использования современных методов машинного обучения и анализа данных для построения моделей поведения биологических объектов. Это позволит обеспечить автоматизированный и точный мониторинг состояния и поведения животных, что в итоге приведет к оптимизации условий содержания, повышению продуктивности и улучшения здоровья животных.

### Анализ существующих методов нейросетевой обработки видеоданных

Существующие методы нейросетевой обработки видеоданных демонстрируют высокую эффективность в области компьютерного зрения. Они успешно применяются для анализа видеоданных, обеспечивая точные и надежные результаты. Основные инструменты в этой области включают сверточные нейронные сети (CNN), рекуррентные нейронные сети (RNN), двухпоточные нейронные сети (Two-Stream Networks) и трехмерные CNN, чаще всего используемые для решения задач анализа видеоданных. Эти методы позволяют извлекать как пространственную, так и временную информацию, что критически важно для мониторинга поведения биологических объектов [3].

В контексте задачи мониторинга поведения биологических объектов сверточные нейронные сети хорошо подходят для распознавания объектов и фиксированных поз животных, однако имеют ограничения в анализе временных зависимостей [4]. Рекуррентные нейронные сети эффективны для мониторинга последовательностей поведения животных, выявления изменений в динамике, таких как поведенческие паттерны, включая циклы

активности и покоя. Двухпоточные нейронные сети хорошо справляются с распознаванием сложных действий и взаимодействий между животными, например во время охоты. Трехмерные сверточные нейронные сети позволяют анализировать сложные и длительные поведенческие паттерны, такие как агрессия или охота.

### Разработка и адаптация нейросетевых моделей

Цель исследования заключается в разработке и адаптации нейросетевых моделей на основе видеоданных для точного и надежного анализа ключевых состояний поведения животных на примере коров. Основное внимание уделяется способности нейросетевых моделей выявлять незначительные изменения в поведении и состоянии животных, так как каждое состояние характеризуется уникальными визуальными признаками, которые будут выявляться и классифицироваться с использованием различных нейросетевых алгоритмов.

Для построения модели поведения коров беспривязного содержания на основе видеоданных необходимо четко определить ключевые состояния, которые можно наблюдать. Каждое состояние характеризуется специфическими визуальными признаками, которые могут быть выявлены и классифицированы с помощью нейросетевых алгоритмов.

Основываясь на экспертном мнении специалистов, можно выделить следующие ключевые состояния.

1. **Кормление** (животное находится у кормушки и потребляет корм).
  - **Визуальные признаки:** наклоненная к кормушке голова, движение челюстей, статичная поза тела.
2. **Отдых** (животное лежит на земле, не проявляя активных движений).
  - **Визуальные признаки:** лежачее положение, минимальное движение головы и конечностей, расслабленное тело.
3. **Движение** (животное ходит или бежит по пастбищу или в загоне).
  - **Визуальные признаки:** движение всех четырех конечностей, изменение положения тела в пространстве, возможные изменения скорости и направления.
4. **Стресс** (животное проявляет признаки беспокойства или дискомфорта).
  - **Визуальные признаки:** частые движения головой, бег, мычание, быстрые и хаотичные движения, повышение активности.
5. **Болезнь** (животное проявляет симптомы заболевания или недомогания).
  - **Визуальные признаки:** вялость, минимальная активность, необычные позы, снижение аппетита (отказ от кормления).
6. **Охота** (животное проявляет активное стремление к партнеру для размножения).
  - **Визуальные признаки:** повышенная подвижность и возбуждение, активное поиск или преследование других особей.

Для анализа поведения коров и построения модели их поведения важно создать пространство состояний, которое описывает возможные состояния и переходы между ними. Пространство состояний представляет собой фундаментальный элемент для моделирования и анализа поведения биологических объектов, в частности коров. В данном контексте пространство состояний описывает все возможные состояния коров и переходы между этими состояниями, что позволяет понять и предсказать поведенческие паттерны на основе видеоданных.

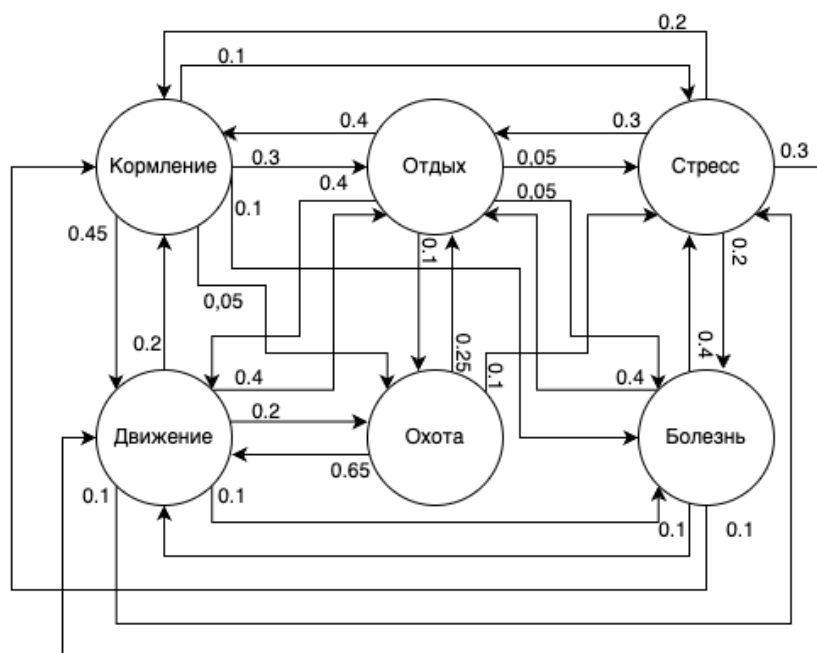
Предлагается использовать марковскую модель для описания переходов между состояниями. Пространство состояний может быть представлено как граф, где узлы – это состояния, а ребра – вероятности переходов между состояниями.

### Пример графа состояний

Состояния, которые можно выделить по визуальным признакам на видео: кормление, отдых, движение, стресс, болезнь, охота. Переходы и вероятности (примерные значения) приведены в таблице, а в виде графа – на рисунке.

Примерные значения переходов и вероятностей, выявленные на основе экспертных оценок

Кормление → движение (0.45). Кормление → отдых (0.3). Кормление → стресс (0.1). Кормление → болезнь (0.1). Кормление → охота (0.05)	Отдых → кормление (0.4). Отдых → движение (0.4). Отдых → охота (0.1). Отдых → стресс (0.05). Отдых → болезнь (0.05)	Стресс → отдых (0.3). Стресс → движение (0.3). Стресс → кормление (0.2). Стресс → болезнь (0.2)
Движение → отдых (0.4). Движение → кормление (0.2). Движение → охота (0.2). Движение → стресс (0.1). Движение → болезнь (0.1)	Болезнь → отдых (0.4). Болезнь → стресс (0.4). Болезнь → кормление (0.1). Болезнь → движение (0.1)	Охота → движение (0.65). Охота → отдых (0.25). Охота → стресс (0.1)



Пространство состояний

### Формализованное описание переходов

Обозначим состояния в виде  $S_i$  и  $S_j$ . Тогда вероятность перехода из состояния  $S_i$  в состояние  $S_j$  обозначается как  $P(S_j|S_i)$ .

Матрица переходов будет выглядеть следующим образом:

$$P = \begin{pmatrix} P(S_1|S_2) & P(S_2|S_1) & P(S_3|S_1) & P(S_4|S_1) & P(S_5|S_1) & P(S_6|S_1) \\ P(S_1|S_3) & P(S_2|S_3) & P(S_3|S_2) & P(S_4|S_2) & P(S_5|S_2) & P(S_6|S_2) \\ P(S_1|S_4) & P(S_2|S_4) & P(S_3|S_4) & P(S_4|S_3) & P(S_5|S_3) & P(S_6|S_3) \\ P(S_1|S_5) & P(S_2|S_5) & P(S_3|S_5) & P(S_4|S_5) & P(S_5|S_4) & P(S_6|S_4) \\ P(S_1|S_6) & P(S_2|S_6) & P(S_3|S_6) & P(S_4|S_6) & P(S_5|S_6) & P(S_6|S_5) \end{pmatrix},$$

где  $P(S_j|S_i)$  – это вероятность перехода из состояния  $S_i$  в состояние  $S_j$ .

Если вероятность перехода из состояния «Кормление» в состояние «Движение» составляет 0.45, тогда для 100 наблюдений для подтверждения вероятности должно состояться 45 переходов:

$$P(\text{Движение} | \text{Кормление}) = \frac{\text{Количество переходов}}{\text{Количество наблюдений}} = \frac{45}{100}.$$

Таким образом, создается предварительная модель поведения коров, позволяющая на основе видеоданных нейросетевых алгоритмов анализировать и предсказывать их.

### Заключение

Поведение животных и растений определяется множеством факторов, включая генетику, окружающую среду и социальные взаимодействия. Для того чтобы понять эти сложные процессы, необходимо собирать и анализировать большие объемы данных о поведении. Современные технологии позволяют автоматизировать этот процесс, используя датчики, камеры и алгоритмы машинного зрения. Это открывает новые возможности для количественной оценки и прогнозирования их поведения.

Моделирование поведения биологических объектов становится все более важным инструментом в современной науке. Комбинируя новейшие достижения в области машинного обучения и анализа данных, можно создавать мощные инструменты для изучения жизни на Земле и за ее пределами. В будущем такие модели будут играть ключевую роль в решении ветеринарных и зоотехнических задач.

### Библиографический список

1. Волков А. К., Миронова Л. В., Потапова С. Е. Применение предварительно обученных нейронных сетей для решения задачи обратного поиска рентгеновских изображений запрещенных предметов и веществ // Научный вестник МГТУ ГА. 2024. № 27(2). С. 8–24.
2. Carillo F., Abeni F. An Estimate of the Effects from Precision Livestock Farming on a Productivity Index at Farm Level. Some Evidence from a Sample of Dairy Farms in Lombardy // *Animals*. 2020. № 10(10). P. 1781.
3. Practices and applications of convolutional neural network-based computer vision systems in animal farming: A review / G. Li, Y. Huang, Z. Chen [et al.] // *Sensors*. 2021. № 21(4). P. 1492.
4. Animal species recognition with deep convolutional neural networks from ecological camera trap images / I. S. Binta, D. Valles, T. J. Hibbitts [et al.] // *Animals*. 2023. № 13(9). P. 1526.

*Н. И. Чулочникова\**

студент

*Е. Л. Турнецкая\**

кандидат технических наук, доцент – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ИСПОЛЬЗОВАНИЕ НЕЙРОСЕТЕЙ ДЛЯ УЛУЧШЕНИЯ КАЧЕСТВА ЗВУКОВОЙ ЗАПИСИ И СОЗДАНИЯ ВИДЕОКОНТЕНТА

Рассмотрены преимущества использования нейросетей в звуковой и видеозаписи при автоматизации процессов, таких как шумоподавление, улучшение качества звука и создание визуальных эффектов. Представлен функционал онлайн-сервисов Adobe Enhance Speech и Krisp, предназначенных для улучшения качества аудиозаписей с помощью нейронных сетей. Показаны возможности создания видеоматериалов с помощью нейросетей Kandinsky, «Шедеврум», Hedra и HeyGen.

**Ключевые слова:** искусственный интеллект, нейросетевые модели, автоматизация, звукозапись, видеоконтент.

*N. I. Chulochnikova\**

Student

*E. L. Turnetskaya\**

PhD, Tech., Associate Professor – Scientific Adviser

\*St. Petersburg State University of Aerospace Instrumentation

## USING NEURAL NETWORKS TO IMPROVE THE QUALITY OF SOUND RECORDING AND VIDEO CONTENT CREATION

The advantages of using neural networks in audio and video recording for automating processes such as noise reduction, sound quality improvement and visual effects creation are considered. The functionality of Adobe Enhance Speech and Krisp online services designed to improve the quality of audio recordings with the help of neural networks is presented. The possibilities of creating video materials with the help of Kandinsky, Masterpiece, Hedra and HeyGen neural networks are shown.

**Keywords:** artificial intelligence, neural network models, automation, sound recording, video content.

В последние годы нейросети и искусственный интеллект (ИИ) стали неотъемлемой частью различных областей, включая звукозапись и создание видеоконтента. Нейросети – это сложные алгоритмы, способные обучаться на больших объемах данных, выявляя закономерности и генерируя новые результаты.

Одно из ключевых преимуществ использования нейросетей в звуковой и видеозаписи – возможность автоматизации процессов, таких как шумоподавление, улучшение качества звука и даже создание визуальных эффектов. Это позволяет значительно сократить время на постобработку и повысить качество конечного продукта. Однако с развитием этих технологий возникают и определенные вызовы, такие как необходимость в обучении пользователей и вопросы этики, связанные с авторством и оригинальностью контента.

Обогащение качества звука может существенно улучшить восприятие подкастов, аудио или видео с речью. Превосходный звук не только привлекает внимание, но и способствует укреплению вашей репутации как профессионала или повышению доверия к вашему бренду. Исследование, проведенное колледжем USC и Австралийским национальным университетом, выявило, что качество звука влияет на уровень доверия людей к услышанной информации и ее источнику. «Как только мы снизили качество звука, ученые и их исследования внезапно потеряли доверие», – сказала Эрин Ньюман [1]. Применение нейросетей для улучшения качества звука также помогает избавиться от посторонних шумов. Например, если видео записано для своего аккаунта в социальных сетях и отдельно записан звук дома, но на заднем плане слышны плач ребенка или мяуканье кота, нейросеть сможет отфильтровать эти звуки. Или при записи звука на улице, где было много лишних звуков, нейросеть сможет их убрать.

Даже при записи в идеальных условиях, в студии или тихом офисе, всегда есть возможность повысить качество. Для удаления малозаметных артефактов и искажений, обработайте звуковую дорожку через нейросеть, чтобы достичь наилучшего результата. Рассмотрим инструменты для улучшения записей, в которых использована технология ИИ.

Adobe Enhance Speech [2] – онлайн-сервис, предназначенный для улучшения качества аудиозаписей с помощью нейронных сетей. Он использует ИИ для анализа аудиосигнала и определения его характеристик, таких как тональность, скорость речи и наличие шумов. Это позволяет улучшить качество записи, сделать ее более разборчивой и естественной для восприятия слушателем. Основные функции Enhance Speech включают:

– шумоподавление – удаление фонового шума, что позволяет выделить речь и сделать ее более разборчивой;



– улучшение четкости – подчеркивание высоких частот и других аспектов звука, чтобы сделать речь более ясной;

– адаптивность – технология может адаптироваться к различным условиям записи, что делает ее универсальной для разных типов аудио.

Krisp [3]. Приложение также предназначено для шумоподавления в реальном времени во время видеозвонков и записей. Основные функции Krisp включают (табл. 1):

– удаление фонового шума – Krisp эффективно фильтрует звуки окружающей среды, такие как шумы от клавиатуры, разговоры или звуки улицы;

– поддержка нескольких платформ – Krisp совместим с большинством популярных приложений для видеозвонков и записи, что делает его удобным инструментом для пользователей;

– легкость в использовании – пользователи могут легко включить или отключить функцию шумоподавления одним кликом.

Таблица 1

Сравнение Enhance Speech и Krisp

Параметр	Enhance Speech	Krisp
Цель использования	Ориентирован на постобработку аудио, улучшая качество уже записанных материалов	Фокусируется на реальном времени, обеспечивая чистый звук во время общения
Пользовательский интерфейс	Может требовать больше технических знаний для настройки и использования, особенно при работе с аудиоредакторами	Предлагает простой и интуитивно понятный интерфейс, что делает его доступным для широкой аудитории
Применение	Может быть более подходящим для профессионалов в области звукозаписи, подкастов и киноиндустрии	Идеально подходит для удаленной работы и видеозвонков, где важна четкость звука в реальном времени
Стоимость	Бесплатно 1 час/сутки	Бесплатно 2 часа/сутки
Формат файла для обработки	wav, mp3, aac, flac, ogg, oga, m4a	Любые
Длительность аудио	30 минут	60 минут
Размер файла	500 Мб	Любой

Оба сервиса – Enhance Speech и Krisp – играют важную роль в улучшении качества звука, но служат разным целям. Enhance Speech предлагает более глубокую обработку для профессионального использования, тогда как Krisp обеспечивает удобное решение для повседневной коммуникации. Выбор между ними зависит от конкретных потребностей пользователя и контекста использования.

Создание видео с помощью нейросетей – это быстро развивающаяся область, которая использует алгоритмы глубокого обучения для генерации, редактирования и улучшения видеоконтента (табл. 2). Такие технологии позволяют создавать реалистичные анимации, синхронизировать речь с движениями персонажей, а также трансформировать текстовые описания в видеоряд. Это может быть полезно для создания рекламных роликов, анимаций, иллюстраций и других видов визуального контента.

Kandinsky [4] – нейросеть, разработанная для генерации изображений на основе текстовых подсказок. Позволяет пользователям создавать уникальные художественные работы, используя различные стили и техники.

«Шедеврум» [5] – платформа, которая позволяет создавать и редактировать изображения и видео с использованием искусственного интеллекта. Предлагает широкий спектр инструментов для художников и дизайнеров.

Hedra [6] – нейросеть, фокусирующаяся на создании видеоконтента для социальных сетей. Предоставляет инструменты для автоматического монтажа, генерации анимаций и оптимизации видео под различные форматы, что делает ее идеальной для маркетинга и продвижения в интернете.

HeyGen [7] – платформа для создания анимированных видео с говорящими персонажами на основе текстовых подсказок. Использует технологии синтеза речи и анимации.

Таблица 2

Сравнение технологий для создания видео

Нейросеть	Форма запроса	Язык запросов	Обязательная регистрация	Время обработки запроса	Кадрирование видео	Создание анимации
Kandinsky	Текстовый	Русский, английский	Да (через Сбер ID)	До 10 минут	Можно	Да
Шедеврум	Текстовый	Русский, английский	Да (через Яндекс ID)	До 10 минут	Можно	Да
Hedra	Аудио, изображение	Английский	Да	До 5 минут	Можно	Да
HeyGen	Текстовый	Русский, английский	Да	до 5 минут	Нельзя	Нет

Рассмотрим две нейросети, обладающие разным функционалом: «Шедеврум» и Hedra. На рис. 1 показан процесс создания видео в Hedra. Нейросеть позволяет генерировать видео с любым текстом и оживить картинку. Для этого необходимо написать текст, выбрать голос или добавить аудиодорожку, затем загрузить картинку (персонажа или фотографию) и нажать «Создать видео», которое можно воспроизвести онлайн, скачать или поделиться ссылкой.

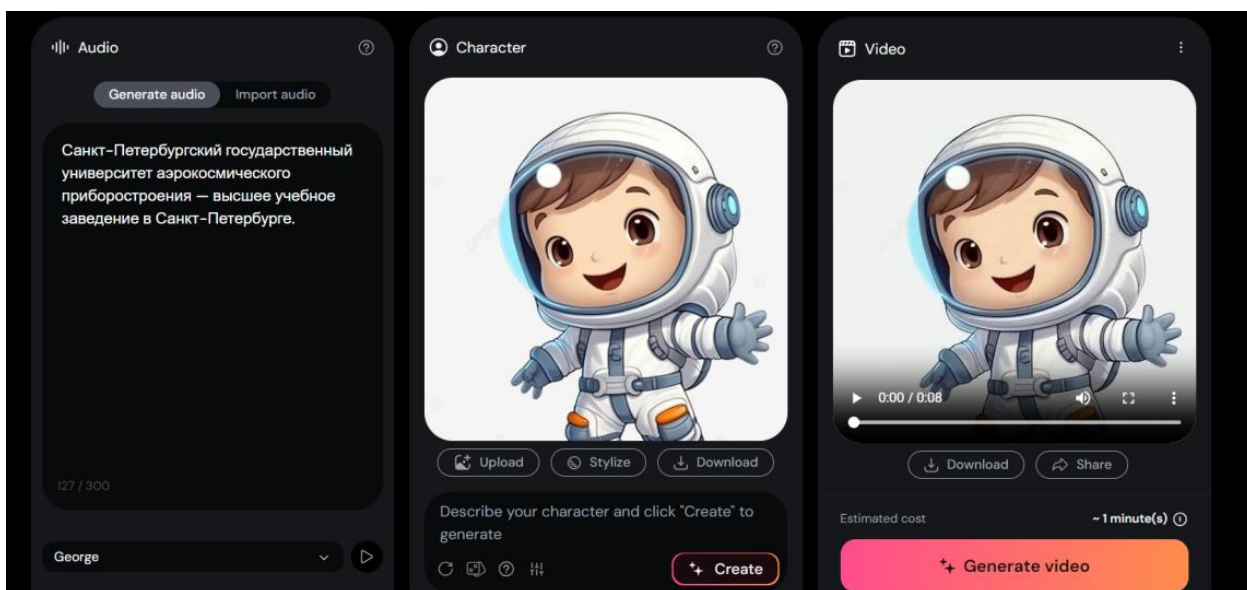


Рис. 1. Пример создания видео в Hedra

На рис. 2 представлен процесс создания видео в Шедеврум. Для получения видео необходимо воспользоваться мобильным приложением, выбрать из меню «видео», написать промпт, через пару секунд нейросеть предложит выбрать первый кадр для видео и эффект, после этого к видео можно будет добавить музыку и опубликовать созданный видеоролик, длительностью до 4 с.

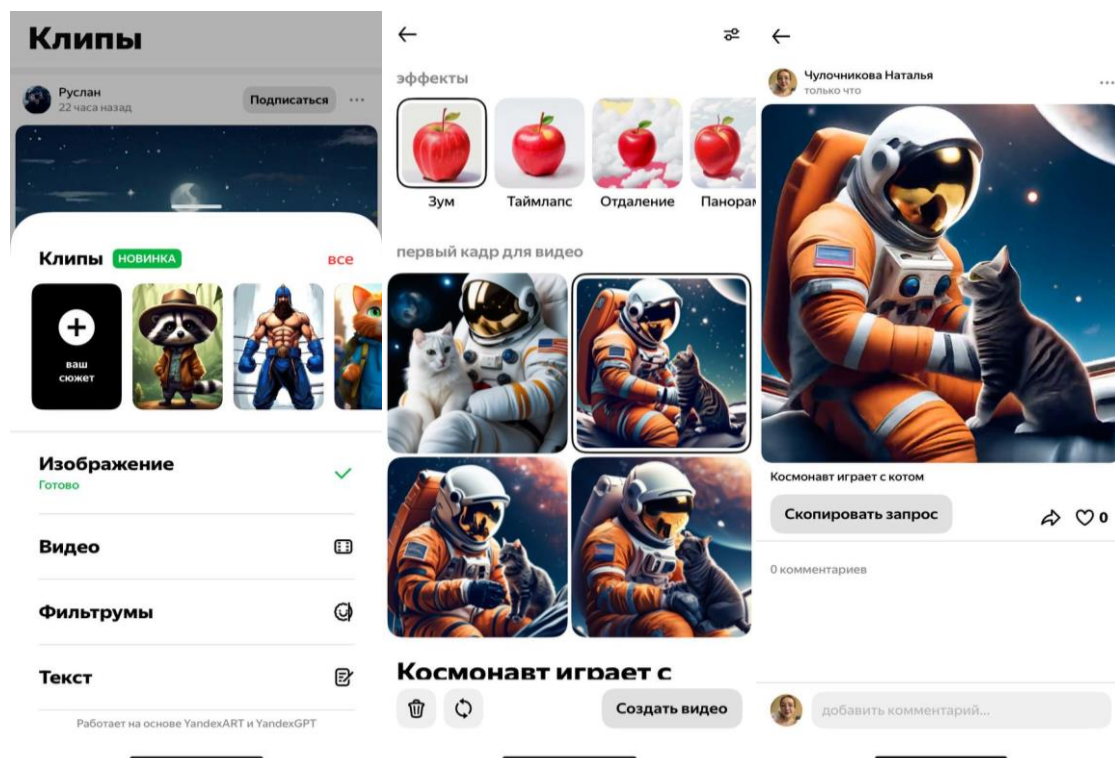


Рис. 2. Процесс создания видео в «Шедеврум» по запросу «Космонавт играет с котом»

Каждая нейросеть имеет собственные особенности и возможности, поэтому выбор какой-либо конкретной зависит от ваших целей и задач.

Современные технологии искусственного интеллекта значительно изменили подход к созданию и обработке медиаконтента. Их интеграция позволяет значительно повысить качество медиапродукции, сократить время на обработку и сделать процесс более интуитивно понятным. Используя описанные технологии совместно, можно создавать профессионально звучащие и визуально привлекательные медиапроекты.

#### **Библиографический список**

1. The quality of audio influences whether you believe what you hear // USC Today URL: <https://today.usc.edu/why-we-believe-something-audio-sound-quality/> (дата обращения: 25.08.2024).
2. Enhance Speech // Adobe Podcast. URL: <https://podcast.adobe.com/enhance> (дата обращения: 20.08.2024).
3. Krisp. URL: <https://krisp.ai/> (дата обращения: 20.08.2024).
4. Kandinsky. URL: <https://kandinsky-ai.ru/> (дата обращения: 20.08.2024).
5. Шедеврум. URL: <https://shedevrum.ai/> (дата обращения: 20.08.2024).
6. Hedra. URL: <https://www.hedra.com/app/characters> (дата обращения: 20.08.2024).
7. HeyGen. URL: <https://www.heygen.com/> (дата обращения: 20.08.2024).

**И. О. Шальнев\***

младший научный сотрудник

**А. Ю. Аксенов\***

кандидат технических наук

\*Санкт-Петербургский Федеральный исследовательский центр Российской академии наук

## ИСПОЛЬЗОВАНИЕ ОПТИЧЕСКОГО ПОТОКА ДЛЯ ВЫДЕЛЕНИЯ ДИНАМИЧЕСКИХ ПРИЗНАКОВ ДВИЖУЩИХСЯ ОБЪЕКТОВ

Рассмотрено использование оптического потока для выделения динамических признаков движущихся объектов. Проведенные эксперименты показывают возможность использования метода оптического потока для определения источника движения, при этом в качестве входных данных используются векторы перемещения, сохраненные в потоке, формируемом видеокодеком при сжатии с потерями.

**Ключевые слова:** оптический поток, движущийся объект, кластеризация, классификация.

**I. O. Shalnev\***

Junior Research Employee

**A. Yu. Aksenov\***

PhD, Tech.

\*St. Petersburg Federal Research Center of the Russian Academy of Sciences

## USE OF OPTICAL STREAM TO HIGHLIGHT DYNAMIC FEATURES OF MOVING OBJECTS

The paper considers the use of optical flow for the selection of dynamic features of moving objects. Experiments conducted show the possibility of using the optical flow method to determine the source of motion, with the input data used as vectors of movement, saved in the stream formed by video codec when compressed with losses.

**Keywords:** optical flow, moving object, clustering, classification.

Сегодня системы видеоаналитики находят применение в различных областях народного хозяйства, даже в тех задачах, где машинное зрение ранее не использовалось. Одна из таких задач – наблюдение за животными в сельском хозяйстве, в частности для отслеживания их перемещения по территории и формирования статистических оценок по количеству и видам движения для каждого животного [1; 2].

Для определения источника движения без предварительной локализации объекта может служить метод оптического потока. Также использование оптического потока может решать обратную задачу – локализацию объекта, находящегося в движении, при условии применения фиксированной камеры, а также стабильного заднего фона. Данные условия выполняются при размещении неподвижных камер в закрытых помещениях, где содержатся животные.

Оптический поток – это метод обработки видеопотока, который позволяет определить направление и скорость движения объектов в кадре. Он используется в различных областях, включая компьютерное зрение, робототехнику и сжатие данных [3]. Однако этот метод имеет ограничения. Например, он может работать только при наличии достаточного количества света и контраста между объектом и фоном. Кроме того, он может быть чувствительным к шуму и артефактам изображения. Тем не менее оптический поток является важным инструментом для анализа движения объектов в видеопотоке и может быть использован в различных приложениях, таких как слежение за объектами, определение траектории движения и т. д.

В подавляющем большинстве видеокодеков (программных или аппаратных средств для сжатия видеоданных с потерями) уменьшение передаваемой информации происходит за счет разнообразных алгоритмов поиска перемещенных блоков пикселей. Видео состоит из последовательности кадров, различие которых в основном невелико. Поэтому передавать даже сжатые кадры неэффективно. Сначала передается опорный кадр – сжатое изображение, а следом за ним вычисленные относительно предыдущих кадров векторы перемещения блоков пикселей. Таким образом, передача опорных кадров вместе с закодированными векторами перемещения позволяет воссоздать видео без видимых для человеческого глаза потерь. Опорные кадры передаются с частотой, определенной в настройках кодера. Если видео статичное, то количество передаваемой информации заметно уменьшается, что говорит о том, что сдвиг пикселей не выявляется, а значит, векторов перемещения, необходимых для передачи, нет.

На рис. 1 показан пример смещения блоков пикселей: а – перемещенные из другого кадра блоки пикселей; б – векторы перемещения. Скорость передвижения блоков пикселей отражает длину вектора перемещения.

а)



б)




Рис. 1. Пример смещения блоков пикселей

Данную особенность видеокодеков можно использовать для обнаружения движущихся объектов. Библиотека работы с видео- и аудиокодеками `ffmpeg` [4] позволяет не только декодировать видеокадры, но и извлекать метаданные из видеофайла или видеотрансляции. Метаданные, помимо прочего, хранят векторы перемещения.

Полученные векторы необходимо кластеризовать: по пространственной близости, углу и величине. Если есть группа близко расположенных коллинеарных векторов с несильно различающимися длинами, то можно заключить, что она является кластером, а стало быть, потенциальным объектом для дальнейшей классификации.

Векторы перемещения передаются в сжатом видеопотоке в виде списка, каждый элемент которого хранит структуру, состоящую из координат начала вектора и его конца, а также ряд дополнительной информации, такой как размер окна и т. д. Для пространственной кластеризации предварительно список векторов необходимо преобразовать в матричный вид, где размер матрицы должен совпадать с разрешением кадра, а концы векторов должны быть отмечены максимальным для 8-битного числа целочисленным значением – 255. В экспериментах был использован метод скользящего окна: если в окне 16 на 16 пикселей существует конец другого вектора, то такой вектор принимается в кластер, а его конец помечается номером этого кластера, после чего проверяется окружение вновь прибывшего вектора. Если концу вектора не присвоен номер кластера, то считается, что обнаружен новый кластер и ему присваивается номер следующего свободного кластера. На рис. 2, а показан пример работы такого алгоритма, зеленым квадратом выделены области уже добавленных в кластер векторов. На рис. 2, б продемонстрирован результат работы такого подхода, где отчетливо видно, что близлежащие векторы попали в один кластер.




Рис. 2. Пример пространственной кластеризации

Работа алгоритма пространственной кластеризации может давать недостоверный результат. Например, некоторые пешеходы, показанные на рис. 2, б, идут в противоположном направлении, тем не менее они принадлежат одному кластеру. На рис. 3 продемонстрировано распределение углов показного кластера, где видны два пика, соответствующих противоположным направлениям. Таким образом, необходимо модифицировать алгоритм так, чтобы близлежащие, но противоположно направленные векторы принадлежали разным кластерам. Это можно реализовать путем добавления условия, при котором векторы не добавляются в кластер, если разность их углов более 30 градусов. Аналогичное решение было предпринято с кластеризацией по длине: если разность длин более определенного порога, то такой вектор не присваивается к кластеру.




Рис. 3. Распределение углов кластера

Указанный метод не лишен недостатков: сонаправленное движение объектов может быть распознано как одно целое, следовательно, векторы такого движения будут принадлежать одному кластеру. Таким движением как раз являются движения группы животных.

Проведенные эксперименты показывают возможность использования метода оптического потока для определения источника движения, при этом в качестве входных данных используются векторы перемещения, сохраненные в потоке, формируемом видеокодеком при сжатии с потерями. Данные вектора перемещения являются побочным продуктом процесса сжатия видеоданных IP-камерой, и их использование позволяет сократить потребность в ресурсах для определения источника движения и задачи сопровождения движущегося объекта в области кадра.

#### Библиографический список

1. Современные интеллектуальные технологии управления молочным стадом: проблемы и пути развития / Е. Ю. Авксентьева, С. В. Кулешов, А. А. Зайцева, В. Н. Суровцев // Системы управления и информационные технологии. 2022. № 2(88). С. 76–81.
2. Черкашин Е. А. Применение нейронных сетей для классификации объектов в видеоданных в задачах автоматического мониторинга состояния биологических объектов // Системы анализа и обработки данных. 2023. № 3(91). С. 69–86.
3. Beauchemin S. S., Barron J. L. The computation of optical flow // ACM Comput. 1995. Surv. 27, 3. P. 433–466.
4. Ni Han Biao, Cao San Xing. Research and Implementation of Asynchronous Video Converter based on Linux // Applied Mechanics and Materials. 2012. Dec. P. 241–244.

УДК 004.942, 616-71

**Б. К. Акопян**

старший преподаватель

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ КЛАССИФИКАЦИИ ЭПИЗодОВ НАРУШЕНИЙ СЕРДЕЧНОГО РИТМА

Рассматривается решение задачи многоклассовой классификации эпизодов нарушения сердечного ритма по двум информативным признакам методами машинного обучения. Применяются три метода классификации: множественная логистическая регрессия, метод опорных векторов и случайный лес. Проведены обучение и тестирование моделей на наборах из открытых баз данных MIT-BIH Arrhythmia и INCART, принадлежащих трем классам: нормальный эпизод, желудочковая экстрасистолия и предсердная экстрасистолия. Приведены значения сбалансированной F-меры для оценки качества классификации.

**Ключевые слова:** машинное обучение, логистическая регрессия, метод опорных векторов, метод случайного леса, многоклассовая классификация, электрокардиограмма, анализ данных.

**В. К. Акоруян**

Senior Lecturer

St. Petersburg State University of Aerospace Instrumentation


## APPLICATION OF MACHINE LEARNING METHODS FOR ARRHYTHMIC EPISODES CLASSIFICATION

The article considers the solution of the multiclass classification of episodes of cardiac arrhythmia by two informative features of machine learning methods. Three classification methods are used: multiple logistic regression, support vector machine and random forest. Training and testing of models on sets from the open databases MIT-BIH Arrhythmia and INCART, belonging to three classes. The values of balanced F-measure for classification quality assessment were given.

**Keywords:** machine learning, logistic regression, support vector machine, random forest, multiclass classification, electrocardiogram, data analysis.

Конечная цель анализа биомедицинских сигналов заключается в классификации принятого сигнала с целью его определения в одну из известных категорий и выдача диагностического решения о состоянии обследуемого. Одна из подобных задач – классификация нарушения сердечного ритма по сигналу электрокардиограммы [1].

Постановка задачи многоклассовой классификации эпизода нарушения ритма по сигналу электрокардиограммы выглядит следующим образом: в зависимости от положения опорной точки  $R_i$  (рисунок) определяются информативные признаки так, что каждый эпизод в записи описан в общем случае набором из  $n$  информативных признаков  $\Theta_i = (\theta_1, \theta_2 \dots \theta_n)$ . Известно, что истинное состояние кардиоцикла может быть отнесено только к одному из  $M$  классов, представленных множеством  $\Omega = \{\Omega_1, \Omega_2 \dots \Omega_M\}$ . Для классификации необходимо определить границы разделяющих поверхностей областей каждого класса в  $n$ -мерном пространстве признаков  $\mathbb{R}^n$  и положение точки  $\Theta$  в данном пространстве. В данной статье рассмотрим задачу многоклассовой классификации при  $n = 2, M = 3$ .



К задаче многоклассовой классификации эпизода нарушения ритма по сигналу электрокардиограммы

Текущее исследуемое пространство состоит из двух информативных признаков [2].

1. Коэффициент сцепления  $\Delta RR_i$ , отражающий отношение длительности текущего  $RR$ -интервала к длительности предыдущего:

$$\theta_1 = \frac{RR_i}{RR_{i-1}},$$

где  $RR_i$  – длительность  $RR$ -интервала, предшествующего текущему кардиоциклу;  $RR_{i-1}$  – длительность  $RR$ -интервала, предшествующего предыдущему кардиоциклу.

2. Коэффициент эксцесса  $i$ -го R-зубца  $\gamma_i$ :

$$\theta_2 = \frac{\mu_4}{\sigma_s^4}, \mu_4 = \sum_{j=1}^{N_s} \left( \left( n_j - \bar{n} \right) T_\Delta \right)^4 \frac{s_j^2}{\sum_{j=1}^{N_s} s_j^2},$$

где  $s$  – выборка значений исследуемого фрагмента электрокардиосигнала в окрестности опорной точки  $R$ ,  $\mu_4$  – оценка центрального момента четвертого порядка для выборки  $s$ ,  $N_s$  – объем выборки  $s$ ,  $\sigma_s$  – оценка выборочной дисперсии выборки  $s$ ,  $T_\Delta$  – период дискретизации сигнала,  $n$  – порядковый номер отсчета,  $\bar{n}$  – среднее значение порядковых номеров.

В рамках данного исследования используются системы классификации с обучением на основе алгоритмов логистической регрессии (LR), метода опорных векторов (SVM) и случайного леса (RF).

Для задачи классификации на три класса применяется метод множественной логистической регрессии [3]: пусть дан вектор входных данных  $\mathbf{X} = \{\Theta_1, \Theta_2, \dots, \Theta_i, \dots, \Theta_I\}$  и соответствующие каждому элементу данного набора метки классов  $\Omega_i \in \Omega$ . Для каждого класса случайным образом инициализируются весовые коэффициенты  $\varphi_m$ , где  $m = 1, 2, \dots, M$  – счетчик числа классов. Линейные комбинации признаков и весов преобразуются в вероятности классов в соответствии с выражением

$$P(\Omega = m | \Theta) = \frac{e^{\varphi_m \mathbf{X}}}{\sum_{j=1}^M e^{\varphi_j \mathbf{X}}}.$$

После этого осуществляется обучение модели с использованием функции потерь, которая оценивает разницу между предсказанными вероятностями и истинными метками классов:

$$L(\varphi) = -\frac{1}{I} \sum_{i=1}^I \sum_{j=1}^M \Omega_{i,j} \log(P(\Omega = m | \Theta_i)),$$

где  $\Omega_{i,j}$  – индикаторная функция, которая равна единице, если наблюдение  $\Theta_i$  принадлежит классу  $\Omega_j$ , в противном случае нулю. Затем методом градиентного спуска [4] минимизируется функция потерь, а полученные градиенты используются для обновления значений весов  $\varphi_m$ .

Суть метода опорных векторов (support vector machine, SVM) заключается в поиске гиперплоскости, разделяющей классы в пространстве информативных признаков наилучшим образом.

$$\varphi^T \mathbf{X} + b = 0,$$

где  $\varphi$  – вектор весовых коэффициентов,  $\mathbf{X}$  – вектор входных данных,  $b$  – коэффициент смещения.

В соответствии с этим методом, чем больше расстояние между разделяющей гиперплоскостью и объектами разделяемых классов, именуемое зазором, тем меньше будет средняя ошибка классификатора. Поскольку большинство реальных данных являются линейно неразделимыми, чаще всего используется метод опорных векторов с мягким зазором, функция потерь для которого описывается следующей формулой:

$$L(\varphi) = \min \frac{1}{2} \|\varphi\|^2 + C \sum_{i=1}^I \max(0, 1 - \Omega_i (\varphi^T \Theta_i + b)),$$

где  $C$  – параметр регуляризации, который определяет штраф за ошибки классификации. В рамках данного исследования  $C = 1$ . Для многоклассовой классификации метод опорных векторов использует комбинацию стратегий «один против остальных» и «один против одного».

Модель случайного леса состоит из множества деревьев решений. При построении деревьев реализуется процедура бутстрепа [5], при которой для каждого дерева из набора данных  $\mathbf{X}$  формируется случайное подмножество обучающих данных с повторением, что приводит к обучению деревьев на разных наборах данных. При их разделении выбираются случайные наборы параметров, что повышает общую точность и устойчивость модели. Каждое дерево осуществляет прогнозирование, после чего прогнозы всех деревьев объединяются и по мажоритарному принципу определяется итоговый класс  $\Omega_i^*$ :



$$\Omega_i^* = \arg \max_{j \in \{1,2,3\}} \sum_{q=1}^Q w_q Y(T_q(\Theta_i) = \Omega_j),$$

где  $Q$  – число деревьев,  $q$  – счетчик числа деревьев,  $T_q(\Theta_i)$  – результат классификации  $q$ -го дерева,  $w_q$  – весовой коэффициент  $q$ -го дерева. В рамках данного исследования  $Q = 300$ .

Исследование проводилось на материалах отведения II открытых верифицированных баз данных MIT-BIH Arrhythmia DB [6] и Санкт-Петербургского Института кардиологической техники «ИНКАРТ» (INCART) [7]. В рамках исследования обработано 9500 эпизодов, принадлежащих трем классам (нормальный эпизод, эпизод желудочковой экстрасистолии и эпизод предсердной экстрасистолии). Исследуемые классы сбалансированы посредством случайного исключения наблюдений из мажоритарного класса, в данном случае класса нормальных эпизодов. Для имеющегося набора данных произведено разделение на обучающую и тестовую выборки в соотношении 3:1. Результаты оценки приведены в таблице. В качестве показателя качества классификации выбрана сбалансированная  $F$ -мера:

$$F = 2 \frac{Acc \cdot Rc}{Acc + Rc}, \quad Acc = \frac{TP}{TP + FP}, \quad Rc = \frac{TP}{TP + FN},$$

где  $Acc$  – точность;  $Rc$  – полнота;  $TP$  – число истинно положительных решений;  $TN$  – число истинно отрицательных решений;  $FP$  – число ложноположительных решений;  $FN$  – число ложноотрицательных решений.

#### Показатели качества многоклассовой классификации

Параметр	MIT-BIH Arrhythmia DB			INCART DB		
	LR	SVM	RF	LR	SVM	RF
F, %	86,01	91,98	84,39	86,33	92,41	84,71

По результатам, приведенным в таблице, очевидно, что наиболее высокие показатели качества многоклассовой классификации для обеих баз данных продемонстрировала модель на основе метода опорных векторов SVM (Support Vector Machine), что свидетельствует о его высокой эффективности в задачах многоклассовой классификации. Наихудшие показатели демонстрирует метод случайного леса, что может свидетельствовать о необходимости дополнительных исследований для более точной настройки параметров данного метода.

#### Библиографический список

1. Bouchouareb R., Ferroudji K. Classification of ECG Arrhythmia using Artificial Intelligence techniques (RBF and SVM) // 4th International Conference on Pattern Analysis and Intelligent Systems (PAIS). 2022. P. 1–7.
2. Аюпян Б. К. Классификация эпизодов нарушений сердечного ритма по информативным признакам во временной области электрокардиограммы // Известия высших учебных заведений. Приборостроение. 2024. Т. 67, № 4. С. 305–314.
3. Модель логистической регрессии как дополнительный математический метод прогнозирования нарушений сердечной проводимости в семьях г. Красноярска / С. Ю. Никулина, А. А. Чернова, В. А. Шульман [и др.] // Российский кардиологический журнал. 2014. № 10(114). URL: <https://cyberleninka.ru/article/n/model-logisticheskoy-regressii-kak-dopolnitelnyu-matematicheskiiy-metod-prognozirovaniya-narusheniy-serdechnoy-provodimosti-v-semyah-g> (дата обращения: 31.08.2024).
4. Мартынов А. В., Кандыба В. Е. Метод градиентного спуска в машинном обучении // Шаг в науку. 2022. № 4. URL: <https://cyberleninka.ru/article/n/metod-gradientnogo-spuska-v-mashinnom-obuchenii> (дата обращения: 31.08.2024).
5. Шитиков В. К. Использование рандомизации и бутстрепа при обработке результатов экологических наблюдений // Princ. ekol. 2012. № 1(1). URL: <https://cyberleninka.ru/article/n/ispolzovanie-randomizatsii-i-butstrepa-pri-obrabotke-rezultatov-ekologicheskikh-nablyudeniy> (дата обращения: 31.08.2024).
6. Moody G. B., Mark R. G. The impact of the MIT-BIH Arrhythmia Database // IEEE Engineering in Medicine and Biology. 2001. Vol. 20, №3. P. 45–50.
7. St Petersburg INCART 12-lead Arrhythmia Database. 2008. URL: <https://physionet.org/content/incartdb/1.0.0/> (дата обращения: 31.08.2024).

*А. А. Бардовский\**

аспирант

*С. Г. Фомичева\**

кандидат технических наук, профессор

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ДОВЕРЕННАЯ СРЕДА ВЫПОЛНЕНИЯ OP-TEE В ЗАДАЧАХ ЗАЩИТЫ ИНТЕЛЛЕКТУАЛЬНЫХ ИОТ-РЕШЕНИЙ

Рассматриваются технические аспекты работы со средой доверенных вычислений OP-TEE для защиты интеллектуальных IoT-решений. Статья имеет цель познакомить читателя с основными аспектами работы с OP-TEE. Описаны этапы разработки, компиляции и взаимодействия с ТА, а также процесс развертывания и конфигурирования среды OP-TEE на платформе QEMU v8. Уделено внимание проблемам и сложностям, возникшим в процессе работы с данными технологиями, и предложены возможные пути их решения.

**Ключевые слова:** IoT, OP-TEE, QEMU, ARM TrustZone, доверенные вычисления, доверенные приложения.

*A. A. Bardovsky\**

PhD Student

*S. G. Fomicheva\**

PhD, Tech., Professor

\*St. Petersburg State University of Aerospace Instrumentation

## TRUSTED EXECUTION ENVIRONMENT OP-TEE FOR PROTECTING SMART IOT SOLUTIONS

The article discusses the technical aspects of working with the OP-TEE trusted computing environment for protecting intelligent IoT solutions. The article aims to introduce the reader to the main aspects of working with OP-TEE. The main stages of development, compilation and interaction with TA, as well as the process of deploying and configuring the OP-TEE environment on the QEMU v8 platform are described. Attention is paid to the problems and difficulties that arose in the process of working with these technologies, and possible solutions are proposed.

**Keywords:** IoT, OP-TEE, QEMU, ARM TrustZone, trusted computing, trusted applications.

### Введение

Интернет вещей (IoT) охватывает миллионы интеллектуальных устройств, которые генерируют, обрабатывают огромные объемы критически важных и конфиденциальных данных и обмениваются ими, что делает эти устройства основными целями для кибератак [1–3]. Традиционные механизмы безопасности, такие как криптографические алгоритмы и протоколы, часто неэффективны, поскольку они обычно внедряются в качестве второстепенной задачи, а не являются неотъемлемой частью системы с самого начала. Такой подход делает системы IoT уязвимыми, особенно в сильно взаимосвязанных средах [4].

Учитывая всепроникающую связь устройств IoT, необходима целостная, сквозная стратегия безопасности. Один из эффективных подходов – безопасность путем изоляции [5]. Доверенные среды выполнения (TEE), такие как OP-TEE, играют решающую роль в реализации этой стратегии, предлагая надежную основу для защиты конфиденциальных данных и операций в системах IoT.

В данной работе рассматриваются технические вопросы, с которыми пришлось столкнуться в процессе работы над легким интеллектуальным агентом для обнаружения атак при распределенном машинном обучении [6]. Описывается процесс развертывания и конфигурирования среды OP-TEE на платформе QEMU v8, а также основные этапы разработки, компиляции и взаимодействия с доверенными приложениями.

### Технологии OP-TEE и QEMU

QEMU (Quick Emulator) – это мощный эмулятор с открытым исходным кодом, который позволяет эмулировать аппаратное обеспечение различных платформ. Он играет важную роль в разработке и тестировании, позволяя разработчикам создавать виртуальные среды, которые точно имитируют поведение реальных устройств, в том числе IoT. Эта возможность особенно ценна в контексте доверенных сред выполнения, таких как OP-TEE, где тестирование и отладка на физическом оборудовании могут быть сложными и ресурсоемкими.

OP-TEE (Open Portable Trusted Execution Environment) – это TEE с открытым исходным кодом, разработанная с целью обеспечения безопасной среды для запуска доверенных приложений (ТА) вместе с недоверенной операционной системой, такой как Linux. Разработанная в рамках архитектуры ARM TrustZone OP-TEE предлагает основу для изоляции критически важных операций от потенциально скомпрометированных компонентов, что имеет решающее значение в контексте безопасности IoT.

Архитектура OP-TEE разделена на два основных мира: безопасный и нормальный. В безопасном мире функционирует ОС OP-TEE, которая размещает доверенные приложения, в то время как в нормальном мире функционирует насыщенная ОС, например Linux. Такое разделение гарантирует, что даже если насыщенная ОС будет скомпрометирована, критические функции безопасности, выполняемые в безопасном мире, останутся защищенными. Способность OP-TEE обеспечивать такую надежную изоляцию делает его ключевым компонентом в обеспечении безопасности интеллектуальных решений IoT, где обеспечение целостности и конфиденциальности данных имеет первостепенное значение.

### Сборка OP-TEE для QEMU

Как было сказано, QEMU позволяет разворачивать OP-TEE без необходимости физического оборудования, ускоряя процесс разработки безопасных решений для IoT. Возможность развернуть OP-TEE на платформе QEMU позволила легко добавить данную среду доверенных вычислений в разработанный стенд для туманных вычислений [7].

OP-TEE имеет возможности простой сборки для разных платформ, включая QEMU v8. Инструкции по сборке можно найти в документации. Раздел, посвященный QEMU v8 позволяет путем выполнения нескольких простых команд подготовить все необходимое и запустить эмуляцию OP-TEE. Однако эта сборка будет включать насыщенную ОС Linux с минимальным набором утилит, который недостаточен для разработки и отладки IoT-приложений, так как OP-TEE использует инструмент buildroot для создания настраиваемой операционной системы Linux. Еще одна проблемой – отсутствие возможности прямого сетевого доступа к насыщенной ОС. Причиной служит конфигурация сети эмулятора QEMU по умолчанию. Она позволяет насыщенной ОС иметь доступ в Интернет, но к самой насыщенной ОС невозможно получить прямой доступ из внешней сети или хоста.

При конфигурации ОС Linux для включения в нее необходимых утилит были использованы средства конфигурации buildroot. В процессе работы над легким интеллектуальным агентом с целью обнаружения атак при распределенном машинном обучении была необходимость в утилите perf для мониторинга счетчиков производительности, а также в утилите openssh. Для добавления утилит необходимо изменить конфигурацию, на основе которой buildroot в процессе сборки OP-TEE собирает насыщенную ОС. Это было сделано путем добавления нескольких строк, добавляющих необходимые пакеты, в файл «optee/build/common.mk». За добавление утилит openssh и perf отвечают строки:

```
BR2_PACKAGE_LINUX_TOOLS_PERF?=y
BR2_PACKAGE_LINUX_TOOLS_PERF_SCRIPTS?=y
BR2_PACKAGE_LINUX_TOOLS_PERF_TUI?=y
BR2_PACKAGE_LINUX_TOOLS_PERF_NEEDS_HOST_PYTHON3?=y
BR2_PACKAGE_OPENSSSH=y
```

Возможно, существуют более правильные подходы для изменения конфигураций buildroot для OP-TEE, так как имеются стандартные конфигурации для различных платформ. Они находятся в директории «optee/buildroot/configs».

Для решения проблемы сетевого доступа к насыщенной ОС были изменены параметры запуска эмуляции QEMU. В них был добавлен параметр переадресации одного из портов для возможности использования службы ssh. В случае необходимости иметь прямой доступ к виртуальной машине QEMU следует изменить тип сети. Параметры запуска эмуляции находятся в файле «optee/build/common.mk». Измененные параметры выглядят следующим образом: QEMU\_EXTRA\_ARGS +=\

```
-netdev user,id=vmnic$(HOSTFWD),hostfwd=tcp::2222-:22 -device virtio-net-device,netdev=vmnic.
```

Доступ к насыщенной ОС с хоста по ssh производился с помощью команды ssh -p 2222 login@localhost.

### Компиляция доверенных приложений для OP-TEE

В OP-TEE существуют два способа реализации доверенных приложений: доверенные приложения пользовательского режима (TA) и псевдо-TA (PTA). TA – полнофункциональные доверенные приложения, соответствующие спецификации GlobalPlatform API TEE. В большинстве случаев данный тип доверенных приложений является предпочтительным. PTA не являются доверенными приложениями. Это интерфейс, предоставляемый ядром OP-TEE внешнему миру: защищенным клиентским доверенным приложениям и незащищенным клиентским сущностям. PTA отличаются от TA в следующем:

- 1) PTA работают на более высоком уровне привилегий. Это может быть полезно в некоторых случаях;
- 2) PTA могут быть добавлены только в процессе сборки OP-TEE. Другими словами, PTA встраиваются в ядро OP-TEE на этапе сборки.

Подробная инструкция по компиляции TA присутствует в документации OP-TEE. Для того чтобы создать и скомпилировать TA для интеллектуального агента безопасности была выполнена следующая последовательность действий:

- 1) написан его код TA и сгенерирован его уникальный UUID;
- 2) настроен make-файл, специфичный для создаваемого TA;
- 3) используя кросс-компилятор ARM для сборки TA, была выполнена команда make, которая сгенерировала двоичный файл;

4) данный файл был положен в директорию «lib/optee\_armtz» насыщенной ОС и были изменены для него права доступа, которые добавляют возможность чтения файла другим пользователям.

После этого созданное доверенное приложение было автоматически загружено в безопасный мир OP-TEE и готово к использованию.

Также в процессе работы над интеллектуальным агентом была необходимость чтения регистров производительности процессора. Данную операцию невозможно выполнить из ТА в силу недостаточного уровня привилегий. Поэтому для этих целей было написано РТА. Код РТА должен иметь те же точки входа, что и ТА. Для добавления РТА в OP-TEE было проделано:

- 1) файл с исходным кодом РТА расположен в директории «optee/optee-os/core/pta»;
- 2) сгенерирован UUID для данного РТА;
- 3) добавлен в исходный код РТА вызов макроса `pseudo_ta_register()`, который используется в OP-TEE для регистрации РТА в ядре OP-TEE;
- 4) модифицирован скрипт сборки: в файл «sub.mk» добавлена строка для включения исходного кода РТА в систему сборки OP-TEE;
- 5) пересобрана OP-TEE.

Важно отметить, что при некоторых ошибках в исходном коде РТА в выводе системы сборки OP-TEE не будет никаких ошибок, которые бы касались этого РТА. Это усложняет процесс разработки.

### Заключение

Были рассмотрены основные технические аспекты работы со средой доверенных вычислений OP-TEE для защиты интеллектуальных IoT-решений. Особое внимание было уделено процессу развертывания и конфигурирования OP-TEE на платформе QEMU, что позволило успешно ее интегрировать в испытательный стенд для туманных вычислений. В ходе работы были описаны основные этапы создания и компиляции доверенных приложений, а также выявлены проблемы и предложены пути их решения.

### Библиографический список

1. *Xu L. D., He W., Li S.* Internet of Things in Industries: A Survey // IEEE Trans. Industrial Informatics. 2014. Vol. 10, № 4. P. 2233–2243.
2. *Keoh S. L., Kumar S. S., Tschofenig H.* Securing the Internet of Things: A Standardization Perspective // IEEE Internet of Things J. 2014. Vol. 1, № 3. P. 265–275.
3. *Sadeghi A.-R., Wachsmann C., Waidner M.* Security and Privacy Challenges in Industrial Internet of Things // Proc. 52nd Design Automation Conf. 2015. P. 54:1–54:6.
4. *Langner R.* Stuxnet: Dissecting a Cyberwarfare Weapon // IEEE Security & Privacy. 2011. Vol. 9, № 3. P. 49–51.
5. *Armand F., Gien M.* A Practical Look at MicroKernels and Virtual Machine Monitors // Proc. 6th IEEE Consumer Comm. and Networking Conf. 2009. P. 1–7.
6. *Fomicheva S. G., Bardovsky A. A.* A Lightweight Smart Agent for Detecting Attacks in Distributed Machine Learning // 2024 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF), St. Petersburg, Russian Federation, 2024. P. 1–10.
7. *Бардовский А. А., Фомичева С. Г.* Создание испытательного стенда для туманных вычислений // Волновая электроника и инфокоммуникационные системы. 2024. Ч. 2. СПб.: ГУАП. С. 13–18.

*Г. А. Батайкин\**

студент

*М. Д. Поляк\**

старший преподаватель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ОПРЕДЕЛЕНИЕ ПОЛОЖЕНИЯ КНИГ НА СТЕЛЛАЖЕ И РАСПОЗНАВАНИЕ ИХ НАЗВАНИЙ

Рассматривается проблема инвентаризации книг на книжных полках и стеллажах с применением методов машинного зрения. Решаются задачи обнаружения книг, определения их положения на книжной полке или стеллаже, а также распознавания названия и автора на переплете.

**Ключевые слова:** распознавание объектов, сегментация изображения, YOLOv8, оптическое распознавание символов, OCR, Pytesseract, EasyOCR.

*G. A. Bataikin\**

Student

*M. D. Polyak\**

Senior Lecturer

\*St. Petersburg State University of Aerospace Instrumentation

## DETECTION OF BOOKS ON A SHELF WITH TITLE RECOGNITION

This paper addresses the problem of book inventory on shelves and racks using computer vision methods. The tasks include detecting books, determining their position on the shelf or rack, and recognizing the title and author on the spine.

**Keywords:** object recognition, image segmentation, YOLOv8, optical character recognition, OCR, Pytesseract, EasyOCR.

### Введение

Задача распознавания и классификации объектов на изображениях активно исследуется на протяжении последних нескольких десятилетий. Развитие технологий машинного обучения, а также появление мощных архитектур глубоких нейронных сетей, таких как DeepLab, PantherNet, YOLO (You Only Look Once) [1], привели к значительному прогрессу в области распознавания объектов на изображениях. Однако применение данных технологий к специфическим задачам, таким как распознавание книг на стеллажах и автоматическая фиксация основной информации о них, до сих пор имеет сложности в реализации. Данная задача усложняется различными факторами, включая разнородность дизайна обложек книг, возможные искажения перспективы, и наличием текстовых блоков различных размеров и шрифтов.

Настоящая работа направлена на разработку и тестирование системы, способной не только с достаточной точностью выделять книги на изображении, но и распознавать их название и автора. Для решения данной задачи использовалась модель YOLOv8 [2], известная высокой точностью и быстротой в задачах обнаружения и сегментации объектов. В дополнение к этому для распознавания текста были применены технологии оптического распознавания символов (OCR) [3], включая такие инструменты, как Pytesseract [4] и EasyOCR [5]. Эти инструменты позволяют эффективно извлекать текстовую информацию, содержащуюся на изображениях.

### YOLO

Алгоритм YOLO (You Only Look Once) представляет собой одну из самых популярных и эффективных моделей для задач обнаружения объектов на изображениях. В отличие от других методов, таких как R-CNN, где процесс распознавания объектов происходит в несколько этапов, YOLO осуществляет обнаружение объектов в один проход, что значительно ускоряет процесс. Основным принцип работы YOLO заключается в разделении изображения на сетку и прогнозировании ограничивающих рамок (bounding boxes), а также вероятностей принадлежности объектов к определенным классам для каждой ячейки сетки. Модель предсказывает несколько ограничивающих рамок для каждой ячейки, а также вероятность того, что рамка содержит объект и его класс. Затем на основе этих предсказаний происходят фильтрация и удаление дублирующихся рамок с использованием метода немаксимального подавления (non-max suppression), что позволяет выбрать наиболее вероятные предсказания.

В данной работе была использована модель yolov8m.pt, являющаяся частью восьмого поколения архитектуры YOLO. Версия m (medium) этой модели представляет собой сбалансированное решение, обеспечивающее достаточную точность при небольшом размере и быструю скорость обучения в сравнении со старшей моделью l. Модель YOLOv8m отличается улучшенной точностью по сравнению с предыдущими версиями благодаря оптимизированной архитектуре, использующей современные подходы в области глубокого обучения, такие как сверточные нейронные сети (CNN) и улучшенные блоки свертки и подвыборки.

## EasyOCR и TesseractOCR

EasyOCR – это библиотека для OCR, разработанная на основе глубоких нейронных сетей. Поддерживает множество языков и шрифтов, что делает ее гибким и универсальным инструментом для распознавания текста в самых разных сценариях. В основе EasyOCR лежат модели сверточных нейронных сетей, которые позволяют эффективно обрабатывать сложные изображения и достигать высокой точности даже при наличии различных искажений, шумов или других факторов, затрудняющих распознавание текста.

TesseractOCR – одна из старейших и наиболее проверенных временем библиотек для OCR, изначально разработанная компанией Hewlett-Packard и позже усовершенствованная Google. Tesseract использует методику распознавания текста, основанную на многоступенчатом процессе: начиная с бинаризации изображения и заканчивая анализом распознанного текста с целью исправления ошибок. С момента своего создания Tesseract претерпел множество улучшений, включая интеграцию современных технологий машинного обучения, что позволило значительно повысить точность и скорость работы алгоритма. Одно из ключевых преимуществ Tesseract – поддержка большого количества языков и возможность распознавания сложных текстов, таких как многострочные и многоязычные документы.

### Подготовка обучающей выборки

Для дообучения yolov8m необходимо сформировать датасет из размеченных данных, по которым модель научится находить искомые объекты. Для подготовки данных были рассмотрены две платформы: Roboflow [6] и CVAT [7].

Roboflow Annotate – это онлайн-инструмент для маркировки изображений с целью обнаружения объектов, классификации и сегментации. Он не только предоставляет удобный интерфейс для разметки, но и позволяет оценить качество и полноту собранных данных, визуализируя расположение объектов на тепловой карте, а также количество изображений конкретного размера. После разметки данный инструмент помогает структурировать данные для конкретной модели, разделить их на обучающую, тестовую и валидационную выборки, предобработать их, а также подвергнуть аугментации.

CVAT – платформа для разметки изображений с целью последующей классификации, обнаружения объектов, семантической и экземплярной сегментации, формирования облака точек, 3D-кубидов, видеоаннотации или выделения скелета объекта. Данная платформа обладает всеми достоинствами Roboflow, однако онлайн-версия не имеет бесплатных тарифов, а оффлайн предполагает запуск контейнеров в docker, что требует значительных вычислительных мощностей. Данные проблемы стали причиной для использования Roboflow Annotate в качестве основного инструмента разметки.

В итоге был сформирован и размечен датасет (рис. 1) для обучения из 119 изображений, на которых содержится более 1000 размеченных объектов.

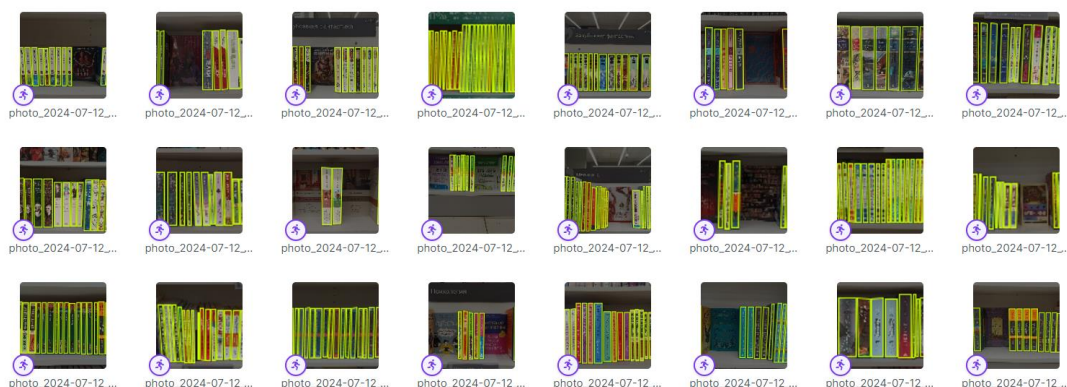


Рис. 1. Визуальное представление готового датасета

### Обучение модели

Обучение модели происходило с использованием вычислительных мощностей Google Colab [8; 9] с использованием ускорителя NVIDIA T4. Значения использованных при обучении параметров приведены в табл. 1.

Таблица 1

#### Параметры обучения

Epochs	100
Imgsz	640
Batch	16

Ход обучения показан на рис. 2. Итоговые метрики обученной модели приведены в табл. 2.

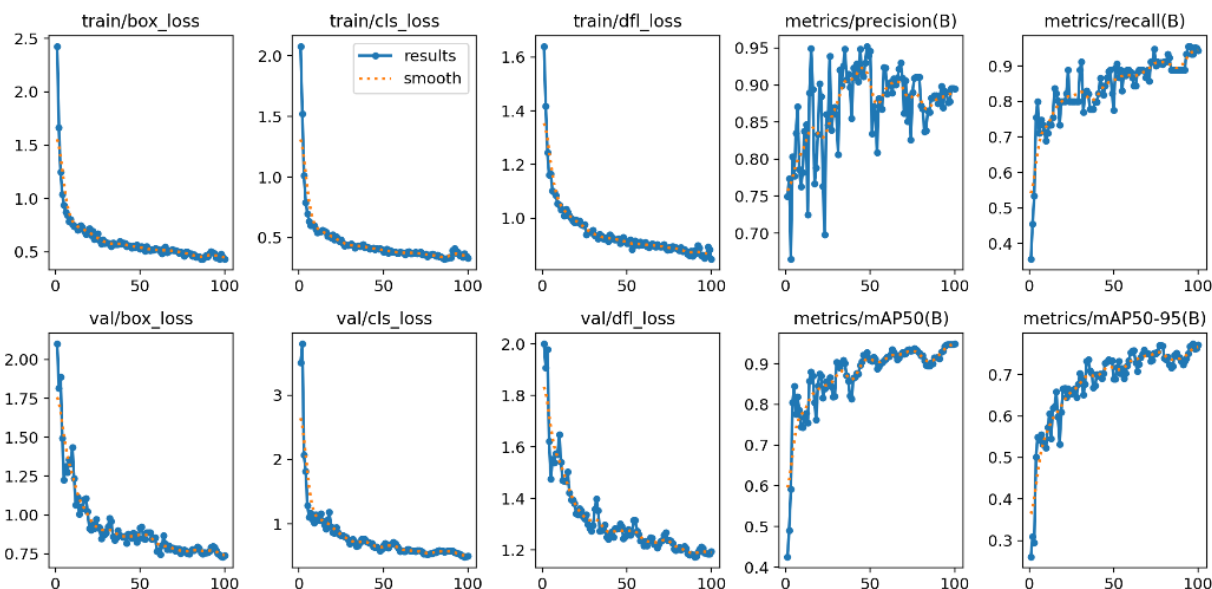


Рис. 2. Кривые метрик обучения

Таблица 2

**Результирующие значения метрик обучения**

Precision	Recall	mAP50	mAP50-95
0.878	0.933	0.949	0.775

**Анализ результатов**

После дообучения модель yolov8m прекрасно справляется с обнаружением книг даже в нагруженных сценах. Пример работы модели приведен на рис. 3.



Рис. 3. Визуализация работы модели YOLOv8

При нахождении посторонних объектов в кадре алгоритм все еще показывает хорошие результаты, однако если книга будет чем-то закрыта, то с высокой вероятностью она не будет распознана. Как показано на рис. 4, при скрытии книги на 10–20% она все еще будет обнаружена, однако соседние книги, скрытые почти на половину, не обнаруживаются.

Обнаружено книг: 6



Рис. 4. Обработка скрытых объектов

При распознавании текста возникла проблема определения ориентации текста. Решить ее с помощью встроенного в PyTesseract метода `image_to_osd()` не удалось, поэтому был использован альтернативный подход.

При распознавании текста PyTesseract возвращает распознанный текст и уровень достоверности распознавания. При сравнении результатов распознавания корректной и отличной от нее ориентации была получена тепловая карта корреляции (рис. 5). По ней можно увидеть, что текст, распознанный при правильной ориентации ( $label = 1$ ), имеет высокий уровень достоверности, при этом большое количество специальных символов может говорить о неверной ориентации книги ( $label = 0$ ).




Рис. 5. Тепловая карта корреляции

Для решения задачи определения ориентации текста было решено обучить отдельную модель, которая будет принимать решение о корректности ориентации книги. В качестве модели для решения проблемы классификации был выбран метод опорных векторов (Support Vector Machines, SVM) [10]. По результатам обучения алгоритм успешно справляется с определением ориентации книги (рис. 6).






Рис. 6. Результат распознавания текста

При распознавании текста алгоритм путает некоторые буквы со специальными символами, (например, букву «С»). В большинстве случаев такая проблема возникает, только когда буква стоит в начале строки. Также есть проблемы с некорректной последовательностью распознанных блоков текста, как в примере с книгой «ТОЧКА ДЕН БРАУН ОБМАНА» или с распознаванием текста на разных языках в рамках одного изображения. Решение перечисленных проблем в данной работе рассматриваться не будут.

### Результаты и выводы

По итогам работы был разработан алгоритм с использованием нескольких моделей машинного обучения, который справляется с поставленной задачей обнаружения книг и распознавания текста на их корешках. Разработанный алгоритм может быть интегрирован в программные продукты, осуществляющие решение задач по учету библиотечного фонда. Дальнейшее развитие и улучшение алгоритма может заключаться в решении проблем распознавания сложных шрифтов, а также многострочных текстов с несколькими колонками.

### Библиографический список

1. You Only Look Once: Unified, Real-Time Object Detection / J. Redmon, S. Divvala, R. Girshick, A. Farhadi // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 779–88.
2. Jocher G., Chaurasia A., Qiu, J. Ultralytics YOLO (Version 8.0.0). 2023. URL: <https://github.com/ultralytics/ultralytics> (дата обращения: 01.09.2024).
3. Поляк М. Д. Модель стохастической искусственной нейронной сети в задачах распознавания образов // Научно-технические ведомости Санкт-Петербургского государственного политехнического университета. Информатика. Телекоммуникации. Управление. 2013. № 1(164). С. 33–38.
4. Smith R. An Overview of the Tesseract OCR Engine // ICDAR '07: Proceedings of the Ninth International Conference on Document Analysis and Recognition. IEEE, 2007. P. 629–633.
5. EasyOCR. URL: <https://github.com/JaidedAI/EasyOCR> (дата обращения: 01.09.2024).
6. Roboflow (Version 1.0) / B. Dwyer, J. Nelson, T. Hansen [et al.]. 2024. URL: <https://roboflow.com> (дата обращения: 01.09.2024).
7. Computer Vision Annotation Tool (CVAT) (Version 2.8.2) // CVAT.ai Corporation. URL: <https://github.com/cvat-ai/cvat> (дата обращения: 01.09.2024).
8. Google Colaboratory. URL: <https://colab.research.google.com> (дата обращения: 01.09.2024).
9. Bisong E. Google Colaboratory // Building Machine Learning and Deep Learning Models on Google Cloud Platform. Apress, Berkeley, CA. 2019.
10. Cortes C., Vapnik V. Support-vector networks // Machine learning. 1995. Vol. 20(3). P. 273–297.

*М. Ю. Бердина*

кандидат экономических наук, доцент

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ВО ФРАНЧАЙЗИНГЕ

Показано, что применительно к франчайзингу целесообразно реализовать инструменты двух типов искусственного интеллекта: корпоративный и генеративный. Приведены примеры практического применения искусственного интеллекта во франчайзинговой деятельности.

**Ключевые слова:** франчайзинг, искусственный интеллект.

*M. Yu. Berdina*

PhD, Economic, Associate Professor

St. Petersburg State University of Aerospace Instrumentation

## USING ARTIFICIAL INTELLIGENCE IN FRANCHISING

The paper shows that it is useful to implement two types of artificial intelligence tools for franchising: corporate and generative. Examples of the practical application of artificial intelligence in franchising activities are given.

**Keywords:** franchising, artificial intelligence.

В наши дни, вместо того чтобы ограничиваться миром сетевых вычислений и ИТ-услуг, искусственный интеллект и возможности машинного обучения начинают проникать в отдельные отрасли и бизнес-сектора по всем направлениям. Искусственный интеллект (ИИ) и франчайзинг в настоящее время становятся, как это ни казалось бы парадоксальным для данного вида предпринимательской деятельности, естественным сочетанием и явлением. Учитывая стремительное проникновение ИИ в повседневную жизнь и деловую практику, он, скорее всего, будет играть значительную роль в эффективности, рекламе и продвижении, создании и сборе данных, а также прибыльности тех франчайзинговых сетей, которые включают его различные инструменты в текущей работе.

Исходя из типологии ИИ, отметим, что применительно к франчайзингу целесообразно реализовать инструменты двух типов ИИ [1]:

- корпоративный – приложение машинного обучения, используемое для повседневной деловой активности, которое может адаптироваться, совершенствоваться и функционировать автономно, часто путем сортировки, маркировки и принятия решений на основе входных данных;
- генеративный, который производит/создает новый контент, использует, как правило, гораздо более обширные данные для обучения и достижения в обработке естественного языка для обеспечения творческих или других форм выражения.

Учитывая сетевую природу франчайзингового бизнеса, сам принцип сетевого подхода позволяет применять весьма эффективно именно генеративный ИИ (чат-боты, чат GPT и пр.). Участники франчайзинговых отношений могут планировать и делать многое из того, что они намерены реализовывать в рамках текущей деятельности, просто общаясь.

ИИ может иметь множество применений во франчайзинге. Например, помочь в поиске, оценке и выборе потенциальных франчайзи; разработать более эффективную интеграцию и эксплуатацию соответствующих франчайзинговых систем и операций; собирать, оценивать и манипулировать данными и поведением клиентов для увеличения продаж; помогать в оценке, производительности и найме сотрудников франчайзи.

Международная ассоциация франчайзинга (IFA) выпустила белую книгу под названием «Сила искусственного интеллекта» [2], где рассматриваются различные варианты использования ИИ для франчайзинга в маркетинге и трансформации бизнеса. Эксперты IFA отмечают, что «искусственный интеллект продолжает быстро трансформировать ландшафт цифрового маркетинга, позволяя компаниям глубже понимать своих клиентов, оптимизировать свои рекламные кампании и персонализировать свои маркетинговые усилия. Поскольку объем цифровых данных продолжает расти в геометрической прогрессии, традиционные маркетинговые методы становятся менее эффективными. Вот почему ИИ стал важным инструментом для маркетологов, позволяя им использовать алгоритмы машинного обучения и прогнозную аналитику для лучшего понимания своей аудитории и предоставления более релевантного и увлекательного опыта» [3].

Однако с таким всеобъемлющим ожидаемым использованием ИИ во франчайзинге возникает риск нарушения конфиденциальности и данных и их неправильного использования. Франчайзеры и франчайзи должны понимать, что им, возможно, придется застраховаться от таких рисков и предпринять все необходимые шаги, чтобы избежать их или пострадать от последствий и негативной реакции со стороны потребителей, которые потеряют доверие к бренду франчайзинговой сети из-за таких нарушений и неправильного использования в результате использования ИИ.

Основное преимущество применения ИИ во франчайзинге – получение конкурентного преимущества на рынке. Применительно к франчайзеру ИИ применяется с точки зрения работы с большими данными. У франчайзеров есть огромные массивы информации (данных) об их бизнес-модели, портрете идеального кандидата во франчайзи и показателях, которые измеряют их финансовые показатели по сравнению с конкурентами. ИИ помогает франчайзерам раскрыть потенциал, который заложен в их данных, и то, как можно применять прогностическую аналитику для принятия лучших и более обоснованных решений о направлении и эффективности развития всей сети. ИИ помогает франчайзерам консолидировать всю получаемую от франчайзи информацию, анализировать ее и в виде сформулированных гипотез и решений, выдавать франчайзи необходимые рекомендации по работе. Также сюда можно отнести и, казалось бы, такие простые для понимания преимущества, как автоматизация задач, улучшение приложений обслуживания клиентов и повышение узнаваемости бренда и рыночности тех самых продуктов и услуг, которые франчайзеры предлагают потребителям.

Для потенциального франчайзи процесс поиска подходящей франшизы, чтобы стать его полноценным участником, может быть непосильной задачей. Это не так уж и удивительно, если учесть, что сегодня на рынке представлено порядка 4000 различных типов франчайзинговых концепций по всему миру. При таком количестве информации, не говоря уже о сложных этапах, связанных с процессом присоединения к сети, многие кандидаты во франчайзи просто не знают, с чего начать. Теперь, благодаря применению инструментов ИИ, которые предназначены для улучшения и совершенствования процесса поиска информации, все стало намного проще. Так, например, разработана функционирует в формате бета-тестирования платформа ИИ, которая по сути функционирует как инструмент предварительной квалификации. Задавая вопросы и отвечая на подсказки пользователя, любой кандидат во франчайзи может получить ответы на свои вопросы и получить также доступ к руководству по работе той или иной франчайзинговой сети, основанные на десятилетиях аналитических знаний. А это, в свою очередь, может помочь им принимать более обоснованные решения о своих собственных предпочтениях в отношении присоединения к той или иной сети. Прежде всего, этот инструмент ИИ может использовать свою функцию предиктивного анализа, чтобы определить, подходит ли предприниматель в кандидаты-франчайзи.

Конкуренция в сфере франчайзинга очень высока. С тысячами франчайзинговых брендов в различных отраслях генерация франчайзинговых лидов может быть сложной задачей. В то же время узкий рынок труда создает проблему для существующих франчайзеров, поскольку они изо всех сил пытаются набрать надежных специалистов, чтобы идти в ногу со спросом клиентов.

Искусственный интеллект в своем активе имеет множество приложений, которые можно использовать во франчайзинговом бизнесе для решения возможных проблем. Среди наиболее популярных приложений можно назвать следующие [3]:

- разработка франчайзинговой концепции: технология искусственного интеллекта может помочь франчайзеру определить основные характеристики его успешных франчайзи, что позволит улучшить стратегию подбора персонала для повышения коэффициентов конверсии;

- чат-боты. Франчайзинговые компании могут использовать чат-ботов на своих сайтах и в социальных сетях для поддержки и привлечения клиентов. Чат-боты экономят время и деньги, отвечая на простые вопросы без привлечения дополнительного персонала;

- персонализированный маркетинг. Анализируя данные о клиентах, искусственный интеллект придает маркетинговым усилиям индивидуальный подход. Он также позволяет франчайзи адаптировать кампании к различным демографическим группам, чтобы расширить охват и увеличить конверсию. Генерация контента с помощью искусственного интеллекта также может сэкономить время и повысить креативность;

- обучение. ИИ может улучшить набор персонала и оптимизировать обучение, предлагая виртуальные учебные пособия и решения, смоделированные с помощью ИИ.

Внедрение инициативы ИИ может повысить эффективность, увеличить инновации и сократить расходы, но для того, чтобы увидеть результат, требуется тщательное планирование. Руководителям компаний необходимо проявлять осторожность и помнить о рисках. Чтобы успешно внедрить ИИ во франчайзинговый бизнес, целесообразно сосредоточиться на какой-то одной его сфере. Например, для франчайзера бытовых услуг обучение является одним из ключевых аспектов бизнеса. В этом случае использование обучающей платформы должно позволить всем нашим франчайзи процветать. В результате компании-франчайзеру следует сосредоточиться на том, как ИИ может продвинуть усилия сети по обучению вперед. Причем от потенциальных франчайзи может даже не требоваться опыта в бытовых услугах для запуска бизнеса. Им просто нужны лидерские и деловые навыки, чтобы быть эффективными. В результате многим из новых франчайзи необходимо оттачивать свои навыки и методы продаж по мере начала работы. Франчайзер больше полагается (в случае использования в качестве помощника ИИ) на ролевые сессии во время первоначального обучения персонала в своей штаб-квартире, чтобы позволить франчайзи набраться опыта. Есть приложения, позволяющие погрузить франчайзи во время обучения в условия, приближенные к реальным. Франчайзи могут надеть гарнитуру VR и участвовать в виртуальном звонке по продажам с искусственным человеком. Также франчайзеры используют инструменты обучения ИИ, чтобы помочь своим франчайзи обучать новых сотрудников и переводить на другие языки учебные материалы. Такое виртуальное обучение дает участникам самостоятельный, 360-градусный опыт.

Наличие надежной программы обучения повышает успех франчайзи, увеличивая их количество. Использование ИИ для обучения франчайзи позволяет сэкономить время корпоративной команды франчайзера, оптимизировать обучение и обеспечить гибкость для всех франчайзи конкретной сети.

В качестве примера приведем несколько вариантов практического применения ИИ во франчайзинговой деятельности.

1. Определение приоритетных целей.

Прежде чем начинать инициативу использования инструментов ИИ в текущей деятельности, необходимо обозначить приоритетные цели и задачи, которых компания хочет достичь с помощью той или иной новой технологии. Чтобы определить эти позиции, целесообразно создать целевую группу, состоящую из членов разных отделов, для оценки и определения тех областей бизнеса, которые могут выиграть от автоматизации и повышения производительности.

2. Выбор правильного партнера по использованию ИИ.

При оценке поставщика ИИ нужно убедиться, что его технологические или программные решения будут соответствовать потребностям франчайзинговой сети и интегрироваться с ее текущими системами. Использование ресурсов компании, которая понимает цели своего потенциального клиента и имеет необходимый опыт, может достичь результатов. При поиске правильного партнера важно, чтобы он был с хорошей репутацией и имел работоспособное оборудование или программное обеспечение в той же сфере деятельности, что и франчайзер. Оптимально запросить у него демопродукт, чтобы получить более глубокое понимание.

3. Тестирование новых решений.

Обязательно необходимо провести пилотное тестирование любого ИТ-решения перед его запуском в любой франчайзинговой системе. В этой связи важно получить обратную связь от разработчиков, чтобы убедиться, что ПО удобно для пользователя и эффективно. Поставщики предлагают демонстрации и пробные периоды, чтобы оценить, будет ли решение полезным для бизнеса.

4. Адаптивность.

Технологии ИИ постоянно развиваются. Необходимо быть в курсе достижений ИИ, чтобы оставаться в числе лидеров. После внедрения новой программы важно периодически пересматривать решение и просить поставщика ПО регулярно обновлять свои продукты для внедрения технологических достижений.

Однако, как бы не был хорош ИИ, он никогда не заменит человеческое прикосновение, но уже сейчас добился значительных успехов и сыграет важную роль в изменении нашего будущего. Оставаясь в курсе последних разработок ИИ, франчайзинговый бизнес может стать более конкурентоспособным, генерировать дополнительные лиды и обеспечивать качественную эффективность работы любой франчайзинговой сети.

### Библиографический список

1. *Lieberstein M., Neiditz J.* Artificial Intelligence and Franchising // *New York Law Journal*. 2023. October 25.
2. *Welch J. A., Trounce D. R., Smith M. S.* The Power of A.I.: How It Can Revolutionize Your Business and Propel You to Success.- *Waystone Media Development*, 2023. 217 p.
3. *Izaks L.* Revolutionizing the workplace: how chatgpt is changing the game. URL: <https://www.franchise.org/blog/revolutionizing-the-workplace-how-chatgpt-is-changing-the-game> (дата обращения: 10.09.2024).

*Т. А. Васяева\**

кандидат технических наук, доцент

*М. А. Рябко\**

магистрант

\*Донецкий национальный технический университет

## ПРИМЕНЕНИЕ ГЕНЕТИЧЕСКИХ АЛГОРИТМОВ ДЛЯ РАЗРАБОТКИ АДАПТИВНЫХ ВЕБ-САЙТОВ

Рассматривается способ применения генетического алгоритма для разработки адаптивных веб-сайтов. Генетические алгоритмы как одна из технологий искусственного интеллекта используются для оптимизации параметров сайта, например количества подключенных файлов. Приведен пример работы генетического алгоритма, который поможет оптимизировать работу сайта на различных устройствах с точки зрения адаптивности и производительности.

**Ключевые слова:** генетический алгоритм, адаптивность, веб-сайт, искусственный интеллект, веб-дизайн, оптимизация.

*T. A. Vasiaeva\**

PhD, Tech., Associate Professor

*M. A. Riabko\**

Postgraduate Student

\*Donetsk National Technical University

## USING GENETIC ALGORITHMS TO DEVELOP RESPONSIVE WEBSITES

In this article, a method for applying a genetic algorithm for the development of adaptive websites is discussed. Genetic algorithms, as a technology within artificial intelligence, are used to optimize website parameters, such as the number of connected files. This article will provide an example of how a genetic algorithm works to help optimize the performance of a website on various devices in terms of adaptability and efficiency.

**Keywords:** genetic algorithm, adaptivity, website, artificial intelligence, web design, optimization.

### Введение

В современном мире все больше людей используют мобильные устройства для доступа к сети Интернет. Это создает значительные вызовы для веб-разработчиков, которые должны обеспечить оптимальное отображение своих веб-сайтов на различных устройствах (ПК, смартфоны, планшеты) под разными операционными системами (Windows, Android, IOS). Развитие технологий искусственного интеллекта способствует успешному решению этой проблемы. В области адаптивного дизайна веб-сайтов разработчики используют передовые технологии для улучшения поиска наилучших решений, основанных на заданных критериях, при нахождении наиболее эффективных и удовлетворительных макетов. В данной статье рассмотрено применение генетических алгоритмов для разработки адаптивного веб-сайта.

### Цель исследования

Цель исследования состоит в разработке генетического алгоритма для оптимизации производительности и адаптивности веб-сайтов на различных устройствах за счет оптимизации параметров, таких как макет страницы, количество подключенных файлов, размер и формат изображений, использование шрифтов и кэширование.

### Реализация генетического алгоритма

Генетические алгоритмы используются для нахождения оптимальных решений в сложных задачах. В данной работе применим их при разработке адаптивных веб-сайтов. Рассмотрим этапы разработки.

Первый шаг – определение критерия оптимизации (фитнесс-функции). В контексте разработки адаптивных веб-сайтов поставим цель минимизировать время загрузки и улучшить производительность сайта на различных устройствах, таким образом, критерием оптимизации является минимизация времени загрузки страницы веб-сайта. Для подсчета времени загрузки веб-страницы используется функция языка JavaScript. Данный критерий был выбран из-за того, что скорость загрузки может зависеть от большого количества параметров [1].

Каждый индивид в популяции представляет собой набор параметров веб-сайта, которые используются для генерации конфигурации веб-страницы. Были выбраны следующие параметры оптимизации: макет страницы (grid, flexbox, float или block), количество подключенных CSS-файлов (от 1 до 10), количество подключенных JavaScript-файлов (от 1 до 10), количество изображений на странице (от 1 до 20), формат изображений (jpeg, png, webp), количество шрифтов на странице (от 1 до 5), размер шрифтов (от 10 до 50 pt), наличие кэширования. Таким образом, каждому индивиду соответствует веб-сайт с параметрами, определенными его структурой.

Рассмотрим функцию скрещивания [2]. Отобранные индивиды оператором репродукции скрещиваются для получения потомков. Операция скрещивания происходит путем выбора значения для каждого параметра. Выбор значения осуществляется от первого или второго родителя (вероятность 0,5).

Для поддержания разнообразия в каждой популяции каждый индивид подвергается мутации. Мутация изменяет некоторые параметры индивида случайным образом.

Отбор лучших индивидов производится на основе их функции приспособленности. Решается задача минимизации фитнес-функции, чтобы минимизировать время загрузки сайта. На рисунке представлена программная реализация функций скрещивания и мутации.

```
# Скрещивание двух родителей
def crossover(parent1, parent2):
    child = {}
    for key in parent1:
        child[key] = parent1[key] if random.random() > 0.5 else parent2[key]
    return child

# Мутация модели
def mutate(model):
    key = random.choice(list(model.keys()))
    if key == 'layout':
        model[key] = random.choice(['grid', 'flexbox', 'float', 'block'])
    elif key in ['css_files', 'js_files']:
        model[key] = random.randint(1, 10)
    elif key == 'image_count':
        model[key] = random.randint(1, 20)
    elif key == 'image_format':
        model[key] = random.choice(['jpeg', 'png', 'webp'])
    elif key == 'font_count':
        model[key] = random.randint(1, 5)
    elif key == 'font_size':
        model[key] = random.randint(10, 50)
    elif key == 'caching':
        model[key] = not model[key]
```

Функции скрещивания и мутации

Генетический алгоритм выполняется на протяжении нескольких поколений, пока не будет достигнут критерий остановки. Критерий остановки может быть основан на максимальном количестве поколений, достижении минимального времени загрузки или стабилизации популяции [3].

Работа данного генетического алгоритма начинается с инициализации начальной популяции (веб-сайтов с разнообразными параметрами, влияющими на скорость загрузки веб-сайта [4]) случайным образом. В каждом поколении алгоритм программно оценивает время загрузки веб-страницы, отбирает лучшие конфигурации и использует их для создания нового поколения путем скрещивания и мутации. Этот процесс повторяется на протяжении заданного количества поколений с целью поиска оптимального решения. Результатом работы генетического алгоритма является конфигурация сайта с наименьшим временем загрузки и лучшей производительностью, что обеспечивает адаптивность сайта на различных устройствах.

### Тестирование работы генетического алгоритма

Разработанный генетический алгоритм протестирован в реальных условиях. Было проведено более ста различных генераций, из которых были выбраны наилучшие результаты (табл. 1).

Таблица 1

Лучшее решение, найденное генетическим алгоритмом

Параметр	Значение
Макет	Flexbox
Количество подключенных CSS-файлов	1
Количество подключенных JS-файлов	1
Количество изображений на странице	1
Формат изображения	.jpeg
Количество использованных шрифтов	1
Размер шрифта	12
Наличие кэширования	+

Реализован базовый веб-сайт с найденной генетическим алгоритмом конфигурацией.

## Реализация и тестирование веб-сайта

После анализа результатов работы генетического алгоритма был разработан веб-сайт с помощью языка HTML и таблиц стилей CSS. Использовались все параметры, указанные в табл. 1. Также были реализованы другие варианты веб-страницы. Экспериментальные исследования представлены в табл. 2.

Таблица 2

### Экспериментальные исследования по времени загрузки

Параметры оптимизации	Время загрузки, мс
Flexbox, 1, 1, 1, .jpeg, 1, 12, +	24,56
Grid, 5, 2, 4, .webp, 2, 14, +	43,00
Flexbox, 2, 1, 2, .png, 1, 14, +	35,21
Flexbox, 3, 3, 1, .png, 1, 13, -	31,54
Grid, 1, 2, 2, .jpeg, 2, 12, +	29,43

Проведены исследования по подсчету времени, необходимого для загрузки веб-страницы на устройствах с различным разрешением экрана. По результатам работы на различных устройствах был сделан вывод, что среднее время загрузки приближается к 25–30 мс. Тестирование проводилось с помощью виртуальных средств тестирования. Результаты тестирования для сайта с конфигурацией табл. 1 показаны в табл. 3.

Таблица 3

### Тестирование на устройствах с различным разрешением экрана

Устройство	Разрешение экрана	Время загрузки
iPad Pro	1024x1366	29,34 миллисекунд
Samsung Galaxy A51	412x914	36,41 миллисекунд
Google Nest Hub Max	1280x800	31,12 миллисекунд

Проведя тестирование веб-сайта на различных устройствах с разным разрешением экрана и, сравнив результаты с другими вариантами веб-сайта, описанными в табл. 2, мы пришли к выводу, что время загрузки веб-страницы изменяется в зависимости от описанных параметров, но имеют значение скорость работы веб-сервера и технические характеристики устройства. Время загрузки может изменяться из-за использования «неблагоприятных» параметров, например изображений другого формата и размера, скорости интернет-соединения или использования большого количества подключенных файлов [5].

## Заключение

В ходе исследования разработан генетический алгоритм для оптимизации параметров адаптивных веб-сайтов. Проведенный анализ показал, что использование генетического алгоритма позволяет улучшить производительность сайта, минимизируя время его загрузки и повышая адаптивность на различных устройствах. Применение этого подхода может быть полезным инструментом для веб-разработчиков, стремящихся создать быстрые и эффективные веб-сайты.

В дальнейшем планируется доработка существующего генетического алгоритма, которая расширит его функционал и позволит выполнять оптимизацию по другим критериям.

## Библиографический список

1. *Oliver A., Monmarché N., Venturini G.* Interactive Design of Web Sites with a Genetic Algorithm // ICWI. 2002. P. 355–362.
2. *Гладков Л., Курейчик В., Курейчик В.* Генетические алгоритмы. Litres, 2022.
3. *Asllani A., Lari A.* Using genetic algorithm for dynamic and multiple criteria web-site optimizations // European journal of operational research. 2007. Т. 176, № 3. P. 1767–1777.
4. *Modé E.* Responsive Web Design and Optimizing Loading Times on Mobile Devices for Enhanced Web Presence. 2014.
5. *Gustafson A.* Adaptive web design. Peachpit Press, 2015.

*М. М. Головкин\**

студент

*Т. М. Татарникова\**

доктор технических наук, профессор – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## НЕЙРОСЕТЕВЫЕ ПОДХОДЫ К ИДЕНТИФИКАЦИИ КЛАССИЧЕСКИХ АЛГОРИТМОВ В PYTHON

Представлена разработка нейросети для распознавания классических алгоритмов и структур данных в коде программ на Python в рамках проекта «Алгоритмы структурам данных». С использованием дообученной большой языковой модели Qwen2-0.5B и инструментов LLaMa-Factory создано программное средство, автоматизирующее проверку правильности реализации алгоритмов сортировки, поиска и оптимизации. Сформированный датасет позволяет нейросети обучаться на абстрактных представлениях алгоритмов, что увеличивает точность распознавания. Интеграция с образовательной платформой через API обеспечивает удобный интерфейс для пользователей. Разработка позволит улучшить качество оценки кода, преодолевая ограничения традиционных тестов.

**Ключевые слова:** нейросеть, алгоритмы, структуры данных, LLM, БЯМ, большая языковая модель, программное средство.

*M. M. Golovkin\**

Student

*T. M. Tatarnikova\**

Dr. Sc., Tech., Professor – Scientific Adviser

\*St. Petersburg State University of Aerospace Instrumentation

## NEURAL NETWORK APPROACHES TO THE IDENTIFICATION OF CLASSICAL ALGORITHMS IN PYTHON

The paper presents the development of a neural network for recognizing classical algorithms and data structures in Python program code as part of the «Algorithms and Data Structures» project. Using a pre-trained large language model Qwen2-0.5B and LLaMa-Factory tools, a software tool that automates the verification of the correctness of the implementation of sorting, search and optimization algorithms is created. The generated dataset allows the neural network to train on abstract representations of the algorithms, which increases the recognition accuracy. Integration with the educational platform via API provides a user-friendly interface for users. The development will improve the quality of code evaluation, overcoming the limitations of traditional tests.

**Keywords:** neural network, algorithms, data structures, LLM, BNM, big language model, software tool.

В ходе работы над проектом по предмету «Алгоритмы структуры данных» была поставлена задача разработать нейросеть для распознавания известного (классического) алгоритма в коде программы при наличии прочих известных алгоритмов этого класса. Например, решение этой задачи должно распространяться на алгоритмы сортировки, поиска, оптимизации.

В работе реализовано программное средство на основе алгоритмов обработки кода и анализа его фрагментов посредством нейронной сети для автоматизации проверок правильности реализации того или иного алгоритма или структуры данных.

Для реализации была использована и дообучена большая языковая модель (large language model, LLM) Qwen2-0.5B [1], которая состоит из 500 000 весовых коэффициентов. Также были использованы средства разработки LLaMa-Factory [2], которые представляют собой отличный способ быстро и легко усовершенствовать большие языковые модели для собственных приложений.

В ходе работы над данной нейронной сетью, был создан большой датасет данных, в которые входят такие алгоритмы и структуры данных, как:

- алгоритмы сортировки;
- алгоритмы поиска;
- структуры данных (очередь, дерево, куча);
- структуры данных (массив, список, хеш-таблица, множество, стек).

Особенность датасета состоит в том, что все переменные в коде являются абстрактным набором букв, которые не имеют никакого смысла. Это позволяет нейросети при обучении не запоминать переменные в коде.

Для удобной работы с нейросетью она была интегрирована в образовательную платформу с помощью API – ключа, с данной моделью можно взаимодействовать через интерфейс веб-приложения. Нейросеть на вход принимает любой код на языке программирования Python, а на выходе пишет алгоритм, который реализован в данном коде (рисунок).



```
def bubble_sort(self, comp: Callable[[T, T], bool]) -> None:
    if self.length == 0:
        raise ValueError("array is empty")
    for i in range(self.length):
        for j in range(self.length - i - 1):
            if comp(self[j], self[j + 1]):
                self[j], self[j + 1] = self[j + 1], self[j]
```

bubble\_sort

### *Пример работы нейронной сети*

В данной задаче нейросеть помогает избавиться от «черного ящика», когда на вход подается одна функция или код, который просто «прогоняется» по тестам и выдает, что «тесты пройдены» или противоположный результат. С помощью программы оценить качество реализации того или иного алгоритма почти невозможно, а с помощью нейронной сети – можно.

### **Библиографический список**

1. Qwen2-0.5B. URL: <https://huggingface.co/Qwen/Qwen2-0.5B> (дата обращения: 08.08.2024).
2. LLaMa-Factory. URL: <https://github.com/hiyouga/LLaMA-Factory> (дата обращения: 08.08.2024).

*Е. Д. Григорьева\**

студент

*В. А. Ушаков\**

кандидат технических наук – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ПРИМЕНЕНИЕ ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В МЕТЕОРОЛОГИИ

Рассмотрен вопрос применения технологий искусственного интеллекта в метеорологии: текущее состояние и перспективы.

**Ключевые слова:** интернет вещей, аппаратно-программный комплекс, метеорология, метео данные, «Умный город», искусственный интеллект.

*E. D. Grigorieva\**

Student

*V. A. Ushakov\**

PhD, Tech. – Scientific Adviser

\*St. Petersburg State University of Aerospace Instrumentation

## APPLICATION OF ARTIFICIAL INTELLIGENCE TECHNOLOGY IN METEOROLOGY

The application of artificial intelligence technologies in meteorology: current state and prospects.

**Keywords:** internet of things, hardware and software complex, meteorology, weather-informed, «Smart city», artificial intelligence.

### Введение

Интернет вещей (Internet of Things, IoT, ИВ) представляет собой объединенную сеть, к которой посредством коммуникационной и информационной инфраструктуры подключено множество объектов [1–2]. Сегодня на базе технологии ИВ разрабатывается множество инновационных решений, например концепция «Умный город» – интеграция традиционных коммуникационных технологий и ИВ для управления городским имуществом и сервисами с целью улучшения качества жизни горожан. Использование датчиков и сенсорных сетей позволяет осуществлять мониторинг в реальном времени и осуществлять своевременное реагирование и информирование жителей, по сути, речь идет о разработке системы поддержки принятия решений [3].

Искусственный интеллект (ИИ) – одна из самых быстрорастущих технологических тенденций, в настоящее время получает широкое распространение в системах «умного города». ИИ позволяет системам воспринимать окружающую среду и принимать меры, чтобы максимизировать шансы на успешное достижение поставленных целей, а также интерпретировать и анализировать данные таким образом, чтобы они обучались и адаптировались по мере развития [4]. Использование совокупности технологий ИВ и ИИ значительно улучшает качество работы любой системы, выводя ее на новый уровень.

Одно из актуальных направлений в «умном городе» – метеомониторинг, т. е. процесс сбора, обработки, анализа и интерпретации метеорологических данных [5–7] для наблюдения и прогнозирования погоды и климатических условий в определенной области. На основе технологии ИВ проектируется система автоматизированной метеостанции, которая должна обеспечивать возможность своевременного реагирования на изменения в погодных условиях за счет сбора данных с датчиков и предсказания погоды.

### Обзор возможных путей применения методов ИИ в метеорологии

Система автоматизированной метеостанции состоит из трех основных компонентов: аппаратного модуля (датчики и устройства), модуля прогнозирования и модуля визуализации и управления (мобильное приложение). Необходимо выбрать технологию для использования в модуле прогнозирования, который должен формировать предположения о будущем состоянии погоды в определенном месте на определенный период.

В современных системах для прогнозирования погоды активно используются различные методы ИИ, например нейронные сети, которые позволяют выполнять обработку данных по аналогии с одноименными сетями в человеческом мозге. Их основной плюс – отсутствие необходимости решения сложных физических уравнений и хранения огромных объемов информации [8].

Нейронные сети использует компания Google для быстрого предсказания погоды на ближайшие 8 часов. Алгоритм собирает некоторый архив данных, а затем нейросеть самостоятельно анализирует его и выделяет закономерности. Таким образом, вместо анализа огромного количества данных и генерации прогноза с нуля нейронная сеть находит в них паттерны, от которых можно отталкиваться, что позволяет получать быстрый прогноз погоды [9]. Алгоритмы машинного обучения применяет «Яндекс.Погода», используя систему Meteum. Нейросеть берет прогнозы, рассчитанные американской, канадской, японской и европейской моделями, и считает свой по модели WRF. Полученные результаты сверяются с реальными наблюдениями в нескольких точках, собранных по метеостанциям и спутникам. Далее нейросеть находит повторяющиеся закономерности и выдает прогноз «с точностью до дома» [10].

Поскольку нейросети обучаются на реальных наблюдениях, сверяя свои прогнозы с фактическими данными, система с течением времени улучшает свои прогнозы, накапливая опыт и адаптируясь к изменяющимся климатическим условиям. Однако часто пользователям и разработчикам может быть сложно понять, почему сеть сделала тот или иной прогноз, так как нейросеть может «переобучиться» на специфические условия, но так и не уметь корректно обобщать знания на новые или экстремальные условия, которые не были представлены в обучающих данных.

Еще один метод ИИ, который используется для прогнозирования погоды, – гибридные модели, сочетающие методы глубокого обучения и физические модели. Такие системы объединяют преимущества традиционных физических моделей, которые основываются на математических уравнениях, описывающих атмосферные процессы, с возможностями нейронных сетей и других методов машинного обучения. Гибридные модели могут использовать физическую модель для создания первичного прогноза, а затем корректировать его с помощью нейронной сети на основе реальных данных, таких как наблюдения с метеостанций и космических аппаратов. Это позволяет улучшить точность прогноза, особенно в нестандартных ситуациях, и одновременно обеспечивает лучшую интерпретируемость результатов. Однако сложности могут возникнуть при интеграции этих подходов, а также при необходимости синхронизации различных источников данных и моделей, что требует значительных вычислительных ресурсов. Компания The Weather Company использует гибридный подход для прогнозирования погоды. Они комбинируют мощные физические модели, такие как Global High-Resolution Atmospheric Forecasting (GRAF), с алгоритмами машинного обучения, что позволяет улучшать точность прогнозов и адаптировать их под конкретные географические регионы [11].

Чтобы принять решение о выборе метода ИИ для прогнозирования погоды на основе предоставленных данных, можно использовать метод «анализа по критериям». Он предполагает оценку каждого варианта по заранее определенным критериям, важным для задачи, и последующее сравнение этих оценок.

Для выбора метода были выделены следующие ключевые критерии: точность прогнозирования, скорость обработки данных, адаптивность к изменяющимся условиям, понимание работы алгоритма (интерпретируемость), обобщаемость, количество вычислительных ресурсов. После оценки критериев для каждого метода были получены следующие результаты: для нейронных сетей:  $4 + 5 + 3 + 2 + 3 + 4 = 21$ , для алгоритмов машинного обучения:  $5 + 4 + 5 + 3 + 4 + 2 = 23$ .

Таким образом, для решения задачи прогнозирования погоды более эффективно использовать гибридные модели, так как они имеют высокую способность адаптироваться к новым климатическим условиям, а их результаты более точны.

### Заключение

Был проведен обзор возможного применения технологий искусственного интеллекта в системе автоматизированной метеостанции. Для создания модуля «прогнозирование погоды» был выбран вариант использования гибридных моделей с помощью метода «анализа по критериям».

### Библиографический список

1. *Mostafa B.* Monitoring internet of things networks // 2019 IEEE 5th World Forum on Internet of Things (WF-IoT). 2019. P. 295–298.
2. *Колесник П. Д.* Перспективы Интернета вещей как инструмента цифровой экономики // Хроноэкономика. 2019. № 1(14). С. 53–58.
3. Методологические и методические основы создания и использования интегрированных систем поддержки принятия решений / А. В. Крылов, М. Ю. Охтилев, В. А. Соболевский [и др.] // Известия высших учебных заведений. Приборостроение. 2020. Т. 63, № 11. С. 963–974.
4. Что такое искусственный интеллект // SAP. URL: <https://www.sap.com/central-asia-caucasus/products/artificial-intelligence/what-is-artificial-intelligence.html> (дата обращения: 20.08.2024).
5. *Ушаков В. А.* Модели и алгоритмы управления информационными процессами при взаимодействии подвижных объектов // Морские интеллектуальные технологии. 2022. № 3-1(57). С. 235–247.
6. *Соколов Б. В., Ушаков В. А.* Модели и алгоритмы комплексного планирования информационных процессов при взаимодействии подвижных объектов // Региональная информатика (РИ-2022): матер. конф. (СПб., 26–28 окт. 2022 г.). СПб.: СПОИСУ, 2022. С. 53–54.
7. *Sokolov B., Ushakov V.* Model-Algorithmic Support for Abilities Calculating of Control System Based on Projection Operators // Advances in Intelligent Systems and Computing. 2019. Vol. 986. P. 342–348.
8. *Барсукова М. А., Пальмов С. В.* Методы искусственного интеллекта: краткий обзор // Форум молодых ученых. 2018. № 5/1(21). С. 412–416.
9. Метнет от Google: новый способ прогнозирования погоды // КОД. Журнал Яндекс практикума. URL: <https://thecode.media/metnet/> (дата обращения: 19.08.2024).
10. Как Яндекс использует ИИ для прогнозирования погоды // РБК Тренды. URL: <https://trends-rbc.ru/turbopages.org/trends.rbc.ru/s/trends/innovation/62fbb00c9a79476b8c626b15> (дата обращения: 22.08.2024).
11. Суперкомпьютерные технологии IBM помогут развивать метеорологию // Connect. URL: <https://www.connect-wit.ru/superkompyuternye-tehnologii-ibm-pomogut-the-weather-company-i-ucar-razvivat-meteorologiyu-na-baze-novoj-globalnoj-modeli.html> (дата обращения: 15.08.2024).

*В. Ф. Губайдулин\**

студент

*Ю. А. Скобцов\**

доктор технических наук, профессор

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ПРОЕКТИРОВАНИЕ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ ОТСЛЕЖИВАНИЯ ТРАНСПОРТНЫХ СРЕДСТВ НА ПРОИЗВОДСТВЕННОЙ ТЕРРИТОРИИ

Представлен концепт системы интеллектуального отслеживания транспортных средств на производственной территории с помощью сверточных нейронных сетей. Разработан алгоритм, обеспечивающий целостное отслеживание транспортных средств с нескольких камер, направленных на разные части территории, с помощью переиндексации отслеживаемых объектов на видеоизображении.

**Ключевые слова:** сверточные нейронные сети, многообъектное отслеживание.

*V. F. Gubaydulin\**

Student

*Yu. A. Skobtsov\**

Dr. Sc., Tech., Professor

\*St. Petersburg State University of Aerospace Instrumentation

## DESIGNING AN INTELLIGENT VEHICLE TRACKING SYSTEM ON THE PRODUCTION SITE

The concept of an intelligent vehicle tracking system in the production area using convolutional neural networks is presented. In particular, an algorithm is presented that provides holistic tracking of vehicles from several cameras aimed at different parts of the territory by reindexing tracked objects in the video image.

**Keywords:** convolutional neural networks, multi-object tracking.

### 1. Введение

Для управления и автоматизации складской деятельности существуют различные системы управления складским двором, или YMS. Они используются для диспетчеризации транспортных средств (ТС) с целью обеспечения контроля и безопасности на складской территории. Текущий статус и местоположение ТС определяется в результате различных взаимодействий с системой, например фотофиксация транспортного номера при въезде или считывание RFID-метки (Radio Frequency Identification, радиочастотная идентификация).

Данная статья посвящена постоянному отслеживанию объекта путем идентификации транспортных средств на видеоизображении и фиксации их координат для более быстрого поиска потенциально потерянной машины. В частности, решается проблема отслеживания перемещений транспортных средств с учетом нескольких одновременно работающих видеокамер, направленных на разные участки складской территории. Камеры расположены таким образом, что имеют совместные зоны наблюдения, и когда транспортное средство пересекает эти границы, можно утверждать, что оно переместилось с одной наблюдаемой зоны территории на другую.

### 2. Описание инструментов и структуры системы

При обнаружении транспортных средств применяется сверточная нейронная сеть YOLOv8 [1–3]. Для работы с видеоизображением использовалась библиотека OpenCV2 [4]. В качестве библиотеки трекинга употребляется библиотека многообъектного отслеживания ByteTrack, в качестве базы данных – SQLite. Разработанная система реализована на языке программирования Python.

Спроектирована UML-диаграмма классов, которая легла в основу схемы базы данных (рис. 1). Для минимальной работы системы необходимы три класса: камеры (cameras), отслеживаемые объекты (tracked\_objects\_aud) и ассоциативные границы (exit\_zones). Класс ассоциативных границ необходим для переиндексации объектов при переходе с одной камеры на другую.




Рис. 1. Диаграмма классов

### 3. Алгоритм переиндексации

Метод, ответственный за переиндексацию отслеживаемых объектов при переходе объекта с одной камеры на другую, вызывается на каждом обрабатываемом кадре для любого обнаруженного объекта после записи нового транспортного средства или актуализации данных старого в базе данных. Алгоритм переиндексации представлен псевдокодом А1.

Алгоритм А1

```
1 Procedure actualize_exit_zones_data
2 Ввод exit_area_rect – координаты выделяющей рамки ассоциативной границы
3 Ввод transport_rect – координаты выделяющей рамки транспортного средства
4 Ввод camera_id – идентификационный номер камеры, с которой пришел кадр
5 If exit_area_rect и transport_rect пересекаются then
6 Получение из БД текущего состояния модели ассоциативной границы из класса exit_zone
7 If значение tracked_objects_aud_id НЕ равно текущему транспортному средству then
8 Присвоение tracked_objects_aud_id значения id текущего транспортного средства
9 Присвоение флагу is_empty значения 0
10 End
11 End
12 Else if значение tracked_objects_aud_id для ассоциативной границы из класса exit_zone равно текущему транспортному средству then
13 Присвоение флагу is_empty значения 1
14 Получение пар id объектов и id ассоциативной границ, которые связаны, при условии, что связанная граница также имеет флаг is_empty равный 1
15 If такая пара ассоциативных границ существует then
16 Перезапись координат и камеры в более старой модели для tracked_objects_aud на актуальные, новый id удаляем из таблицы
17 Присвоение парам ассоциативной границы last_tracked_objects_aud NULL и флагу is_empty 1.
18 End
19 End
20 End actualize_exit_zones_data
```

Для апробации выбраны две видеозаписи, которые наблюдают за одной и той же парковкой в разное время суток. Но принята условность, что данные видеоизображения объединены одной ассоциативной границей. Для первой видеозаписи данная граница находится слева, по направлению проезда автомобиля и дальнейшего выхода за границу. Для второй записи граница находится справа, и в первые секунды в нее въезжает другой автомобиль. Несмотря на то, что это разные машины, для тестирования было принято решение опустить данный факт. Таким образом, имеем сценарий, где автомобиль выезжает за границы видимости одной камеры и въезжает в границы видимости другой. На рис. 2, 3 кадр первой записи будет находиться справа (б), а кадр второй записи – слева (а).

На рис. 2 представлен пример работы системы до внедрения алгоритма переиндексации. Автомобиль с индексом 1 выезжает за кадр, и после прохождения через ассоциативную границу второй камеры не изменяет своего индекса, для системы это разные автомобили.

а)



б)



Рис. 2. Работа системы отслеживания до внедрения алгоритма переиндексации

На рис. 3 показан пример работы системы после внедрения алгоритма переиндексации. Автомобиль с индексом 1 выезжает за кадр, и после прохождения через ассоциативную границу второй камеры изменяет свой индекс, теперь для системы это один и тот же автомобиль.



Рис. 3. Работа системы отслеживания после внедрения алгоритма переиндексации

#### 4. Заключение

Реализован и протестирован концепт системы интеллектуального отслеживания транспортных средств на производственной территории с помощью сверточных нейронных сетей и алгоритма переиндексации объектов. Данный концепт может быть включен в комплексную систему YMS как один из модулей для более комплексной диспетчеризации.

#### Библиографический список

1. Николенко С., Кадулин А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. СПб.: Питер, 2022. 480 с.
2. You Only Look Once: Unified, Real-Time Object Detection / J. Redmon, S. Divvala, R. Girshick, A. Farhadi // IEEE Conference on Computer Vision and Pattern Recognition. 2016. P. 10.
3. Прохоренко Н. OpenCV и Java. Обработка изображений и компьютерное зрение. СПб.: БХВ-Петербург, 2018. 320 с.
4. ByteTrack: Multi-Object Tracking by Associating Every Detection Box / Yifu Zhang, Peize Sun, Yi Jiang [et al.] // Proceedings of the European Conference on Computer Vision (ECCV). 2022. P. 1–21.

*Т. А. Киргизбоев\**

магистрант

*Х. Б. Мирзокулов\**

кандидат физико-математических наук – научный руководитель

\*Самаркандский филиал Ташкентского университета информационных технологий им. Мухаммада аль-Хоразми, Узбекистан

## ИСПОЛЬЗОВАНИЕ ТЕХНОЛОГИИ РАДИОЧАСТОТНОЙ ИДЕНТИФИКАЦИИ ДЛЯ МОНИТОРИНГА СКОРОСТИ ДВИЖЕНИЯ АВТОМОБИЛЕЙ

Рассматриваются разработка и исследование новой системы контроля скорости транспортного средства с использованием современной технологии радиочастотной идентификации. Разработаны практические решения по контролю скорости транспортных средств с использованием встроенных элементов системы. Рассмотрены преимущества системы контроля скорости транспортных средств на основе технологии RFID, и проведен ее сравнительный анализ с другими системами определения скорости транспортных средств. Создан прототип реальной модели на базе микроконтроллера Arduino, возможности которого оценивались в ходе эксперимента.

**Ключевые слова:** радар, дистанционное управление, умный город, радиочастотная идентификация.

*T. A. Kirgizboyev\**

Postgraduate Student

*Kh. B. Mirzokulov\**

PhD, Phys.-Math. – Scientific Adviser

\*Samarkand Branch of Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Uzbekistan

## VEHICLE SPEED MONITORING SYSTEM BASED ON RFID TECHNOLOGY

In this paper, discusses the development and research of a new vehicle speed control system using modern radio frequency identification technology. Practical solutions have been developed to control the speed of vehicles using built-in system elements. The advantages of a vehicle speed monitoring system based on RFID technology and its comparative analysis with other vehicle speed detection systems are carried out. A prototype of a real model was created based on the Arduino microcontroller and its capabilities were evaluated during the experiment.

**Keywords:** radar, remote control, smart city, RFID.

В настоящее время контроль скорости движения транспортных средств – один из основных и первостепенных факторов обеспечения безопасности дорожного движения. Обеспечение безопасности дорожного движения с использованием современных информационно-коммуникационных технологий, в частности создание, разработка и внедрение технического и программного комплекса системы контроля скорости движения транспортных средств с использованием современных информационных технологий, приобретает актуальное значение во всем мире [1–3].

В настоящее время научные исследования ряда ученых в нашей республике и в зарубежных странах направлены на изучение и исследование этих вопросов. В частности, для обеспечения безопасного и надежного движения по всем автомобильным дорогам необходимо широкое внедрение информационно-коммуникационных технологий в области безопасной организации дорожного движения и расчета транспортных потоков на магистралях, предотвращения заторов и поиска транспортных средств. В настоящее время разрабатываются предложения по внедрению системы на основе меток RFID (технология радиочастотной идентификации) (далее – система RFID), позволяющей дистанционно передавать информацию о направлении движения транспортных средств [1].

На сегодняшний день существует несколько основных технологий определения скорости транспортных средств. Первая популярная из них – доплеровская пушка, которая представляет собой устройство для определения скорости транспортного средства, позволяющее сотрудникам дорожной полиции определять скорость автомобиля на основе эффекта Доплера [2].

Использование радарной технологии, основанной на эффекте Доплера, имеет ряд недостатков. В частности, доплеровская пушка может одновременно идентифицировать только один автомобиль. Это может затруднить определение превышения скорости при движении нескольких автомобилей бок о бок, что в большинстве случаев оправдано тем, что полицейские останавливают ближайший к ним автомобиль. Другая проблема заключается в том, что при движении двух автомобилей подряд можно определить скорость только одного из них, и в этом случае второй автомобиль, скорее всего, не будет оштрафован, поскольку он не идентифицирован.

Еще одной технологией, используемой при разработке систем определения скорости транспортных средств, является технология распознавания автомобильных номеров (VLPR), которая позволяет обнаруживать

автомобили на контролируемых дорогах с помощью видеокамер и автоматически извлекать данные о номерных знаках для обработки. Технология VLPR позволяет извлекать и идентифицировать номерной знак из изображения с помощью обработки изображений, извлечения текста из изображения и других технологий. Системы на базе искусственного интеллекта могут контролировать парковочные места, измерять интенсивность движения, определять местоположение транспортных средств, распознавать автомобили, проезжающие на красный свет, организовывать мониторинг на платных дорогах на автомагистралях, контролировать скорость движения транспортных средств. В этом случае номер автомобиля является единственным «идентификатором» транспортного средства [3–4].

Данное решение по контролю скорости транспортных средств на основе VLPR требует установки большого количества камер видеонаблюдения для контроля скорости транспортных средств. Одним из основных недостатков этой технологии является то, что камеры видеонаблюдения не могут идентифицировать номерные знаки в плохих погодных условиях. Кроме того, эта система требует мощных центров обработки данных для предварительной обработки видео. Для обработки изображений существует большое количество избыточных видеоданных. Чем больше данных нужно обработать, тем больше времени требуется на обработку изображения.

В предлагаемом нами методе скорость автомобиля определяется на основе средней скорости между двумя точками. Архитектура системы состоит из четырех уровней, которые взаимодействуют друг с другом по вертикали. Это позволяет читателю понять, как работает система. Микрокомпьютер является центральным элементом системы, который управляет двумя RFID-считывателями, двумя микроконтроллерами и GSM-модемом, как показано на рис. 1 [4–6].

Два RFID-считывателя [7–8] сканируют метку, а микроконтроллеры собирают данные с RFID-считывателей. Отсчет времени начинается, когда автомобиль проходит через считыватель RFID в начале зоны, и заканчивается, когда автомобиль проходит через считыватель RFID в конце зоны. Рассчитывается разница во времени, за которое автомобиль должен проехать мимо двух студентов подряд. Скорость автомобиля рассчитывается с учетом разницы во времени и ранее сохраненного постоянного расстояния. Затем рассчитанная скорость сравнивается с ранее сохраненной скоростью. Результат сравнения и информация о RFID-метке отправляется в базу данных с помощью GSM-модуля (см. рис. 1).

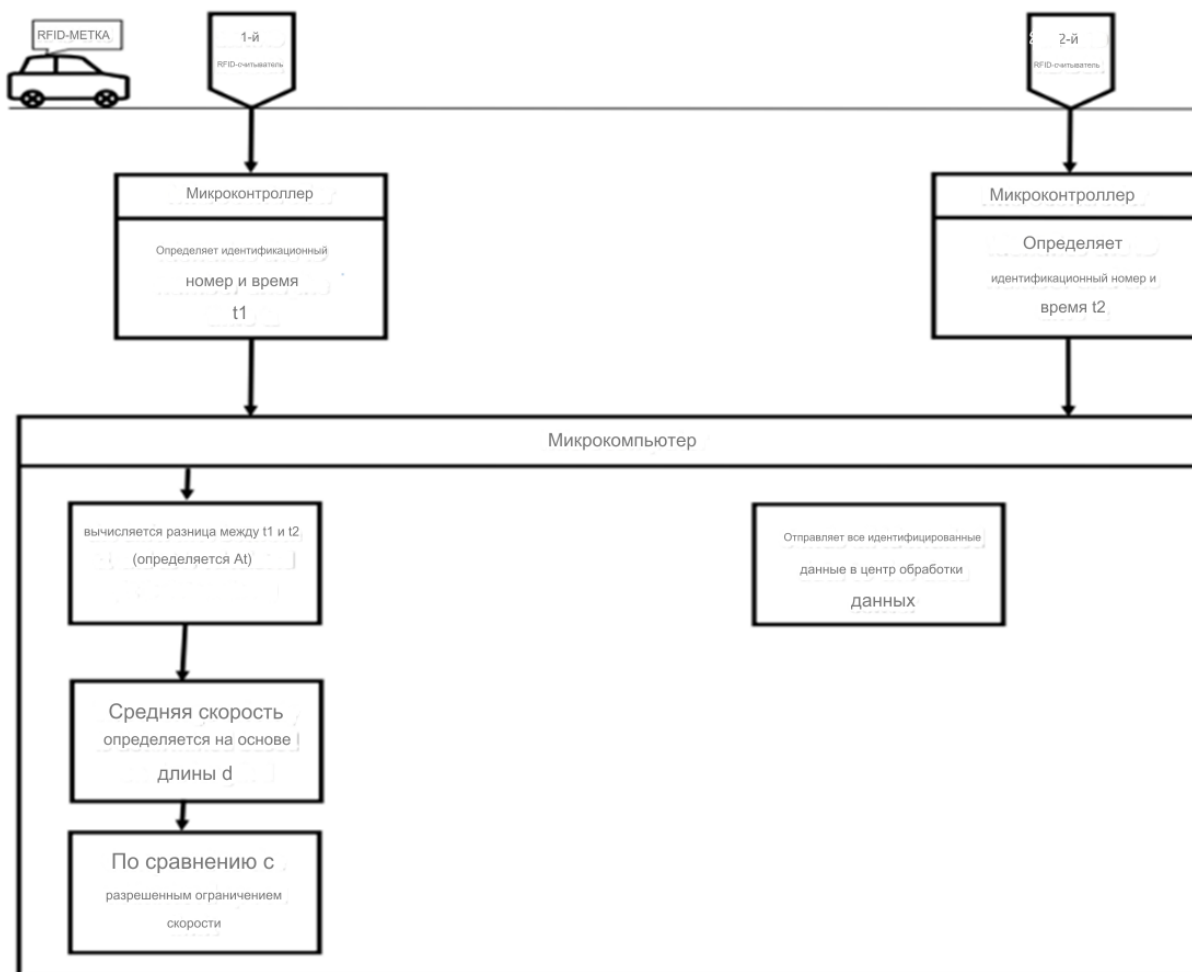


Рис. 1. Алгоритм работы системы



Интеграция GSM-модуля играет ключевую роль в передаче данных, позволяя системе отправлять информацию по беспроводной связи в централизованную базу данных. Эта база данных не только регистрирует информацию RFID-метки и рассчитанную скорость, но и результаты сравнения с предварительно сохраненными ограничениями скорости или историческими данными. Такая система обеспечивает непрерывный мониторинг и анализ, позволяя незамедлительно реагировать на любые отклонения, например превышение скорости. Кроме того, сохраненные данные можно использовать для составления отчетов, выявления закономерностей и принятия обоснованных решений по улучшению организации дорожного движения и повышению безопасности. Используя эту технологию, власти могут повысить безопасность дорожного движения и обеспечить соблюдение скоростного режима, что в итоге способствует созданию более безопасной среды как для пешеходов, так и для водителей.

Разделив архитектуру системы на следующие четыре уровня: физический, каналный, сетевой и прикладной, можно ограничить область поиска для более быстрого обнаружения возможных неисправностей и их устранения [9–13].

Физический уровень является самым низким и в основном связан с размещением оборудования. Эффективность системы проверяется путем размещения оборудования UHF. Все запрограммированные считыватели обмениваются данными с центральной системой через систему беспроводной связи. К областям тестирования относится определение скорости считывания между считывателем и бортовой меткой. Этот параметр должен соответствовать параметрам скорости дороги и транспортного средства.

Ширина дорог позволяет двум или более полосам транспортных средств двигаться в одном направлении одновременно. На двухполосных шоссе ширина каждой полосы составляет 3,7 м. На автомагистралях бетонные барьеры, разделяющие направления движения или полосы определенной ширины, озеленяются. Кроме того, по краям автомагистралей расположены полосы шириной 3 м, называемые обочинами (рис. 2).




Рис. 2. Установка устройств на двухполосной дороге

Чтобы определить скорость транспортных средств с помощью RFID-детекторов, необходимо определить, где на дороге будет установлен RFID-считыватель и как он будет работать. Наиболее оптимальна установка антенны RFID-считывателя на обочине дороги. В этом случае, когда ширина шоссе равна  $l$ , а количество полос —  $n$ , зона считывания антенны ( $d$ ) выражается следующим образом:

$$d = nl. \quad (1)$$

Следовательно, для двухполосных магистралей  $d = 7,4$  м подходит следующий вариант.

Для идентификации автомобилей в одном направлении нам необходим RFID-считыватель с рабочим радиусом 8 м. Для его улучшения мы можем использовать различные типы патч-антенн [14]. RFID-считыватели делятся на два типа: мобильные и стационарные.

Мобильные RFID-считыватели предназначены для ношения с собой, как сотовый телефон. Поэтому они легкие и питаются от батарей. Они оснащены функциями, которые включают и выключают их при необходимости. Мобильные RFID-считыватели передают собранные данные на компьютеры со встроенной памятью или в базу данных, установленную на определенном расстоянии, с помощью беспроводных систем передачи данных.

Стационарные RFID-считыватели устанавливаются в фиксированном месте. Они предназначены для непрерывной работы. То есть их не нужно выключать и включать. Это избавляет человека от необходимости сканировать RFID-метку при каждом ее появлении. Эта функция помогает автоматизировать устанавливаемую систему. Стационарные RFID-считыватели можно заряжать по выбору: от аккумулятора или прокладывая электрические кабели и используя обычную электроэнергию. Кроме того, стационарные RFID-считыватели обеспечивают возможность передачи информации о просканированных RFID-метках как с помощью беспроводных систем связи, так и с помощью встроенных проводных систем связи.

Прототип системы (рис. 3) был разработан на базе микроконтроллера Arduino, в дополнение к которому были установлены RFID-считыватели для идентификации RFID-метки, установленной на автомобиле. На основе полученных данных определяется средняя скорость и выводится на ЖК-дисплей. При проведении экспериментов соблюдается строгий контроль отсутствия бриллюэновского рассеяния в момент взаимодействия излучения накачки с исследуемой средой, т. е. исследования проводятся в предпороговом режиме бриллюэновского рассеяния. Однако можно утверждать, что в этом случае в среде существует гиперзвуковая решетка, хотя бриллюэновское рассеяние прибором не регистрируется.




Рис. 3. Физическая структура прототипа системы

Система представляет собой небольшой прототип реальной модели. В реальной модели вместо микроконтроллера Arduino установлен центр обработки данных и высокопроизводительные компьютеры, а считыватель RFID и знаки увеличенного радиуса действия заменены.




Рис. 4. Принцип работы модели реальной системы

В результате проекта был создан прототип рабочей системы (рис. 4). В этой прототипной системе два RFID-считывателя могут сканировать автомобиль каждый раз, когда он проезжает мимо них. Когда транспортное средство проходит через стартовую зону отслеживания RFID-считывателя, в системе запускается таймер, а когда транспортное средство проходит через стоп-зону отслеживания RFID-считывателя, таймер подсчитывает пройденное расстояние. Средняя скорость автомобиля на этом расстоянии определяется расстоянием между двумя считывателями RFID и временем, необходимым для его преодоления. Полный прототип системы сравнивает среднюю скорость автомобиля с установленным ограничением скорости. При нарушении установленного ограничения скорости водителю через GSM-модуль отправляется текстовое сообщение о нарушении скорости.

В данной статье на основе имеющейся литературы и статей проведен анализ систем и технологий, используемых при контроле скорости движения транспортных средств, проанализирована каждая из них, изучены принципы их работы, выявлены основные недостатки. Изучены предлагаемые современные технологии автоматической идентификации для решения этих задач, проведен их сравнительный анализ и представлены результаты. Технология RFID – это инновация в других технологиях автоматической идентификации и сбора данных, которая обеспечивает ряд преимуществ по сравнению с более ранними технологиями, такими как оптическое сканирование штрих-кода. Эти преимущества обусловлены способностью обнаруживать объекты на расстоянии и обеспечивать надежное покрытие как внутри, так и снаружи здания.

Проведено исследование областей применения принципов технологии радиочастотной идентификации (RFID) и анализ имеющихся возможностей. Изучены преимущества и недостатки технологии RFID. Разработана модель системы контроля скорости автомобиля на основе RFID-меток и оценены ее возможности. Практические эксперименты, проведенные на основе прототипа, показали высокую эффективность и точность этой системы. Перед созданием реальной модели необходимо выбрать активные RFID-метки и спроектировать центры обработки данных.

### Библиографический список

1. Radio Frequency Identification (RFID) for Sensing / F. Costa, S. Genovesi, M. Borgese [et al.] // Encyclopedia of Sensors and Biosensors. 1st ed. Elsevier, 2023. P. 375–390.
2. Self-mixing rotational Doppler effect for spinning velocity detection / Song Qiu, Tong Liu, Zhengliang Liu [et al.] // Optics & Laser Technology. 2024. Vol. 174. P. 110721.
3. License plate recognition system / M. J. Ahmed, M. Sarfraz, A. Zidouri, W. G. Al-Khatib // 10th IEEE International Conference on Electronics, Circuits and Systems. 2003. Vol. 3.
4. *Alexandrov Ch. I.* Radar imaging and radar image processing // 7th International PhD Seminar on Computational electromagnetics and bioeffects of electromagnetic fields, CEMBEF, August 28–31 2013, Niš, Serbia.
5. *Hill J.* Automatic Identification and Data Collection: Scanning into the Future // Journal ASCET. 2000. Vol. 2. P. 269–272.
6. Guidelines for Securing Radio Frequency Identification (RFID) Systems / T. Karygiannis, B. Eydt, G. Barber [et al.] // Computer Security Division Information Technology Laboratory National Institute of Standards and Technology Gaithersburg, MD 20899-8930. 2007.
7. *Mas'od K. I., Abdul Ghafar N. R.* Development of Vehicle Speed Measurement Using RFID // Journal of Engineering Technology. 2021. Vol. 90. P. 108–111.
8. Speed Measurement of a Moving Object by Using a RFID Location System and Active Transponders / C. Eugen, V. Popa, G. Vasile [et al.] // Electronics and Electrical Engineering. 2008. Vol. 8(88). P. 63–66.
9. *Hafeez F., Shammrani M. A., Shammmary O. A.* Smart Vehicles Speed Monitoring System Using RFID // International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering. 2015. Vol. 4(4). P. 1860–1864.
10. *John R.* Tuttle, US 10650200B2 (May 2020).
11. P. Kyung Hwan, K. Tae Young, H. Seok Bong, K. Sung Weon, C. Byoung Gun, L. In Gi, K. Kyung Soo, K. Jung Bum, US 8274371B2 (September 2012).
12. Vehicle speed detection using RFID tags / O. Bhosale, S. More, V. Mule, S. Karande // Journal of Analysis and Computation (JAC). 2019. Vol. 12(1).
13. IOT Based Vehicle Speed Control Automatically in Restricted Areas using RFID / K. Satyanarayana, G. Yaswanthini, L. Kartheeka, N. Rajkumar // International Journal of Engineering & Technology. 2018. Vol. 7(3.31).
14. Printed Antenna for Signal Analysis in the UHF Band / A. Olmasov, K. Mirzokulov, B. Djaniyev, N. Mardiyev // 2022 International Conference on Information Science and Communications Technologies, ICISCT 2022.
15. Traffic Violation Detection System based on RFID / S. Hajeb, M. Javadi, S. M. Hashemi, P. Parvizi // Journal of Mechanical, Aerospace, Industrial, Mechatronic and Manufacturing Engineering. 2013. Vol. 7(2).

*С. И. Колесникова\**

доктор технических наук, доцент

*В. А. Васильев\**

магистрант

*Д. Р. Алешина\**

магистрант

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## СРАВНЕНИЕ ЭФФЕКТИВНОСТИ УПРАВЛЕНИЙ МАНИПУЛЯТОРОМ С НЕИЗВЕСТНОЙ МАССОЙ ЗВЕНА

Представлено исследование эффективности управления роботом-манипулятором в условиях возмущений на основе разных подходов. Основным результатом заключается в сравнении аналитически сконструированных регуляторов – релейного и синергетического, и «нестрогих» регуляторов – жадного и нейросетевого. Рассмотрен в качестве тестового примера трехзвенный манипулятор с неопределенностью в виде неизвестной массы третьего звена.

**Ключевые слова:** робот-манипулятор, модели управления роботом-манипулятором, показатели качества управления, релейное управление, синергетическое управление, нейросетевое управление, возмущение случайное и систематическое.

*S. I. Kolesnikova\**

Dr. Sc., Tech., Associate Professor

*V. A. Vasiliev\**

Postgraduate Student

*D. R. Aleshina\**

Postgraduate Student

\*St. Petersburg State University of Aerospace Instrumentation

## NUMERICAL COMPARISON OF THE QUALITY OF RELAY AND SYNERGETIC ROBOT MANIPULATOR CONTROLS

A study of the effectiveness of two different methods of manipulator robot control is presented: relay and synergetic. A comparative analysis of these methods is performed using numerical models and experiments.

**Keywords:** manipulator robot, manipulator robot control models, control quality indicators, relay control, synergetic control, random and systematic disturbance.

### Введение

Под манипуляторами понимают робототехнические системы, специально разработанные для выполнения задач манипулирования объектами или материалами. Число публикаций на тему управления различными типами подвижных роботов или манипуляционных систем (экскаваторы, погрузчики, бурильные установки и пр.) стремительно растет [1–15]. Однако не вполне решенной проблемой остается выполнение функций роботом в условиях, препятствующих получению полной информации о его координатах и параметрах.

Классифицировать все системы управления (с точки зрения методов их построения) такими объектами непросто в силу принципиально разных решаемых ими задач, характера и уровня неопределенности условий, в которых целевые задачи решаются.

Теоретические вопросы управления подобными устройствами достаточно подробно изложены в [1–6]. В работах В. И. Матюхина (например, [1]) для управления роботами предложено использовать так называемые скользящие режимы [16] с высокой вычислительной трудоемкостью и нежелательным явлением chattering, обусловленным запаздыванием переключающих устройств.

Алгоритм синергетического метода конструирования агрегированных регуляторов из [17] применительно к управлению движением центра масс подвижного объекта, описанным в виде системы дифференциальных и/или разностных уравнений, является аналитически обоснованным и обеспечивает робастность системе управления при определенных условиях. В [18] данный алгоритм распространен на случай наличия возмущений в условиях как систематических, так и случайных помех. В [19] получен новый алгоритм построения кусочно-постоянного управления (названного релейным), апробированный на трехзвенном манипуляторе с неизвестной массой третьего звена. Цель настоящей работы – провести численное сравнительное исследование качества и эффективности регуляторов, аналитически сконструированных и полученных на основе алгоритмов машинного обучения. В качестве тестового объекта взят трехзвенный манипулятор (без ограничения общности).

Кратко остановимся на принципиальных моментах каждого из сравниваемых подходов относительно «преодоления» неопределенности в виде неизвестного груза последнего звена.

## Постановка задачи управления

Детальная схема тестового объекта с неизвестным грузом, сопоставленным третьему звену, приведена на рис. 1.




Рис. 1. Детальная классическая схема робота-манипулятора

Особенность построенных регуляторов состоит в учете возмущения в модели управления (неизвестная масса звена). Рассмотрены для сравнения четыре алгоритма управления: синергетический, релейный, жадный и нейросетевой.

**Основание релейного адаптивного управления – кинематические соотношения и принцип адаптации**  
Введем обозначения

$$\Phi^T = (\alpha, \beta, \gamma)^T, \quad \mathbf{z}^T = (x_1, x_2, x_3, y_1, y_2, y_3)^T, \\ \ddot{\phi}_i = u_i, \quad i = 1, 2, 3,$$

$\mathbf{u} \in R^3$  – вектор управления,  $\mathbf{l} \in R^3$  – вектор длин звеньев,  $(\alpha, \beta, \gamma)$  – углы между звеньями,  $(x_1, x_2, x_3, y_1, y_2, y_3)$  – координаты точек  $A(x_1, y_1)$ ,  $B(x_2, y_2)$ ,  $C(x_3, y_3)$ .

*Замечание.* Подробный вывод релейного регулятора на основе кинематических соотношений и структуры адаптивного регулятора имеется в [19].

Используются уравнения вращательного движения звеньев вокруг точек 0, A и B (см. рис. 1) (при отсутствии неопределенностей):

$$\mathbf{J}(\mathbf{z})\ddot{\boldsymbol{\phi}} = \mathbf{M} - \mathbf{R}(\mathbf{z}), \quad \mathbf{M}, \mathbf{J}, \mathbf{u}, \mathbf{R} \in R^3, \quad (1)$$

где  $\mathbf{M}, \mathbf{J}, \mathbf{R}$  – вектор управляющих моментов, моментов инерции и весовых моментов (произведение веса тела на плечо или проекцию центра тяжести звена на ось  $0X$ ), соответственно.




Рис. 2. Блок-схема адаптивного управления: на входе – управление, ведущее к отклонению звена на угол  $\phi$  с ожидаемым значением  $\phi^*$ ; на выходе  $\Delta\phi$ , влияющее на корректировку  $\Delta u$

На основе принципа адаптивного регулирования (рис. 2) и предположения, что неизвестная масса  $m_4$  груза (связанная с 3-м звеном) представима в виде  $m_4 = qm_0$ , где  $m_0$  – максимальная масса грунта, которую может зачерпнуть ковш,  $q$  – неизвестная константа, лежащая в интервале  $0 \leq q \leq 1$ , а также доступности измерению всех координат  $\mathbf{z}(t)$ , величины  $\mathbf{J}(\mathbf{z})$ ,  $\mathbf{R}(\mathbf{z})$  и  $\Delta\mathbf{J}(\mathbf{z})$ ,  $\Delta\mathbf{R}(\mathbf{z})$  (обусловленные возмущением) могут быть найдены [19] и в данных неполно определенных условиях. Тогда

$$(\mathbf{J}(\mathbf{z}) + q\Delta\mathbf{J}(\mathbf{z}))\ddot{\boldsymbol{\phi}} = \mathbf{M} - \mathbf{R}(\mathbf{z}) - q\Delta\mathbf{R}(\mathbf{z}), \quad \mathbf{M}, \mathbf{J}, \mathbf{u}, \mathbf{R} \in R^3, \quad (2)$$

или покоординатно:

$$\ddot{\phi}_i = \frac{M_i - R_i(\mathbf{z}) - q\Delta R_i(\mathbf{z})}{(J_i(\mathbf{z}) + q\Delta J_i(\mathbf{z}))}, \quad i=1,2,3. \quad (3)$$

Заметим, что при  $q = 0$  (2) переходит в (1). В итоге получаем формулы для регулятора в условиях неопределенности. Согласно схеме на рис. 2, сначала находится программное управление  $\mathbf{u}(t)$  для задачи вполне определенной, затем  $\Delta \mathbf{u}(t)$  по формулам из [19].

### Основание синергетического управления – вариационный принцип

Поведение объекта, допускающего неопределенность в описании трехзвенного манипулятора, основано на классической хорошо известной системе [1]:

$$\mathbf{m}\ddot{\mathbf{b}}(t) = \mathbf{q}(\mathbf{b}(t), \dot{\mathbf{b}}(t)) + \mathbf{u}(t) + \boldsymbol{\zeta}(t), \quad t \geq 0, \quad (4)$$

где  $\mathbf{b} \in R^3$ ,  $\mathbf{b}(t) = (b_1(t), b_2(t), b_3(t))^T$  – вектор состояния;  $\mathbf{q} = q(\mathbf{b}, \dot{\mathbf{b}}) \in R^3$  – обобщенные силы, действующие на объект;  $\mathbf{m} = \|m_{ij}\|_{3 \times 3}$  – матрица кинетической энергии;  $\mathbf{u}, \boldsymbol{\zeta} \in R^3$  – векторы управления и аддитивного возмущения соответственно.

Согласно основному методу синергетической теории управления – методу аналитического конструирования агрегированных регуляторов и его расширению на случай возмущения по каналу управления – методу интегральной адаптации, определяется закон управления, переводящий изображающую точку из произвольного начального состояния в расширенном фазовом пространстве системы на многообразии  $\boldsymbol{\Psi}(\mathbf{x}(t)) = \mathbf{x}_1(t) - \mathbf{x}^*$ . Функция  $\boldsymbol{\Psi}(\mathbf{x})$  есть целевая макропеременная  $\mathbf{x}^*$  – заданное значение. Связь с системой (4) осуществляется заменой  $\mathbf{x}_1(t) = \mathbf{b}(t)$ ,  $\mathbf{x}_2(t) = \dot{\mathbf{b}}(t)$ .

Для тестового простого примера система управления в скалярном виде примет вид [20]

$$\begin{aligned} \dot{x}_{1i}(t) &= x_{2i}(t), \quad \dot{x}_{2i}(t) = (aq)_i + (au)_i + z_i, \\ \dot{z}_i(t) &= \eta \psi_i^*, \quad \eta > 0, \quad (au)_i = -\omega_1^{-1} \psi_i^{(0)} - (aq)_i + \frac{\partial \varphi_i}{\partial x_{1i}} x_{2i} + \eta \frac{\partial \varphi_i}{\partial z_i} \psi_i^*, \\ \varphi_i &= -\omega_2^{-1} (\psi_i^* + k \hat{z}_i(t)) - k \eta \psi_i^*, \quad k > 0, \quad \frac{\partial \varphi}{\partial x_{1i}} = -(\omega_2^{-1} + k \eta), \quad \frac{\partial \varphi_i}{\partial \hat{z}_i} = -\omega_2^{-1} k, \\ \psi_i^* &= x_{1i}(t) - b_i^*, \quad \psi_i^{(0)} = x_{2i} - \dot{\varphi}_i(x_{1i}, \hat{z}_i), \quad \psi_i^{(0)} = \psi_i^*(x) + k \cdot \hat{z}_i, \quad \omega_i > 0, \quad i = 1, 2, 3. \end{aligned} \quad (5)$$

Все постоянные в (5) – параметры регулятора.

### Управление манипулятором на основе алгоритмов машинного обучения

Используемые алгоритмы – жадный и нейросетевой – имеют основой кинематику процесса, выраженную формулами (2), (3). Рассматривается упрощенная схема манипулятора (рис. 3).




Рис. 3. Упрощенная схема робота-манипулятора

Звеньям  $A_{i-1}A_i$  и их центрам тяжести  $a_i$  сопоставлены соотношения

$$\overrightarrow{A_{i-1}A_i} = \begin{pmatrix} l_i * \cos \alpha_i \\ l_i * \sin \alpha_i \end{pmatrix}, \quad \overrightarrow{A_0A_i} = \sum_{j=1}^i \overrightarrow{A_{j-1}A_j},$$

$$\overrightarrow{A_0a_i} = k_i * \overrightarrow{A_{i-1}A_i} + \sum_{j=1}^{i-1} \overrightarrow{A_{j-1}A_j}, \quad \overrightarrow{A_0b} = k_b * \overrightarrow{A_{n-1}A_n} + \sum_{j=1}^{n-1} \overrightarrow{A_{j-1}A_j}.$$

где коэффициент  $k_i$  равен отношению  $\frac{|\overrightarrow{A_{i-1}a_i}|}{|\overrightarrow{A_{i-1}A_i}|}$ , что позволяет корректно обрабатывать случаи, когда звенья манипулятора неоднородны. В этом случае задачи управления ставятся следующим образом.

### Постановка задачи управления на основе жадного алгоритма

В каждый момент времени работы алгоритма найти такие управляющие моменты  $M_i$ , при которых система

$$\ddot{\alpha}_i = \frac{M_i - (R_i(z) + \Delta R_i(z))}{J_i(z) + \Delta J_i(z)}$$

из начального неподвижного состояния  $\alpha_i(0)=0, \dot{\alpha}_i(0)=0$  переходит в другое неподвижное состояние  $\overrightarrow{A_0A_n} = \overrightarrow{A_0A_k}, \dot{\alpha}_i(t_k) = 0$  или в его некоторую окрестность, минимизируя функцию потерь:

$$loss = \begin{cases} |\overrightarrow{A_0A_k} - \overrightarrow{A_0A_n}|^2, & \text{при } \dot{\alpha}_i < q * \ddot{\alpha}_{max} * \Delta t \\ |\overrightarrow{A_0A_k} - \overrightarrow{A_0A_n}|^2 + \frac{\left(\frac{\sum_{i=1}^n l_i}{3}\right)^3 * \sum_{i=1}^n \left|\frac{\dot{\alpha}_i}{\ddot{\alpha}_{max} * \Delta t}\right|}{|\overrightarrow{A_0A_k} - \overrightarrow{A_0A_n}| + \frac{\sum_{i=1}^n l_i}{3}}, & \text{при } \dot{\alpha}_i \geq q * \ddot{\alpha}_{max} * \Delta t \end{cases},$$

где  $\ddot{\alpha}_{max}$  – максимальное управление, которое подается на  $i$ -е звено манипулятора,  $q - const$ .

### Постановка задачи управления на основе нейросетевого алгоритма

Пусть имеются множества векторов  $X \subset \mathbb{R}^m, Y \subset \mathbb{R}^n$ . Требуется найти отображение  $f: X \rightarrow Y$ , такое, что если  $X_j$  – вектор, описывающий состояние манипулятора в момент времени  $t_j$ , то  $Y_j$  – вектор, соответствующий управляющим моментам  $M_i$ , при которых система

$$\ddot{\alpha}_i = \frac{M_i - (R_i(z) + \Delta R_i(z))}{J_i(z) + \Delta J_i(z)}$$

из начального неподвижного состояния  $\alpha_i(0)=0, \dot{\alpha}_i(0)=0$  переходит в другое неподвижное состояние  $\overrightarrow{A_0A_n} = \overrightarrow{A_0A_k}, \dot{\alpha}_i(t_k) = 0$  или в его некоторую окрестность, где  $\overrightarrow{A_0A_n}, \overrightarrow{A_0A_k}$  – векторы, сопоставленные последнему звену манипулятора и целевой точке соответственно.

### Результаты сравнительного моделирования четырех алгоритмов управления

**Результаты сравнения релейного и синергетического управлений в условиях случайных возмущений.** В табл. 1 приводится сравнительная характеристика релейного и синергетического управления с учетом возмущений.

В следующем разделе представлены графики моделирования управления роботом-манипулятором с учетом шума (шум к управлению), где  $\mathbf{x}_1 = (1.04; 1.571; 2.094)$  – углы робота в начальный момент;  $\mathbf{x}_2 = (0; 0; 0)$  – скорости в начальный момент;  $\mathbf{x}_z = (0.774; 1.238; 2.013)$  – целевой вектор.

Генерируется равномерно распределенный шум  $z$  с параметрами  $a = -1$  и  $b = 1$ .

На рис. 4 изображены соответствующие графики зависимостей  $x_1$  от времени релейного и синергетического управления с учетом шума.

а)







Рис. 4. Графики зависимостей: а – управляемых координат, б, в – управлений синергетического и релейного соответственно под воздействием равномерного шума

Таблица 1

Сравнение релейного и синергетического управлений с учетом возмущений

Показатели качества	Релейное управление	Синергетическое управление, усл. ед.
Величина перерегулирования	34.366 925	34.366 925
Время переходного процесса	0.064	0.084
Колебательность	1	4
Энергия, затрачиваемая на управление	43	37



**Результаты сравнения релейного жадного и нейросетевого управлений.** Параметры полагались равными:  $l_1 = 5\text{ м}, l_2 = 3\text{ м}, l_3 = 2\text{ м}, m_1 = 50\text{ кг}, m_2 = 30\text{ кг}, m_3 = 20\text{ кг}$  [21].




Рис. 5. Траектория изменения положения трехзвенного манипулятора

В табл. 2 приведены данные численного сравнительного моделирования для случая *а* на рис. 5. Из таблицы следует, что релейный алгоритм не справляется с большой массой груза, быстрее нейросетевого достигает цели там, где он работоспособен и имеет большие энергозатраты.

Таблица 2

**Сравнение релейного с жадным и нейросетевым управлением**

Масса груза 3-го звена, кг	Релейное управление		Жадный алгоритм		Нейросетевой алгоритм	
	$t_k$ , с	Энергия, Дж	$t_k$ , с	Энергия, Дж	$t_k$ , с	Энергия, Дж
0	4	1257.877	20	4263.939	6	1168.296
1	5	1308.382	4	1422.646	6	1222.548
5	–	–	19	8491.353	14	7521.141
10	–	–	50	24 993.045	40	23 496.441
11	–	–	–	–	41	27 915.314
11.25	–	–	–	–	48	30 158.662

Жадный алгоритм, в свою очередь, имеет аномалии в процессе работы с некоторыми массами, например при  $m=0,1,5,3,7$ . Это происходит из-за самой сути алгоритма, когда он старается как можно быстрее прийти в целевую точку, неудачно отклоняясь от исходной траектории в некоторых случаях.

Нейросетевой алгоритм обучался на выборке, сформированной жадным алгоритмом, но работает эффективнее: может достигать цели с большей массой груза, при этом чаще всего работает быстрее и тратит меньше энергии.

В табл. 3 приведены данные численного сравнительного моделирования для случая *б* на рис. 5.

Таблица 3

**Данные численного сравнительного моделирования**

Масса груза, кг	Релейное управление		Жадный алгоритм		Нейросетевой алгоритм	
	$t_k$ , с	Энергия, Дж	$t_k$ , с	Энергия, Дж	$t_k$ , с	Энергия, Дж
0	9	3394.112	13	3339.105	71	12807.629
1	–	–	20	5365.374	15	4489.098
5	–	–	33	23 694.302	19	21 997.658
9	–	–	48	28 410.331	38	27 370.023
9.5	–	–	–	–	51	32 544.715

Из приведенных данных следует, что управление по нейросетевому алгоритму было успешным с большей массой груза, как и в случае на рис. 5, а.

Управление по релейному алгоритму несравнимо ни с жадным, ни с нейросетевым алгоритмами, при отсутствии предположения неизвестной массы 3-го звена он работает корректно.

### Заключение

Рассмотренные алгоритмы решения задачи управления движением центра масс объекта с неполным описанием являются продолжением более ранних исследований одного из авторов. Несомненный интерес представляет сравнение аналитически сконструированных алгоритмов управления (синергетический, релейный), робастные свойства которых доказаны конструктивно [20], и алгоритмов машинного обучения (нейросетевой, жадный).

Приведенные графики и данные о времени достижения цели, энергозатратах управляемых координат свидетельствуют о приемлемом качестве аналитически полученных управлений, что обеспечивает достижение цели в терминах глобального минимума соответствующего функционала качества и удержание объекта управления в окрестности желаемого состояния.

Все рассмотренные алгоритмы допускают проектирование системы управления с ограничением на значения переменных и случай стохастического шума, однако проектирование управления с этими дополнительными ограничениями является предметом дальнейших исследований. Результаты работы могут быть эффективно применены во всех системах управления роботами-манипуляторами, функционирующими в условиях неопределенности, а также при проектировании систем поддержки принятия решений при управлении сложными объектами.

Исследование эффективности релейного и синергетического управлений роботом-манипулятором вносит определенный вклад в область управления робототехническими системами. Проведенный анализ показывает, что синергетическое управление обеспечивает более стабильное и точное позиционирование при известных шумах и возмущениях, в то время как релейное может быть более простым и эффективным в других условиях.

Используемый метод к решению задач управления роботами-манипуляторами может быть распространен на другие виды неопределенностей: неточное измерение текущего угла между звеньями, воздействие внешних случайных воздействий.

### Библиографический список

1. Матюхин В. И. Управление движением манипулятора. М.: Науч. издание Ин-та проблем управления им. В. А. Трапезникова РАН, 2010. 95 с.
2. Краснова С. А., Уткин В. А., Уткин А. В. Блочный синтез систем управления роботами-манипуляторами в условиях неопределенности. М.: ЛЕНАНД, 2014. 208 с.
3. Перегудова О. А., Макаров Д. С. Синтез управления трехзвенным манипулятором // Автоматизация процессов управления. 2015 Т. 40, № 2. С. 109–113.
4. Krasnova S. A. Cascade Design of the State Observer for Nonlinear Systems in the Presence of External Perturbation // Autom. Remote Control. 2003. Vol. 64, № 1. P. 1–22.
5. Прямой метод синтеза системы управления рабочим органом манипулятора при неполных измерениях / С. А. Краснова, В. А. Уткин, А. В. Уткин А.В., Тхань Тиен Нгуен // Проблемы управления. 2008. № 1. С. 10–18.
6. Макарова Т. А. Моделирование движения трехзвенного робота с безредукторным приводом с использованием робастных регуляторов // Известия вузов. Машиностроение. 2014. № 1. С. 4–8.
7. Dwivedy S. K., Eberhard P. Dynamic analysis of flexible manipulators, a literature review // Mechanism and Machine Theory. 2006. № 41. P. 749–777.
8. Yu H., Liu Y., Hasan M. S. Review of modelling and remote control for excavators // International Journal of Advanced Mechatronic Systems. 2009. Vol. 2, № 1. P. 68–80.
9. Active disturbance rejection control for robotic systems: A review / R. Fareh, S. Khadraoui, M. Y. Abdallah [et al.] // Mechatronics. 2021. Vol. 80. P. 102671.
10. Yi-Liang Yeh. A Robust Noise-Free Linear Control Design for Robot Manipulator with Uncertain System Parameters, 2021. 18 с.
11. Control of a Three-Link Manipulator Using Fractional-Order PID Controller / T. Kathuria, V. Kumar, K. P. S. Rana, A. T. Azar. 2018. 34 с.
12. Kilicaslan S., Özgören M. K., Ider S. K. Hybrid Force and Motion Control of a Three-Dimensional Flexible Robot Considering Measurement Noises. 2022. 23 с.
13. Bertino A., Naseradinmousavi P., Kelkar A. Analytical and Experimental Decentralized Adaptive Control of a High-Degrees-of-Freedom Robot Manipulator. 2021. 11 с.
14. Retrofitting of the IRB6-S2 robotic manipulator using Computer Numerical Control- based controllers / A. J. Alvares, J. S. Toquica, E. J. Lima II, M. H. S. Bomfim. 2018. 22 с.
15. Jahanshahi H., Zhu Zh. H. Review of machine learning in robotic grasping control in space application // Acta Astronautica. 2024. Vol. 220. P. 37–61.

16. Уткин В. И. Скользящие режимы в задачах оптимизации и управления. М.: Наука, 1987. 368 с.
17. Колесников А. А. Синергетическая теория управления. Таганрог: Гос. радиотехн. ун-т; М.: Энергоатомиздат, 2002. 343 с.
18. Kolesnikov A. A., Kolesnikova S. I., Tsvetitskaya S. A. Discrete Stochastic Regulator on a Manifold, Minimizing Dispersion of the Output Macrovariable // Мехатроника, Автоматизация, Управление. 2019. Vol. 20. P. 707–713.
19. Параев Ю. И., Колесникова Ю. И., Цветницкая С. А. Управление роботом-манипулятором в условиях неопределенности // Вестник Томского государственного университета. Управление, вычислительная техника и информатика, 2021. № 57. С. 4–12.
20. Kolesnikova S. I., Paraev Y. I., Tsvetitskaya S. A. Two Algorithms for Designing Control over Centerof-Mass Motion of a Moving Object with Incomplete Description // Proceedings-2020 2nd International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency, SUMMA 2020. 2020. P. 716–721.
21. Васильев В. А., Колесникова С. И. Апробация релейного управления роботом-манипулятором в условиях неопределенности // Семьдесят шестая Международная студенческая научная конференция ГУАП (17–21 апр. 2023 г.): сб. докл.: в 4 ч. Ч. 3: Технические науки. СПб.: ГУАП, 2023. С. 198–203.

*С. И. Колесникова\**

доктор технических наук, доцент

*А. А. Фоменкова\**

кандидат технических наук, доцент

*М. Д. Поляк\**

старший преподаватель

*А. А. Щеголева\**

магистрант

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## СИСТЕМА СТАБИЛИЗАЦИИ БИОИНЖЕНЕРНОГО СТОХАСТИЧЕСКОГО ОБЪЕКТА НА ОСНОВЕ МНОЖЕСТВЕННОСТИ ЦЕЛЕВЫХ МАКРОСОСТОЯНИЙ

Представлена функциональная схема достижения и дальнейшей стабилизации биоинженерного объекта в пространстве технологически целесообразных целевых макросостояний на принципах синергетической теории управления и алгоритмов машинного обучения. В качестве тестовых систем рассмотрены объекты анаэробного биореактора, водной экосистемы, в основе описания которых уравнения «хищник – жертва». Суть предлагаемой технологии заключается в разработке правила чередования аналитически сконструированных регуляторов, сопоставленных биофизическим и технологическим макросостояниям с аттрактивным свойством.

**Ключевые слова:** биоинженерный объект, мультистабильность, макропеременная, целевое макросостояние, правило переключения регуляторов, принцип нелинейной адаптации, синергетическое стохастическое управление, возмущение случайное и систематическое, функциональная схема множественного регулятора.

Научные исследования поддержаны грантом РНФ (проект № 23-29-00336).

*S. I. Kolesnikova\**

Dr. Sc., Tech., Associate Professor

*A. A. Fomenkova\**

PhD, Tech., Associate Professor

*M. D. Polyak\**

Senior Lecturer

*A. A. Shchegoleva \**

Postgraduate Student

\*St. Petersburg State University of Aerospace Instrumentation

## STABILIZATION SYSTEM OF A BIOENGINEERED STOCHASTIC OBJECT BASED ON A MULTIPLICITY OF TARGET MACROSTATES

A functional diagram of achieving and further stabilizing a bioengineered object in the space of technologically feasible target macrostates is presented on the principles of synergetic control theory and machine learning algorithms. Objects of an anaerobic bioreactor and aquatic ecosystem are considered as test systems, the description of which is based on the «predator – prey» equation. The essence of the proposed technology is to develop a rule for alternating analytically designed regulators associated with biophysical and technological macrostates with an attractive property.

**Keywords:** bioengineering object, multistability, macrovariable, target macrostate, rule for switching regulators, principle of nonlinear adaptation, synergetic stochastic control, random and systematic disturbance, functional diagram of a multiple regulator.

### Введение в проблему

Цель настоящего исследования – повышение надежности функционирования и времени безотказной работы для динамического объекта с мультистабильностью за счет создания модели множественного регулирования сложными объектами, к которым в полной мере относятся биоинженерные объекты, в частности системы очистки сточных вод на основе биореакторов, водные экосистемы, системы, описывающие инфекционные заболевания, и другие объекты, в описании моделей которых присутствует биохимическая и/или биофизическая составляющие.

Суть излагаемой модели стабилизации динамического нелинейного объекта сводится к управляемому «блужданию» между несколькими устойчивыми экспертно заданными так называемыми макросостояниями, под которыми будем далее понимать некоторую окрестность предельных значений макропеременных как функций динамических состояний, отражающих суть желаемых технологических показателей биоинженерного объекта управления. Мотивацией к созданию такой модели служит признание научным миром нелинейности всех реальных систем и отсутствие стационарных режимов не только у природных систем [1–4]. Принцип самоорганизации в гомеостатических системах [5; 6] и понятие теории сложных эмерджентных биосистем (по И. Р. Пригожину) привели к тому, что гомеостатическое регулирование становится основой для науки в целом.

В качестве базовых регуляторов для организации множественного регулирования полагается использовать регуляторы, аналитически построенные на основе синергетической теории управления (СТУ) [1; 7] и ее стохастического расширения [8], поскольку при соблюдении определенных условий СТУ-регуляторы обеспечивают стабилизацию динамического объекта в окрестности одного из локальных макросостояний как некоторых пределов определенных функций от динамического состояния объекта.

В докладе

- 1) приведены формализованные постановки задач управления биоинженерного объекта, допускающие применение СТУ;
- 2) дана функциональная схема стабилизации биоинженерного объекта с мультистабильностью;
- 3) представлен стохастический алгоритм и примеры его реализации для СТУ-конструирования базовых регуляторов, реализующих локальные макросостояния как обобщение детерминированного метода конструирования агрегированных регуляторов – основного метода СТУ.

## 1. Математические модели управления применительно к биоинженерным системам

Основные направления исследования биохимических систем (см., например, [9–18]) в настоящее время представлены, с одной стороны, методами, позволяющими изучать свойства динамического равновесия, инвариантности, наличия периодических режимов и пр. С другой стороны, наблюдается развивающаяся тенденция, связанная с формированием целенаправленного внешнего воздействия на нестабильный биохимический процесс, направленного на придание системе необходимых свойств. Разнообразие методов, используемых при решении этой задачи, продиктовано следующими факторами:

- различие математического описания (системы ОДУ или разностных уравнений и дробных режимов реакции-диффузии);
- уровень и виды неопределенностей модели (детерминистические и стохастические);
- критерии качества целевой системы и ограничения на объект и параметры управления.

Так, для объектов, рассматриваемых в классе ОДУ / разностных систем, используются методы дифференциальных игр и принцип максимума Понтрягина, алгоритмы машинного обучения, метод гарантирующих регуляторов, стохастические алгоритмы и др.

Разнообразие методов управления (см., например, обзор современных и классических методов управления А. А. Красовского в [1]), во-первых, указывает прежде всего на отсутствие единого инструмента исследования нелинейных систем и, во-вторых, на проблему дальнейшей стабилизации уже достигнутого целевого состояния объектов, подверженных мультистабильности, отягощенной возможными возмущениями как внешнего, так и внутреннего характера.

Существующие методы управления для сложных и неполно формализуемых объектов, к которым относятся в полной мере и биоинженерные системы, условно принято делить на следующие группы:

- классические методы управления нелинейными объектами (см. обзор в [1; 9] с указанием достоинств и недостатков каждого);
- современные методы и реализующие их алгоритмы на основе машинного обучения;
- численное и имитационное моделирование схем воздействия на биоинженерный объект [6; 19].

## 2. Формальные постановки задачи управления в условиях неопределенности с позиции СТУ

Исходная математическая модель объекта управления имеет общее описание в виде системы нелинейных обыкновенных дифференциальных уравнений, все решения которой ограничены:

$$\begin{aligned} \dot{\mathbf{X}} &= \mathbf{A}(\mathbf{X}) + \zeta(t) + \mathbf{G}\mathbf{U}(t), \quad \mathbf{X} \in \mathbb{R}^n, \quad \mathbf{X}[t_0] = \mathbf{X}_0 \\ \mathbf{G} &= \left( 0, \dots, 0, \underbrace{1, \dots, 1}_m \right), \quad \mathbf{U} = (0, \dots, 0, u_1, \dots, u_m)^T, \\ \zeta &= (0, \dots, 0, \zeta_1, \dots, \zeta_m)^T, \quad m \leq n, \end{aligned} \quad (1)$$

где  $\mathbf{X} \in \mathbb{R}^n$ ,  $\mathbf{U}, \zeta \in \mathbb{R}^m$ ,  $m \leq n$  – векторы состояния, управления, ограниченного неконтролируемого возмущения, соответственно;  $\mathbf{A}(\mathbf{X})$  – нелинейная векторная функция состояния.

В описании (1) с инженерной точки зрения функция времени  $\zeta(t)$  есть неконтролируемое возмущение по каналу управления. Содержательно  $\zeta(t)$  может выражать и неполноту модели объекта управления и возможные неточности построения управляющего воздействия при возникновении нестабильных быстро протекающих процессов.

При этом удобно для корректности аналитического вывода закона стохастического управления на основе СТУ-стратегий, обеспечивающего заданные свойства целевой системы, чтобы неизбежная на практике дискретизация модели (1) могла быть представлена в виде стохастической системы разностных уравнений:

$$\begin{aligned}\mathbf{X}[k+1] &= \mathbf{F}[k] + \mathbf{u}[k] + \xi[k+1] + c\xi[k], \\ \mathbf{X}[k_0] &= \mathbf{X}_0, \quad k = k_0, k_0 + 1, \dots\end{aligned}\tag{2}$$

где  $\mathbf{X}[k] = (X_1[k], \dots, X_n[k])^T$ ,  $\mathbf{F}[k] := \mathbf{F}(\mathbf{X}[k]) \in \mathbb{R}^n$ ,  $\mathbf{u} \in \mathbb{R}^m$ ,  $m \leq n$  – векторы состояний дискретной модели технологического процесса, нелинейной векторной функции описания динамики изменения состояний объекта, и управления, соответственно, может содержать случайные неконтролируемые возмущения  $\xi[k] \in \mathbb{R}^l$ ,  $l \leq m$  в виде некоррелированных функций с нулевым средним и ограниченной дисперсией:  $\mathbf{E}\{\xi_i[k]\} = 0$ ,  $\mathbf{D}\{\xi_i[k]\} = \sigma^2$ ,  $i = \overline{1, l}$ ,  $|c| < 1$ . Постоянная  $c$  выражает факт частичной компенсации возмущения предыдущего шага за счет управления.

### 3. Примеры многоцелевых задач биоинженерии в условиях неопределенности

Приведем три примера прикладных задач в виде математической модели объекта управления и желательных заданных экспертом целевых установок, а для последнего примера продемонстрируем алгоритм получения управлений для задач в непрерывной и дискретной постановках, схема которых является универсальной при выполнении ограничений, требуемых СТУ и ее алгоритмами синтеза регуляторов.

**Пример 3.1. Конструирование сценариев развития простейшей водной экосистемы.** Математическая модель одного из вариантов описания управляемого взаимодействия фитопланктона и зоопланктона (природного хищника фитопланктона) [19; 20] может иметь вид:

$$\begin{aligned}\frac{dP_1}{dt} &= r_1 P_1 \left( 1 - \frac{P_1 + \alpha_1 P_2}{K_1} \right) - \frac{w_1 P_1 Z}{d_1 + P_1}, \\ \frac{dP_2}{dt} &= r_2 P_2 \left( 1 - \frac{P_2 + \alpha_2 P_1}{K_2} \right) - \frac{w_2 P_2 Z}{d_2 + P_2 + \beta P_1} + u + \zeta, \\ \frac{dZ}{dt} &= \frac{w_1 P_1 Z}{d_1 + P_1} - \frac{w_2 P_2 Z}{d_2 + P_2 + \beta P_1} - cZ,\end{aligned}\tag{3}$$

где переменные состояния  $P_1, P_2, Z$  сопоставлены количественным характеристикам популяций нетоксичного фитопланктона, токсичного фитопланктона и зоопланктона соответственно;  $\zeta$  – неконтролируемое возмущение как функция времени. В качестве целевых макросостояний могут выступать следующие:

- 1) достижение численного показателя токсичного фитопланктона заданного целевого значения  $P_2^*$ ;
- 2)

$$\psi(t) = P_2(t) - P_2^* \xrightarrow{t \rightarrow \infty} 0,\tag{4}$$

где  $P_2^*$  может быть функцией времени;

- 3) достижение целесообразного баланса количественных характеристик нетоксичного фитопланктона, токсичного фитопланктона и зоопланктона с экспертно заданными коэффициентами пропорциональности  $k_1, k_2, k_3$ :

$$\psi(t) = k_1 P_1(t) + k_2 P_2(t) + k_3 Z(t) \xrightarrow{t \rightarrow \infty} 0,$$

и другие физически согласованные целесообразные свойства целевой системы для (3).

**Пример 3.2. Стабилизация функционирования системы биоочистки в окрестности одного из практически желательных макросостояний.** Описанию (1), в частности, подчиняются модели анаэробных биореакторов со взвешенно-седиментированной биомассой и с прикрепленной на неподвижных плоскостных носителях биомассой, являющиеся следствием обобщенной модели анаэробного биореактора [21] как сложного биотехнического объекта:

$$\begin{aligned}
\mathbf{X} &= (S, B_1, P, B_2, G, \theta, Q)^T, \mathbf{G} = (0, 0, 0, 0, 0, 1, 1)^T, \\
F_1 &= Q(t)(S_{in}(t) - S(t)) - k_1(\theta)B_1(t) - k_2(\theta) \frac{S(t)B_1(t)}{k_3(\theta) + S(t)}, \\
F_2 &= -Q(t)B_1(t) + k_4(\theta) \frac{S(t)B_1(t)}{k_3(\theta) + S(t)}, \\
F_3 &= -Q(t)P(t) + k_5(\theta)B_1(t) + k_6(\theta) \frac{S(t)B_1(t)}{k_3(\theta) + S(t)} - k_7(\theta)B_2(t) - k_8(\theta) \frac{P(t)B_2(t)}{k_9(\theta) + P(t)}, \\
F_4 &= -Q(t)B_2(t) + k_{10}(\theta) \frac{P(t)B_2(t)}{k_9(\theta) + P(t)}, \\
F_5 &= -G(t) + k_{11}(\theta) \frac{P(t)B_2(t)}{k_9(\theta) + P(t)} \frac{k_{12}(\theta)}{k_{12}(\theta) + P(t)}, \quad F_6 = 0, \quad F_7 = 0.
\end{aligned} \tag{5}$$

Здесь  $\mathbf{X}$  – вектор состояний (концентрации исходного субстрата  $S$ , кислотогенной биомассы  $B_1$ , промежуточных продуктов брожения  $P$ , метаногенной биомассы  $B_2$ , побочного продукта – метана  $G$ , рабочая температура в биореакторе  $\theta$ , скорость разбавления среды в биореакторе  $Q$ );  $k_i(\theta)$  – кинетические параметры процесса с известным законом изменения. Тогда  $\mathbf{u}, \zeta \in \mathbb{R}^2$  – искомый закон регулирования по температуре и по концентрации входного потока и неизвестная функция времени (возмущение) соответственно.

Приведем формулировки некоторых целевых макросостояний  $\psi(\mathbf{X}(t)) \rightarrow 0, \psi(\mathbf{X}(t)) \in R^m, m=1,2$  для анаэробного биореактора с указанным описанием:

- максимизация выхода биогаза (метана):  $\psi = G - G^* \rightarrow 0$  (здесь и далее знак « $*$ » указывает на заданные экспертом значения);
- минимизация содержания летучих жирных кислот  $\psi = P - P_{\min} \rightarrow 0$ ;
- достижение заданной степени очистки  $\frac{S_{in} - (S + P)}{S_{in}} 100\% \rightarrow \eta^*$  на выходе реактора, при ограничении

на значение гидравлического времени  $V/Q_{in} < t_{st}$  для заданных входных данных:  $V$  – объем реактора,  $S_{in}$  – входная загрязненность;

- совместное достижение минимизации концентрации загрязнений  $S_{out}(t) = S(t) + P(t)$  потока очищенной воды на выходе биореактора и вывода биогаза на желаемый уровень:

$$\begin{aligned}
\psi_1(t) &= S(t) + P(t) - S^* \rightarrow 0, \\
\psi_2(t) &= G(t) - G^* \rightarrow 0,
\end{aligned}$$

и другие технологически и физически согласованные макросостояния.

**Пример 3.3. Вывод системы иммунологии в окрестность безопасного для большого органа макросостояния.** Модель иммунологии [22] в обозначениях (1) как объект управления примет вид:

$$\begin{aligned}
\dot{\mathbf{X}} &= \mathbf{F}(\mathbf{X}) + \zeta(t) + \mathbf{G}\mathbf{u}(t), \quad \mathbf{X} = (x_1, x_2, x_3, x_4)^T = (V, C, F, m)^T, \\
\mathbf{F}(\mathbf{X}) &= (f_1, f_2, f_3, f_4)^T, \quad f_1 = a_1 - a_2F, \quad f_2 = a_3\xi(m)F(t - \tau)V(t - \tau) - a_5(C - 1), \\
f_3 &= a_4(C - F) - a_8, \quad f_4 = a_6V - a_7m, \quad \mathbf{G} = (0, 0, 1, 0), \quad \mathbf{u} = (0, 0, 1, 0)^T, \\
V(t_0) &= V_0, \quad C(t_0) = C_0, \quad F(t_0) = F_0, \quad m(t_0) = m_0.
\end{aligned} \tag{6}$$

В модели (6) величины  $a_i, i = 1, \dots, 8$  – параметры модели, определяющие стадию поражения органа;  $\tau$  – длительность формирования плазматических клеток;  $V$  – концентрация антигенов (жертв);  $F$  – концентрация антител (хищников);  $C$  – концентрация плазматических клеток;  $m$  – относительная характеристика пораженного органа;  $\xi(m)$  – функция, количественно сопоставленная скорости производства антител при поражении органа,  $\zeta$  – неконтролируемое возмущение,  $\mathbf{u}$  – искомый закон, регулирующий поступление лекарственных средств, реализующий цель управления:

$$\psi = V - V^* \rightarrow 0, \quad V^* \downarrow 0, \tag{7}$$

и функционалом качества  $\Phi_C$  с параметром регулятора  $w > 0$ .

Представим два базовых алгоритма [7; 8] конструирования регуляторов  $\mathbf{u} \in R^m$ , обеспечивающих стабилизацию (1) и (2) в окрестности заданного макросостояния  $\psi(\mathbf{X}) \rightarrow 0, \psi(\mathbf{X}) \in R^m$ , в условиях возмущения и для читабельности изложим их для одного из примеров.

**Пример 3.4. Применение алгоритма нелинейной адаптации.** Решение задачи в постановке (6), (7) реализуется выполнением следующих шагов.

1. Стандартное расширение фазового пространства на основе моделирования внешнего возмущения  $\zeta(t)$  в виде решения некоторого дифференциального уравнения  $\mathbf{z}$ , обеспечивающее замкнутость системе (6) как базовой для применения алгоритма аналитического проектирования [\*]:

$$\begin{aligned}\dot{\mathbf{X}} &= \mathbf{F}(\mathbf{X}) + \mathbf{z}(t) + \mathbf{G}u(t), \\ \dot{\mathbf{z}}(t) &= \eta\psi(t), \eta = \text{const} > 0,\end{aligned}\quad (8)$$

где коэффициент  $\eta$  – потенциальный параметр синтезируемой системы управления.

2. Вывод структуры регулятора  $u$  из решения 1-й вариационной задачи  $(\Phi_C^1, \psi_1)$ :

$$\Phi_C^1 = \int_0^\infty (\psi_1^2 + w_1^2 \dot{\psi}_1^2) dt \rightarrow \min, \psi_1 = x_3 - \varphi(x_1, z, x_2, x_4),$$

где  $\varphi(x_1, z, x_2, x_4)$  – внутреннее управление, а, согласно утверждению 1, уравнение экстремалей для  $\Phi_C^1$  имеет вид (4) с параметром  $w_1 = \text{const} > 0$ , из которого следует, что

$$u = -w_1^{-1}\psi_1 - f_3(x_1, x_2, x_3, x_4) - z + \dot{\varphi}(x_1, z, x_2, x_4).\quad (9)$$

3. Редукция системы на достигнутом макросостоянии  $\psi_1 = 0, t \rightarrow \infty$ , т. е. с учетом  $x_3 = \varphi(x_1, z, x_2, x_4)$  получаем:

$$\begin{aligned}\dot{\mathbf{X}}_{\psi_1} &= \mathbf{F}_{\psi_1}(\mathbf{X}_{\psi_1}), \mathbf{X}_{\psi_1} = (x_1, x_2, \varphi, x_4)^T = (V, C, \varphi, m)^T, \\ \dot{z}(t) &= \eta\psi(t), \\ \mathbf{F}_{\psi_1}(\mathbf{X}_{\psi_1}) &= (f_{1\psi_1}, f_{2\psi_1}, f_{4\psi_1})^T, f_{1\psi_1} = a_1 - a_2\varphi, f_{2\psi_1} = a_3\xi(m)\varphi(t-\tau)V(t-\tau) - a_5(C-1), \\ f_{4\psi_1} &= a_6V - a_7m, \dot{z}(t) = \eta\psi(t).\end{aligned}\quad (10)$$

4. Вывод структуры нового (внутреннего) управления  $\varphi = \varphi(x_1, z, x_2, x_4)$  из решения 2-й вариационной задачи  $(\Phi_C^2, \psi_2)$ :

$$\Phi_C^2 = \int_0^\infty (\psi_2^2 + w_2^2 \dot{\psi}_2^2) dt \rightarrow \min, \psi_2 = \psi + kz, k = \text{const} > 0.$$

Из основного уравнения  $w_2\dot{\psi}_2 + \psi_2 = 0, w_2 > 0$  экстремалей для  $\Phi_C^2$  следует, что

$$\varphi = a_2^{-1}(w_2^{-1}(\psi + kz) + a_1 + k\eta\psi),\quad (11)$$

и, соответственно,

$$\dot{\varphi} = \frac{\partial\varphi}{\partial x_1} \frac{dx_1}{dt} + \frac{\partial\varphi}{\partial z} \frac{dz}{dt} = a_2^{-1}((w_2^{-1} + k\eta)(a_1 - a_2F) + w_2^{-1}k\eta\psi).\quad (12)$$

5. Формирование итогового регулятора в виде совокупности уравнений (7), (9), (11), (12).

Нижний индекс  $(\cdot)_{\psi_1}$  в описании (10) означает, что система (8) описывает поведение координат (6) на многообразии  $\psi_1 = 0, t \rightarrow \infty$ .

#### 4. Модель множественного управления целевыми макросостояниями биоинженерного объекта

Функциональная модель управления биоинженерной системы при наличии нескольких устойчивых состояний (рис. 1) предполагает выполнение условий, аналогичных требованиям при конструировании регуляторов на синергетических принципах [1; 7]:

- 1) объект управления описан системой ОДУ (разностных уравнений);
- 2) существование устойчивых макросостояний, математическая модель которых известна в форме предельных соотношений  $\psi(\mathbf{X}(t)) = 0$ , где  $\psi(\mathbf{X}(t))$  – экспертно определяемая функция (макропеременная) от состояния объекта управления;
- 3) существование и ограниченность решений исходной системы уравнений относительно заданной цели управления;
- 4) притягивающие свойства макросостояний;
- 5) ограниченность неконтролируемых возмущений по каналам управления.



Существенным расширением основного метода СТУ является его распространение на стохастические объекты [8], т. е. возмущение может носить систематический, случайный или смешанный характер, при этом случайное возмущение может учитываться не только по каналу управления.

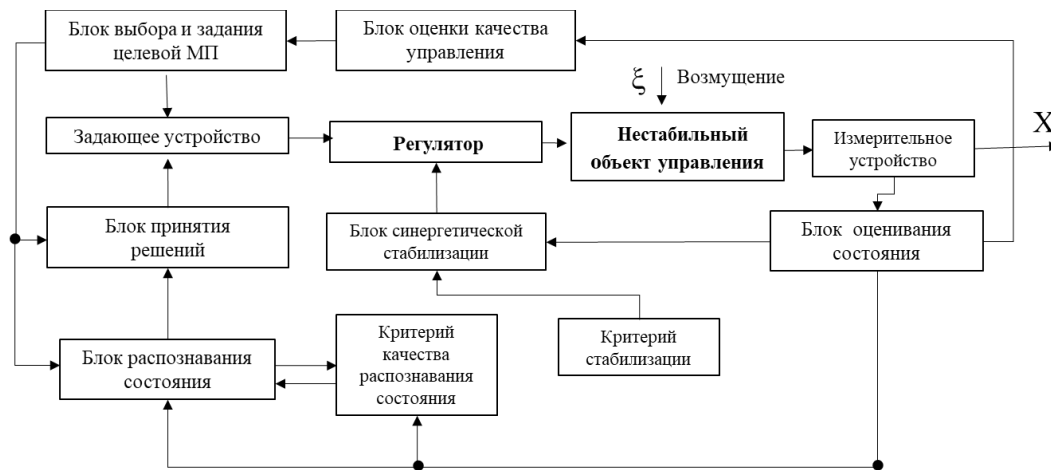


Рис. 1. Функциональная схема организации достижения и поддержания стабильного состояния биоинженерного объекта в условиях возмущений

Специфика представленной модели стабилизации многомерного, многосвязного с режимами детерминированного хаоса объекта заключается в следующем:

- размерность множества целевых состояний, задаваемая экспертно, не является жесткой и по мере накопления истории об объекте динамически изменяется;
- априорно полученная на обучении траектория целенаправленного «блуждания» изображающей точки системы может подчиняться критерию энергосбережения, но в реальных условиях важен фактор стабильности всей системы;
- система адаптивна и изменяет структуру регулятора в соответствии с глобальным критерием оценки качества управления и в ответ на факторы характера возмущения и/или на присущую биоинженерным объектам внутреннюю нестабильность;
- система управляется и стабилизируется в соответствии с принципом физической теории управления А. А. Красовского и направленной самоорганизующейся динамики.

**Краткие комментарии к алгоритмическому содержанию основных блоков.** Детальная структура блока распознавания образов состояний и принятия решений (рис. 2) определена на основе алгоритма из [23].

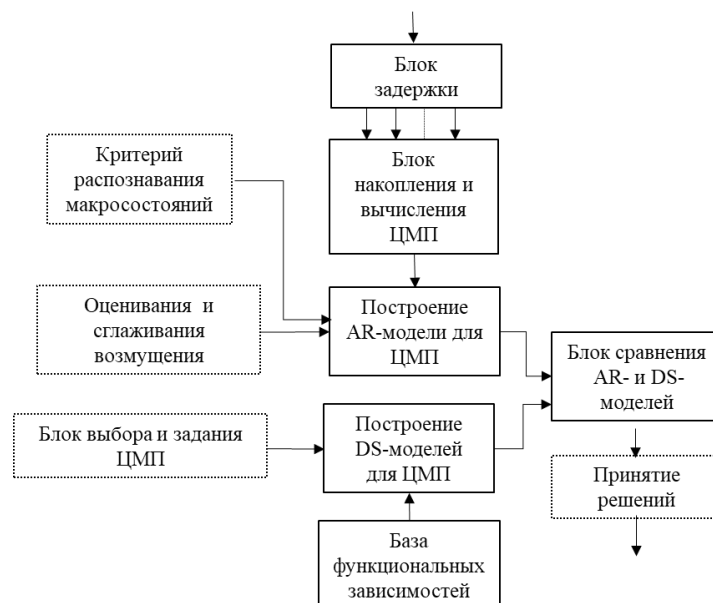


Рис. 3. Детализация блока распознавания образов состояний и принятия решений; DS и AR – обозначения операций получения параметров разностных схем и авторегрессионных моделей; ЦМП – целевая макропеременная; ПР – принятие решений

Здесь структурно представлен алгоритм распознавания состояний как классов (множества отрезков дискретных фазовых траекторий), обладающий высокой разделяющей способностью и основанный на сопоставлении расстояний между векторами параметров авторегрессии, соответствующей отрезку временного ряда – текущим наблюдениям, и параметров разностных схем, сопоставленных выделенным макросостояниям как признакам этих состояний.

Блок ядерного сглаживания оценки возмущения  $\xi$  реализует алгоритм ядерной регрессии [24] для полученной оценки  $\hat{\xi}$ , что повышает точность управления или уменьшает радиус окрестности целевого состояния  $\Psi(\mathbf{X}(t)) = 0$ .

Блок формирования закона нелинейного управления основан на алгоритме стохастического расширения [8] метода конструирования агрегированных регуляторов [1; 7], основные положения которого следующие:

- 1) определяется структура регулятора при фиксированной макропеременной и в предположении полного описания объекта на основе метода конструирования агрегированных регуляторов;
- 2) из множества возможных допустимых управлений выбираются стратегии, обеспечивающие минимальность дисперсии целевой макропеременной.

Функционал качества управления при выбранной целевой макропеременной в условиях неизбежной на практике предварительной дискретизации стохастического объекта управления имеет вид

$$\begin{aligned} \Phi = \Phi(\Psi) &= \mathbf{M} \left( \sum_{k=k_0}^{\infty} \sum_{j=1}^m \left( \alpha_j^2 (\psi_j[k])^2 + (\Delta \psi_j[k])^2 \right) \right) \rightarrow \min, \\ \Delta \psi_j[k] &= \psi_j[k] - \psi_j[k-1], \quad k = k_0 + 1, \dots; \\ \psi_j[k_0] &= \psi_j(\mathbf{X}[k_0]), \quad \mathbf{X}[k_0] = \mathbf{X}_0, \quad \Delta \psi_j[k_0] = 0, \\ \psi_j[k+1] + \lambda_j \psi_j[k] &= 0, \quad \lambda_j = \text{const}, \quad |\lambda_j| < 1, \quad j = \overline{1, m}, \quad k = k_0, k_0 + 1, \dots \end{aligned}$$

В [8] показано, что оценка случайных возмущений в указанных примерах может определяться по формуле

$$\Psi^{(1)}[k+1] + \lambda^{(1)} \Psi^{(1)}[k] = \hat{\xi}[k+1],$$

где умножение по координатам, а верхний индекс указывает на уровень иерархии аналитического синтеза си-нергетического регулятора [2; 4].

**Пример 4.1. Применение алгоритма конструирования стохастического регулятора на основе СТУ-стратегий.** Объект управления (3), (4) после дискретизации по Эйлера с параметром  $h$  с учетом представления (2) может быть приведен к виду

$$\begin{aligned} P_1[k+1] &= P_1[k] + h \left( r_1 P_1[k] \left( 1 - \frac{P_1[k] + \alpha_1 P_2[k]}{K_1} \right) - \frac{w_1 P_1[k] Z[k]}{d_1 + P_1[k]} \right), \\ P_2[k+1] &= P_2[k] + h \left( r_2 P_2[k] \left( 1 - \frac{P_2[k] + \alpha_2 P_1[k]}{K_2} \right) - \frac{w_2 P_2[k] Z[k]}{d_2 + b_1 P_2^2[k]} + u[k] \right) + \xi[k+1] + c \xi[k], \\ Z[k+1] &= Z[k] + h \left( \frac{\gamma_1 P_1[k] Z[k]}{d_1 + P_1[k]} - \frac{\gamma_2 P_2[k] Z[k]}{d_2 + b_1 P_2^2[k]} - m Z[k] - m_1 Z^2[k] \right), \quad k = 0, 1, \dots \end{aligned} \quad (13)$$

Основные шаги конструирования стохастического СТУ-алгоритма управления следующие.

1. Определяем структуру детерминированного регулятора с фиксированными функциями  $\xi[k], \xi[k+1], k = k_0, k_0 + 1, \dots$ , применяя дискретную версию метода конструирования агрегированных регуляторов (АКАДР [1]) к (13):

$$u[k] = \frac{-P_2[k] - \xi[k+1] - c \xi[k] + P_2^* - T_1 \Psi[k]}{h} - \left( r_2 P_2[k] \left( 1 - \frac{P_2[k] + \alpha_2 P_1[k]}{K_2} \right) - \frac{w_2 P_2[k] Z[k]}{d_2 + b_1 P_2^2[k]} \right). \quad (14)$$

2. Применяем операцию условного математического ожидания к (14) относительно  $\xi^k = (\xi[k_0], \xi[k_0 + 1], \dots, \xi[k])$ , получим с учетом некоррелированности  $\xi[k], \xi[k+1], k = k_0, k_0 + 1, \dots$ :

$$u_{\text{vmo}}[k] = \frac{-P_2[k] - c \xi[k] + P_2^* - T_1 \Psi[k]}{\tau} - \left( r_2 P_2[k] \left( 1 - \frac{P_2[k] + \alpha_2 P_1[k]}{K_2} \right) - \frac{w_2 P_2[k] Z[k]}{d_2 + b_1 P_2^2[k]} \right).$$

3. Подставляем найденное управление в (13) и после определения выражения для оценки возмущения как функции от измеряемых величин  $\psi[k]$ ,  $k = k_0, k_0 + 1, \dots$  получим итоговое выражение для дискретного стохастического регулятора:

$$u[k] = \frac{-P_2[k] - c(\psi[k] + T_1\psi[k-1]) + P_2^* - T_1\psi[k]}{h} - \left( r_2 P_2[k] \left( 1 - \frac{P_2[k] + \alpha_2 P_1[k]}{K_2} \right) - \frac{w_2 P_2[k] Z[k]}{d_2 + b_1 P_2^2[k]} \right). \quad (15)$$

### Заключение

Представленное исследование посвящено проблеме повышения качества управления объектами биоинженерной направленности на тестовых примерах двух предметных областей: биореактора и водной экосистемы (без ограничения общности).

Представлена структурно-функциональная схема стабилизации неустойчивого биохимического объекта в пространстве нескольких практически «благоприятных» целевых состояний, для достижения которых существуют СТУ-регуляторы.

Переходы между макросостояниями обеспечиваются последовательностью действий: оценением и распознаванием текущего состояния, оценкой близости текущего образа состояния к другим макросостояниям, множество которых априорно задано, принятием решений об изменении цели в процессе функционирования объекта и управлением перехода от одного макросостояния к другому.

Предложенный подход к конструированию киберфизической системы для биоинженерного объекта использует в совокупности методы:

- оптимизационные – на базе нелинейной теории синергетического управления;
- алгоритмы распознавания образов;
- методы моделирования временных рядов;
- методы имитационного моделирования для оценивания параметров и переменных в реальном режиме времени;
- алгоритмы компьютерного моделирования;
- методы многокритериальной оптимизации и имеет целью обеспечить надежное комплексное сопровождение практического функционирования сложной биохимической системы.

Теоретическая и практическая важность представленной методики получения оптимизационного правила воздействия на объект биоинженерии заключается в следующем:

- аналитический вывод формул для достижения объектом равновесного устойчивого локального макросостояния, что дает значительное преимущество перед другими методами управления в силу наличия универсального закона регулирования;
- учет случайного возмущения в описании объекта управления, обладающего хаотическими свойствами;
- возможность выявления новых свойств биохимических процессов при изменении целевых требований и/или управляемых переходных процессов между окрестностями целевых состояний (формирования сценариев поведения объекта);
- построение прогноза поведения модели объекта при неточностях задания параметров;
- получение рекомендаций по управляемости модели в зависимости от уровня возмущений (внутренних и внешних), неизбежно действующих на неустойчивый в разомкнутом состоянии объект.

Представленный концептуальный и алгоритмический аппарат есть инструмент для моделирования и проверки гипотез об эффективности разрабатываемых алгоритмов управления, сопоставления предсказываемых и эмпирически наблюдаемых результатов с целью более глубокого исследования биоинженерных механизмов, являющихся основой сложных современных систем.

### Библиографический список

1. Синергетика и проблемы теории управления: сб. науч. тр. / под ред. А. А. Колесникова. М.: Физматлит, 2004. 504 с.
2. Мусеев Н. Н. Избранные труды: в 2 т. Т. 1. Гидродинамика и механика. Оптимизация, исследование операций и теория управления. М.: Тайдекс Ко, 2003. 376 с.
3. Малинецкий Г. Г. Среда обитания: параметры порядка, самоорганизация: хаос, структуры, вычислительный эксперимент // Природа. 2023. № 3(1291). С. 26–35.
4. Lazarević M. P. Elements of mathematical phenomenology of self-organization nonlinear dynamical systems: Synergetics and fractional calculus approach // International Journal of Non-Linear Mechanics. 2015. Vol. 73. P. 31–42.
5. Хакен Г. Синергетика. Иерархии неустойчивостей в самоорганизующихся системах и устройствах. М.: Мир, 1985. 424 с.
6. Еськов В. В. Термодинамика неравновесных систем I. R. Prigogine и энтропийный подход в физике живых систем // Вестник новых медицинских технологий. 2017. Т. 24, № 2, С. 7–15.
7. Колесников А. А. Новые нелинейные методы управления полетом. М.: Физматлит, 2013. 196 с.

8. *Kolesnikova S., Kustova E.* Application of a Stochastic Extension of the Analytical Design of Aggregated Regulators to a Multidimensional Biomedical Object // *Mathematics*. 2023. № 11(21). P. 4484.
9. Overview of the recent research progress for stability and control on random nonlinear systems / R. Xi, H. Zhang, Y. Wan, S. Sun // *Annual Reviews in Control*. 2022. Vol. 53. P. 70–82.
10. *Li W., Krstic M.* Prescribed-Time Control of Stochastic Nonlinear Systems with Reduced Control Effort // *Journal of Systems Science and Complexity*. 2021. Vol. 34. P. 1782–1800.
11. *Roman M., Oлару S.* Model-Based Design for Biosystems. Control Opportunities and Discrete-Time Modeling. Challenges // *IFAC-PapersOnLine*. 2018. Vol. 51, iss. 30. P. 666–671.
12. *Freeman W. J., Kozma R., Werbos P. J.* Biocomplexity: adaptive behavior in complex stochastic dynamical systems // *Biosystems*. 2001. Vol. 59, iss. 2. P. 109–123.
13. *Madsen M., Holm-Nielsen J. B., Esbensen K. H.* Monitoring of anaerobic digestion processes: A review perspective // *Renewable and Sustainable Energy Reviews*. 2011. № 15. P. 3141–3155.
14. *Dochain D.* Automatic control of bioprocesses. John Wiley & Sons Publ., 2013, 244 p.
15. *Vieira L. S., Laubenbacher R. C.* Computational models in systems biology: standards, dissemination, and best practices // *Current Opinion in Biotechnology*. 2022. Vol. 75, № 102702.
16. *Beniich N, Abouzaid B., Dochain D.* Extremum seeking control for a mass structured cell population balance model in a bioreactor // *IFAC-PapersOnLine*. 2020. Vol. 53, iss. 2. P. 11392–11397.
17. *Abed E. H.* Bifurcation control: new directions motivated by biology and complex engineered systems. *IFAC Proceedings Volumes*. 2007. Vol. 40, iss. 12. P. 757–763.
18. *Díaz-Seoane S., Blas A. B., Villaverde A. F.* Controllability and accessibility analysis of nonlinear biosystems. *Computer Methods and Programs in Biomedicine*. 2024. Vol. 245. P. 108015.
19. The role of avoidance by zooplankton for survival and dominance of toxic phytoplankton / S. Chakraborty, S. Bhattacharya, U. Feudel, J. Chattopadhyay // *Ecological Complexity*. 2012. Vol. 11. P.144–153.
20. *Thakur N. K., Singh R., Ojha A.* Dynamical study of harmful algal bloom in Sundarban mangrove wetland with spatial interaction and competing effects // *Modeling Earth Systems and Environment*. 2022. Vol. 8. P. 555–577.
21. *Фоменкова А. А.* Модельно-алгоритмическое обеспечение мониторинга состояния систем анаэробной биологической очистки сточных вод: дисс. ... канд. техн. наук. СПб., 2022. 227 с.
22. *Марчук Г. И.* Математические модели в иммунологии. М.: Наука, 1985. 239 с.
23. Колесникова С. И. Метод распознавания и оценивания состояний слабоформализованного динамического объекта на основе разметки временного ряда // *Известия РАН. Теория и системы управления*. 2011. № 5. С. 41–52.
24. *Nadaraya E.* On Estimating Regression // *Theory of Probability & Its Applications*. 1964. № 9(1). P. 141–142.

*И. М. Кудрин\**

студент

*В. А. Миклуш\**

кандидат технических наук, доцент – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ИНТЕЛЛЕКТУАЛЬНЫЕ ИНСТРУМЕНТЫ ДЛЯ СОЗДАНИЯ АДАПТИВНЫХ ВЕБ-ДИЗАЙНОВ: ПОДХОДЫ И ПЕРСПЕКТИВЫ

Рассматривается роль интеллектуальных инструментов в создании адаптивных дизайнов. Дан обзор возможностей применения различных интеллектуальных технологий для анализа пользовательских данных и предложений по улучшению дизайна.

**Ключевые слова:** адаптивный веб-дизайн, машинное обучение, искусственный интеллект, интеллектуальные инструменты.

*I. M. Kudrin\**

Student

*V. A. Miklush\**

PhD, Tech., Associate Professor – Scientific Adviser


\*St. Petersburg State University of Aerospace Instrumentation

## INTELLIGENT TOOLS FOR CREATING RESPONSIVE WEB DESIGNS: APPROACHES AND PERSPECTIVES

The paper examines the role of intelligent tools in creating adaptive designs. An overview of the possibilities of using various intelligent technologies for analyzing user data and suggestions for improving the design is given.

**Keywords:** adaptive web design, machine learning, artificial intelligence, intelligent tools.

Адаптивный веб-дизайн (Responsive Web Design, далее RWD) представляет собой подход к созданию веб-сайтов, который позволяет корректно отображать их на различных устройствах – от мобильных телефонов и планшетов до настольных компьютеров. Важности RWD возрастают в связи с увеличением числа пользователей, взаимодействующих с Интернетом через разнообразные устройства. По данным Statista [1], в 2023 г. более 60% мирового интернет-трафика приходится на мобильные устройства (рисунок). Это создает необходимость для разработчиков и дизайнеров создавать интерфейсы, которые одинаково удобны для использования на устройстве с любым форматом экрана. Адаптивный веб-дизайн стал стандартом индустрии, так как он позволяет создавать интерфейсы, которые учитывают специфические потребности пользователей, обеспечивая им полноценный доступ к информации и онлайн-сервисам, а интеллектуальные инструменты играют ключевую роль в его реализации.



Доля мобильных устройств в интернете с 2015 по 2024 года [1]

## Роль интеллектуальных инструментов в создании адаптивных дизайнов

Интеллектуальные технологии, такие как машинное обучение и искусственный интеллект (далее ИИ), становятся все более весомыми в процессе создания адаптивных веб-дизайнов. Они помогают автоматизировать и оптимизировать многие аспекты разработки, сокращая время и затраты, а также обеспечивают более высокую степень персонализации, что особенно важно для удовлетворения уникальных потребностей различных групп пользователей. Это актуально в современных условиях, когда более 15% пользователей сети Интернет по всему миру имеют какие-либо формы инвалидности [2].

Один из примеров таких технологий – Adobe XD [3], который использует ИИ для анализа пользовательских данных и предложений по улучшению дизайна, например с учетом особенностей восприятия людьми с ограниченными возможностями. Инструменты на базе ИИ могут автоматически предлагать оптимальные цветовые схемы и контрастность для пользователей с нарушениями зрения, а также обеспечивать корректное использование заголовков и текстов. Кроме того, Adobe XD использует технологии машинного обучения для анализа поведения пользователей и предлагает рекомендации по улучшению дизайна. Еще один пример – платформа Figma [4], которая предлагает функции автоматической адаптации макетов, обеспечивая их доступность для всех пользователей, независимо от их возможностей. Кроме описанных примеров, так же есть такие приложения, как: Webflow, InVision и Framer, которые так же позволяют создавать адаптивный дизайн и применять для этого ИИ.

## Подходы к использованию интеллектуальных инструментов

Использование интеллектуальных инструментов позволяет автоматизировать множество аспектов разработки адаптивных дизайнов. Например, автоматическое создание макетов и генерация CSS-кода на основе предварительно заданных шаблонов и правил могут значительно ускорить процесс. Инструменты, такие как Sketch и Figma, позволяют разработчикам создавать и изменять дизайн, не погружаясь в детали верстки.

Кроме того, интеллектуальные инструменты могут использоваться для создания тестов доступности в реальном времени, что позволяет разработчикам оперативно выявлять и устранять проблемы, влияющие на пользователей с ограниченными возможностями. Это снижает затраты времени на исправление ошибок и помогает обеспечить соответствие сайта требованиям доступности, таким как Web Content Accessibility Guidelines (WCAG). [5]

Еще одна перспективная область – является использование аналитических данных и машинного обучения для адаптации дизайна под конкретных пользователей. Анализируя поведение пользователей на сайте, системы ИИ могут предлагать персонализированные элементы дизайна, что приводит к улучшению взаимодействия пользователей с веб-ресурсом. Использование интеллектуальных инструментов для автоматической адаптации интерфейсов под потребности пользователей с ограниченными возможностями улучшает доступность сайта, что также актуально сегодня.

## Перспективы развития интеллектуальных инструментов для адаптивного веб-дизайна

Внедрение интеллектуальных технологий в веб-дизайн открывает новые возможности. Одна из ключевых возможностей – повышение уровня персонализации и автоматизации процессов разработки. Однако, с другой стороны, интеграция таких технологий может быть сложной и требовать значительных усилий по адаптации и настройке.

В ближайшем будущем можно ожидать дальнейшего развития кросс-платформенных решений, которые позволят создавать единые интерфейсы для различных устройств с минимальными усилиями. Полная автоматизация дизайна, где ИИ будет самостоятельно создавать адаптивные интерфейсы на основе предпочтений и потребностей пользователя, также представляется весьма вероятной. Однако это требует дальнейшего развития технологий и решения проблем, связанных с точностью и предсказуемостью действий ИИ.

## Заключение

Интеллектуальные инструменты играют важную роль в современном процессе создания адаптивных веб-дизайнов. Они позволяют автоматизировать рутинные задачи, повысить уровень персонализации и улучшить доступность веб-сайтов для пользователей с различными потребностями, в том числе для пользователей с ограниченными возможностями.

## Библиографический список

1. Percentage of mobile device website traffic worldwide from 1st quarter 2015 to 4th quarter 2023. URL: <https://www.statista.com/statistics/277125/share-of-website-traffic-coming-from-mobile-devices/> (дата обращения: 10.08.2024).
2. Disability // World Health Organization. URL: <https://www.who.int/news-room/fact-sheets/detail/disability-and-health> (дата обращения: 12.08.2024).
3. Adobe XD объявляет о новых интеграциях с искусственным интеллектом URL: <https://www.designer.com/news/31948> (дата обращения: 12.08.2024).
4. Design more, resize less, with Auto Layout. URL: <https://www.figma.com/blog/announcing-auto-layout/> (дата обращения: 15.08.2024).
5. How to Meet WCAG. URL: <https://www.w3.org/WAI/WCAG22/quickref/?versions=2.1> (дата обращения: 12.08.2024).

*Д. А. Кузнецов*

магистрант

Санкт-Петербургский государственный университет аэрокосмического приборостроения

АО «Обуховский завод»

## УНИФИЦИРОВАННАЯ АНАЛИТИЧЕСКАЯ ПЛАТФОРМА НА БАЗЕ МАРШРУТНОГО ТРАНСПОРТА КАК СРЕДСТВО ПОЛУЧЕНИЯ ИНФОРМАЦИИ О СОСТОЯНИИ ГОРОДСКОЙ ИНФРАСТРУКТУРЫ

Технологии видеоаналитики успешно и эффективно применяются городскими службами для контроля городского хозяйства. Устанавливаются умные камеры видеонаблюдения, оснащенные системами анализа видео с применением ИИ. Внедряются автономные мобильные комплексы нейросетевого наблюдения. Все это позволяет отслеживать такие нарушения правил благоустройства города, как граффити на стенах нежилых домов, размещенные на фасадах кондиционеры и ямы на проездах во дворах.

Однако в масштабах мегаполиса разворачивание интеллектуальных систем видеонаблюдения требует немалых временных и финансовых ресурсов. В связи с этим целесообразно рассмотреть возможность модификаций существующих систем видеонаблюдения до уровня, позволяющего наблюдать за состоянием городской инфраструктуры и сообщать полученную информацию в профильные службы в автоматизированном режиме.

**Ключевые слова:** унифицированная платформа, нейросетевая видеоаналитика, распознавание образов маршрутное транспортное средство, нестандартный метод наблюдения, городская инфраструктура.

*D. A. Kuznetsov*

Postgraduate Student

St. Petersburg State University of Aerospace Instrumentation

Obukhov State Plant

## UNIFIED ANALYTICAL PLATFORM BASED ON ROUTE TRANSPORT AS A MEANS OF OBTAINING INFORMATION ABOUT URBAN INFRASTRUCTURE

Video analytics technologies are successfully and effectively used by city services to control the urban economy. Smart video surveillance cameras equipped with AI video analysis systems are being mounted. Autonomous mobile neural network surveillance systems are being introduced. All this allows you to track violations of the rules of urban improvement, such as graffiti on the walls of non-residential buildings, air conditioners placed on facades and pits on driveways in courtyards.

However, on the scale of a megalopolis, the deployment of intelligent video surveillance systems requires considerable time and financial resources. In this regard, it is advisable to consider the possibility of modifying existing video surveillance systems to a level that allows monitoring the state of urban infrastructure and reporting the information received to specialized services in an automated mode.

**Keywords:** unified platform, neural network video analytics, image identification, route vehicle, non-standard surveillance method, urban infrastructure.

### Введение

Количество камер в российских регионах, оснащенных системами анализа видео с применением нейросетевой видеоаналитики, неуклонно растет. По оценкам Министерства цифрового развития, связи и массовых коммуникаций, в российских городах уже работает более 1 млн камер [1]. К концу 2023 г. только в Санкт-Петербурге их насчитывалось порядка 90 000 шт., что составляет 14,5 устройств на 1000 петербуржцев. В Москве на 1000 жителей приходилось 16,8 видеокamer. Согласно информации от министра цифрового развития России Максута Игоревича Шадаева, к 2030 г. количество камер на базе ИИ вырастет до 5 млн [2].

В первую очередь работа камер видеонаблюдения направлена на обеспечение вопросов безопасности, координацию работ служб и ведомств. По мере развития информационных технологий системы анализа видео с применением ИИ активно стали внедряться в сектор городского хозяйства, где требуется оперативно получать информацию о состоянии городской инфраструктуры и в случае выявления несоответствий оперативно реагировать.

Важно отметить положительный эффект от применения систем анализа видео в городском хозяйстве. Например, снижается количество посторонних графических изображений на фасадах частных зданий благодаря комплексу нейросетевой видеоаналитики «Городовой», который применяет в работе Государственной административно-технической инспекции (ГАТИ) Санкт-Петербурга. Зная, что за их имуществом следит умная система, владельцы частных зданий стали тщательнее смотреть за внешним видом своей собственности. Комплекс «Городовой» с июня 2023 г. по май 2024 г. зафиксировал более 10 тыс. потенциальных нарушений.

## Анализ существующих практик получения информации о состоянии городской среды

В условиях городской агломерации наблюдение за окружающей средой – довольно трудоемкий процесс. Здесь задействованы как специальные службы, так и городские жители. Существует возможность сообщить информацию о нарушениях по удобным каналам обратной связи: в Москве – портал «Активный гражданин» [3], в Санкт-Петербурге – через Комитет по благоустройству и дорожному хозяйству по специальному телефону, а в случае неисправности по наружным инженерным сетям – в сбытовые компании ГУП «Топливо-энергетический комплекс Санкт-Петербурга», ГУП «Водоканал Санкт-Петербурга» через портал организаций или специальным телефоном. В целом по России с замечанием можно обратиться через портал государственных услуг России «Госуслуги» [4].

С учетом трудоемкости процесса наблюдения и задействования больших человеческих ресурсов в сфере городского хозяйства с 2022 г. начали активно внедряться системы с использованием искусственного интеллекта для выявления в автоматическом режиме дефектов городской инфраструктуры. Системы с нейросетевой аналитикой в городской среде строятся на базе двух решений:

- а) на основе стационарных камер видеонаблюдения;
- б) на основе мобильных комплексов нейросетевой аналитики.

Информация с видеокамер поступает в центр обработки и хранения данных и обрабатывается программным модулем в онлайн-режиме.

Решение мобильного комплекса нейросетевой аналитики представлено компанией Softlogic Rus. Интеллектуальная система цифрового контроля на базе искусственных нейронных сетей включает автономный мобильный комплекс нейросетевой видеоаналитики, который осуществляет анализ видеопотоков непосредственно на борту транспортного средства при его движении. Система автоматически фиксирует отклонения в состоянии объектов дорожной инфраструктуры и прилегающей территории. В случае фиксации отклонения от эталона комплекс передает информацию о нарушении (фотоснимок и метаданные) в облачную платформу управления. Информация передается через каналы сотовой связи. Встроенные модули ГНСС легализовывают зафиксированные нарушения на карте.

## Модификация действующих систем видеонаблюдения до аналитического уровня

Основная часть городских умных систем видеонаблюдения приходится на Москву, Санкт-Петербург, Анапу, Московскую и Липецкую области, Казань, Новосибирск, Южно-Сахалинск [1]. В других регионах России умные системы пока не получили широкого распространения, поскольку их реализация требует технических и финансовых ресурсов. «Сложные детекторы могут стоить и 300 000 руб. на одну камеру», – заявляет архитектор Softline Digital Александр Костиков [1]. Дополнительно сюда будут включаться затраты на телекоммуникационные услуги по передаче данных между устройствами мониторинга объектов и центром обработки и хранения данных.

Стоимость автономного мобильного комплекса нейросетевого наблюдения от компании Softlogic составляет 2 856 566 руб. по данным завершившегося 22.01.2024 г., тендера, размещенного в информационной системе в сфере закупок zakupki.gov.ru. Это без учета издержек на эксплуатацию.

С учетом сказанного, масштаба мегаполиса, стоимости затрат на внедрение для регионов в качестве дополнения к существующей городской умной системе видеонаблюдения рассматривается к разработке технология унифицированной аналитической платформы (далее – УАП), развернутой на базе маршрутного транспортного средства (далее – ТС).

ТС предлагается двух видов:

а) **маршрутный городской автобус** – для осуществления наблюдения за инфраструктурой в пределах проезжей части;

б) **мусоровоз** – для наблюдения за инфраструктурой дворовой территории.

Использование системы видеоаналитики на базе ТС имеет ряд достоинств:

- а) большой охват городских дорог, попадающих в поле наблюдения УАП;
- б) наблюдение за дворовой территорией, за промышленными районами;
- в) возможность выявления дефекта на ранней стадии;
- г) низкая стоимость за счет использования существующего бортового оборудования (видеокамера, канал передачи информации, ГНСС, вычислительные и накопительные мощности);
- д) универсальность;
- е) отсутствие эксплуатационных затрат на содержание системы.

Разворачивание системы видеонаблюдения на базе маршрутного автобуса позволит муниципалитету снизить затраты на внедрение городских умных систем видеонаблюдения, высвободить действующие комплексы под «горячие» районы. Компания, занимающаяся вывозом бытовых отходов, сможет собирать «цифровой» мусор.

## Возможные сценарии применения УАП

УАП на базе ТС в автоматизированном режиме осуществляет сбор, анализ и систематизацию сведений о состоянии объектов городской инфраструктуры в части:

- появления (наличия) на поверхности дорожного покрытия трещин, ям, оценки динамики их развития (рис. 1);
- качества дорожной разметки (рис. 2);
- размещения на дорожных знаках, перекрестках, проезжей части дорог рекламной и иной информационной печатной продукции [5–9];





Рис. 1. Трещины на дорожном полотне




Рис. 2. Стертая дорожная разметка

- открытых инженерных люках на дорожной части (рис. 3);
- испорченных дорожных знаков;
- переполнения остановочных мусорных баков;
- получения оперативной информации об образовании сосулек на крышах зданий;
- неправильной парковки автомобилей во дворах, препятствующих проезду специального транспорта

(рис. 4).



Рис. 3. Открытые люки




Рис. 4. Неправильная парковка при въезде в ДДУ

### Заключение

Использование мобильных видеокамер, расположенных на городском транспорте, органично дополнит систему стационарных видеокамер с функциями слежения за состоянием инфраструктуры города.

Предложенные технические решения по созданию дополнительного канала получения оперативной информации о состоянии городской инфраструктура на базе маршрутных ТС и выделенные особенности существующих практик и тенденций их развития позволят эффективно применять нейросетевую аналитику для выявления проблемных мест по маршрутам следования ТС.

### Библиографический список

1. Устинова А. Петербург установил 20 000 видеокамер с искусственным интеллектом // Ведомости. URL: <https://www.vedomosti.ru/technology/articles/2023/12/14/1010957-peterburg-ustanovil-20-000-videokamer-s-iskusstvennim-intellektom> (дата обращения: 26.05.2024).
2. Финальный вариант нацпроекта «Экономика данных» подготовят летом 2024 года // Министерство цифрового развития, связи и массовых коммуникаций РФ. URL: <https://digital.gov.ru/ru/events/48369/> (дата обращения: 26.05.2024).
3. Активный гражданин: площадка для проведения электронных голосований среди жителей столицы. URL: <https://ag.mos.ru/home> (дата обращения: 26.05.2024).
4. Госуслуги: портал государственных услуг. URL: <https://www.gosuslugi.ru/> (дата обращения 22.01.2024).
5. Закон Санкт-Петербурга от 31.05.2010 № 273-70 «Об административных правонарушениях в Санкт-Петербурге». URL: <https://gu.spb.ru/laws/71180/> (дата обращения: 28.09.2024).
6. Постановление Правительства Российской Федерации от 26.09.2016 г. № 969 «Об утверждении требований к функциональным свойствам технических средств обеспечения транспортной безопасности и правил обязательной сертификации технических средств обеспечения транспортной безопасности». URL: [https://www.consultant.ru/document/cons\\_doc\\_LAW\\_205190/](https://www.consultant.ru/document/cons_doc_LAW_205190/) (дата обращения: 28.09.2024).
7. Технологический регламент производства работ по содержанию автомобильных дорог регионального значения в Санкт-Петербурге. Утвержден распоряжением Комитета по благоустройству Санкт-Петербурга от 28.03.2022 № 74-р. URL: <https://base.garant.ru/408474133/53f89421bbdaf741eb2d1ecc4ddb4c33/> (дата обращения: 28.09.2024).
8. ГОСТ Р 50597–2017 «Автомобильные дороги и улицы. Требования к эксплуатационному состоянию, допустимому по условиям обеспечения безопасности дорожного движения» (Утвержден и введен в действие приказом Федерального агентства по техническому регулированию и метрологии от 26 сентября 2017 г. № 1245-ст). URL: [https://www.mos.ru/upload/documents/files/2215/GOSTR50597-2017\(1\).pdf](https://www.mos.ru/upload/documents/files/2215/GOSTR50597-2017(1).pdf) (дата обращения: 28.09.2024).
9. Приказ Минтранса России от 16.11.2012 № 402 «Об утверждении Классификации работ по капитальному ремонту, ремонту и содержанию автомобильных дорог». URL: <https://mintrans.gov.ru/documents/7/2911> (дата обращения: 28.09.2024).

*А. С. Латынов\**

студент

*В. А. Миклуш\**

кандидат технических наук, доцент – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ГЕНЕРАЦИЯ ПЕРСОНАЛИЗИРОВАННОЙ РЕКЛАМЫ НА ОСНОВЕ ПОИСКОВЫХ ЗАПРОСОВ

Представлены алгоритмы и технологии, используемые для генерации персонализированной рекламы, даны преимущества персонализированной рекламы: повышение релевантности рекламных предложений и улучшение пользовательского опыта, – выделены основные проблемы.

**Ключевые слова:** персонализированная реклама, поисковые запросы, машинное обучение, искусственный интеллект, ретаргетинг, ремаркетинг.

*A. S. Latypov\**

Student

*V. A. Miklush\**

PhD, Tech., Associate Professor – Scientific Adviser

\*St. Petersburg State University of Aerospace Instrumentation

## GENERATING PERSONALIZED ADS BASED ON SEARCH QUERIES

The paper presents the algorithms and technologies used to generate personalized advertising, gives the advantages of personalized advertising: increasing the relevance of advertising offers and improving user experience, and highlights the main problems.

**Keywords:** personalized advertising, search queries, machine learning, artificial intelligence, retargeting, remarketing.

### Введение

Персонализированная реклама – это вид цифровой рекламы, которая адаптируется под интересы и поведение конкретного пользователя на основе данных о его активности в Интернете, таких как поисковые запросы и история просмотров. В отличие от традиционной рекламы, которая ориентирована на массовую аудиторию, персонализированные объявления создаются с учетом индивидуальных предпочтений пользователя, делая рекламу более релевантной и эффективной.

### Значение персонализации в цифровой рекламе

Персонализация рекламы играет ключевую роль в повышении конверсии и улучшении пользовательского опыта. Люди более склонны взаимодействовать с рекламой, которая кажется им актуальной. Современные технологии анализа данных и искусственного интеллекта позволяют адаптировать рекламные кампании под каждого пользователя, что повышает их эффективность. Однако, наряду с преимуществами, персонализированная реклама вызывает озабоченность в вопросах конфиденциальности, требуя от компаний соблюдения законодательства о защите данных и этических норм.

### Формирование персонализированной рекламы, сбор данных о поисковых запросах

Поисковые системы и рекламные платформы собирают данные о поисковых запросах пользователей с помощью файлов cookies и технологий отслеживания. Каждый запрос фиксируется вместе с информацией о времени, местоположении и предыдущей активности пользователя. Эти данные анализируются с использованием алгоритмов машинного обучения для выявления интересов и поведения пользователя [1].

### Преобразование данных в персонализированную рекламу

На основе собранных данных формируется профиль пользователя. Алгоритмы обрабатывают информацию, чтобы создавать релевантные рекламные объявления. Например, если пользователь ищет фитнес-товары, ему показываются объявления о спортивном оборудовании. Реклама подбирается в реальном времени и адаптируется к интересам пользователя, повышая вероятность взаимодействия с ней [2].

### Генерация персонализированной рекламы

Алгоритмы и технологии, используемые для генерации персонализированной рекламы.

*Машинное обучение и искусственный интеллект.* Алгоритмы машинного обучения и ИИ анализируют данные пользователей, выявляют паттерны поведения и помогают строить профили. Эти технологии автоматически подбирают наиболее релевантную рекламу на основе предпочтений пользователя, его поисковых запросов и прошлой активности.

*Использование cookies и пикселей отслеживания.* Cookies и пиксели отслеживания собирают информацию о действиях пользователя в Интернете: какие сайты он посещает, что ищет и с чем взаимодействует. Эти данные позволяют рекламным платформам показывать целевые объявления, даже если пользователь перемещается между разными сайтами.

*Ретаргетинг и ремаркетинг.* Эти техники используются для повторного взаимодействия с пользователями. Ретаргетинг показывает рекламу людям, которые уже взаимодействовали с сайтом или продуктом, напоминая им о товарах в корзине или услугах, которые они искали. Ремаркетинг работает схожим образом, ориентируясь на повторные показы рекламы пользователям, которые проявили интерес к бренду ранее.

Преимущества персонализированной рекламы:

– повышение релевантности рекламных предложений. Персонализированная реклама позволяет показывать объявления, которые более точно соответствуют интересам пользователя. Например, если человек искал в Интернете информацию о велосипедах, ему могут быть предложены объявления о продаже велосипедов или аксессуаров для них. Исследования показывают, что такие подходы увеличивают вероятность кликов и конверсий. Исследование McKinsey отмечает, что компании, использующие персонализацию, могут увеличить доход на 5–15% [3];

– улучшение пользовательского опыта. Таргетированная реклама не перегружает пользователя ненужными объявлениями, что улучшает его взаимодействие с контентом. Вместо того чтобы получать случайные рекламные предложения, пользователь видит только то, что соответствует его интересам. Например, «Яндекс Музыка» предлагает персонализированные рекомендации на основе прослушанной музыки, что повышает лояльность к платформе и уменьшает раздражение от нерелевантного контента [4].

### **Проблемы, вызовы и будущее персонализированной рекламы**

Персонализированная реклама сталкивается с несколькими важными вызовами, которые могут повлиять на ее эффективность и восприятие пользователями. Один из ключевых проблемных аспектов – точность алгоритмов. Неверные прогнозы или ошибки в анализе данных могут привести к тому, что реклама оказывается нерелевантной для пользователя. Такие ситуации, как неуместные предложения или рекламные объявления, которые не соответствуют интересам, вызывают у пользователей раздражение и снижают доверие к бренду. Это подчеркивает важность улучшения алгоритмов и использования более сложных технологий, которые смогут учитывать нюансы поведения пользователя и лучше предсказывать его потребности.

Еще один вызов для индустрии – противодействие блокировкам рекламы. С ростом популярности ad block рекламодатели теряют доступ к аудиториям, которые активно избегают любых рекламных материалов. Это ограничивает возможности даже высококачественных персонализированных кампаний и снижает их эффективность. Для борьбы с этой проблемой компании разрабатывают новые способы доставки рекламы, включая ненавязчивые форматы или интеграцию рекламных элементов в контент.

### **Заключение**

Несмотря на вызовы, будущее персонализированной рекламы связано с развитием технологий. Совершенствование алгоритмов искусственного интеллекта и использование новых моделей анализа данных, таких как контекстуальный таргетинг и когнитивные алгоритмы, позволит значительно повысить точность и эффективность рекламных кампаний. Эти технологии смогут учитывать не только предыдущие действия пользователя, но и его текущее эмоциональное состояние, контекст запроса и многие другие факторы, что сделает рекламу более точной и полезной.

### **Библиографический список**

1. Татарникова Т. М., Богданов П. Ю. Построение психологического портрета человека с применением технологий обработки естественного языка // Научно-технический вестник информационных технологий, механики и оптики. 2021. Т. 21, №1. С. 85–91.
2. Персонализация рекламы – эффективные способы привлечь клиентов. URL: <https://mindbox.ru/journal/education/personalizaciya-reklamy/> (дата обращения: 27.08.2024).
3. The business value of design. URL: <https://www.mckinsey.com/capabilities/mckinsey-design/our-insights/the-business-value-of-design> (дата обращения: 20.08.2024).
4. Как работают рекомендации Яндекс Музыка. URL: <https://music.yandex.ru/recommendations> (дата обращения: 29.08.2024).

*Ж. Н. Маслова*

доктор филологических наук, доцент

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ВОЗМОЖНОСТИ ПРИМЕНЕНИЯ ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ОБЛАСТИ МАШИННОГО ПЕРЕВОДА

Рассмотрены основные возможности применения технологии искусственного интеллекта в области машинного перевода. Произведен анализ состояния проблемы в данной области, перечислены основные технологии, рассмотрены их достоинства и недостатки.

**Ключевые слова:** искусственный интеллект, машинный перевод.

*Zh. N. Maslova*

Dr. Sc., Philology, Associate Professor

St. Petersburg State University of Aerospace Instrumentation

## THE POTENTIAL OF ARTIFICIAL INTELLIGENCE TECHNOLOGY IN MACHINE TRANSLATION

The paper considers the main possibilities of application of artificial intelligence technology in the field of machine translation. The analysis of the state of the problem in this field, listed the main technologies, considered their merits and shortcomings.

**Keywords:** artificial intelligence, machine translation.

Технические решения давно и прочно укоренились в гуманитарной сфере, где они обеспечивают автоматизацию тех процессов, которые долгое время выполнялись человеком. Один из актуальных вопросов, который давно решается с помощью инноваций, – преодоление языковых барьеров и повышение эффективности международной коммуникации. Автоматизация перевода развивается со второй половины XX в., но внедрение технологии искусственного интеллекта открывает новые перспективы перед лингвистами и инженерами.

Анализ состояния проблемы в данной области показал, что количество и особенности программ и инструментов для перевода отражают многообразие нужд пользователей. Это значит, что одна универсальная программа перевода не может удовлетворить все коммуникативные потребности и специфика языка варьируется в зависимости от сферы применения [1].

Проблема автоматизированного перевода имеет разные направления развития, отраженные в комплексе технических решений, которые позволяют людям достигать более эффективной коммуникации в повседневной и профессиональной жизни. Например, это технология распознавания изображений с последующим переводом (Google Lens, <https://lens.google/intl/ru/>). Область применения этого инструмента включает быстрый перевод вывесок, документов, меню, но мало подходит, например, для перевода художественного текста.

При чтении сайтов на иностранном языке используются Google Translate (<https://translate.google.com>), «Яндекс Переводчик» (<https://translate.yandex.ru/ocr>). Переводить объемные тексты разных жанров помогает DeepL (<https://www.deepl.com/ru/translator>), он подходит для бизнеса и для частного использования. Существуют программные продукты, широко используемые в узкоспециальных сферах деятельности. Например, Alexa Translations (<https://alexatranslations.com/>) – программное обеспечение (ПО) для перевода юридических, финансовых и технических документов. Mirai Translate (<https://miraitranslate.com/en/>) предназначен для деловой сферы, так как поддерживает функцию перевода речи и имеет возможность создания пользовательского словаря для перевода текста и файлов по группам. Сервис Sonix (<https://sonix.ai/ru>) подходит для создания видеоконтента. Этот переводчик широко используется в образовательной сфере, так как позволяет конвертировать видео, учебные пособия или подкасты на другие языки.

Ключевой проблемой остается качество перевода. Несмотря на достигнутые успехи не все языки поддаются успешному переводу из-за их типологического различия. Важна и природа языка. Язык является не только средством общения между людьми. Он непосредственно связан с мышлением, обеспечивает материальное оформление мыслей и обмен информацией между людьми. Кроме того, язык является средством воспроизведения, восприятия, хранения, передачи знания, а также формирования нового знания. Еще одна трудность адаптации языкового материала к машинному переводу в том, что язык возник в результате телесного опыта взаимодействия человека с внешней средой, развития его сознания и общественных отношений.

Изначально следование человеческой природе в разработке алгоритмов не было доминирующим. В 1970–1980-е гг. XX в. получил развитие машинный перевод на основе правил (Rule-Based Machine Translation). На этом этапе была разработана формальная модель, где естественный язык понимался как устройство, обеспечивающее переход от смысла к тексту. Построение текста при этом происходило в результате нескольких пере-

ходов от уровня к уровню [2]. Получение грамматически правильного пословного перевода в машинных переводах этого периода осуществлялось на основе синтаксических и семантических признаков слов, включенных в состав двуязычных словарей [2].

Однако только синтактико-семантический пословный машинный перевод не может быть продуктивен, так смысл высказывания не равен смыслу составляющих его слов и не может быть выведен на основе лишь синтактико-семантических признаков слов.

Исходя из этого основным направлением совершенствования машинного перевода стало моделирование процессов понимания и генерации текста на языке аналогичных человеческому сознанию. Однако у человека эти процессы связаны с экстралингвистическими факторами, которые трудно или невозможно учесть при машинном переводе. Не только устное высказывание связано с контекстом, в каждом тексте есть определенный подтекст умолчания, или пресуппозиция [3]. Кроме того, любой письменный текст и воспроизводимая речь имеют линейную структуру, в то время как порождаемые ими смыслы многомерны.

Концепция статистического машинного перевода (Statistical Machine Translation) была реализована в начале 1990-х г. На смену словарям и правилам пришли корпуса параллельных текстов, так как машинный перевод основан на корпусных данных. На основе корпуса текстов создавалась модель перехода (transition model), в которой вычислялась вероятность правильности перевода слова или фразы [4]. Дополнением к этому служила модель выравнивания слов для установления соответствия между языковыми фрагментами исходного и целевого языков. Позднее в компании IBM была разработана модель фразового перевода, которая основывается на распределении вероятностей разных целевых вариантов перевода исходной фразы. Число комбинаций в этом случае эффективно ограничивается синтаксической моделью исходного предложения. С 2006 г. данная модель использовалась компаниями Google и «Яндекс» [4]. Переводы, полученные таким образом, не были полностью грамматически согласованы. Лингвистический аспект был учтен не полностью.

Современная стадия развития машинного перевода – нейронный машинный перевод (Neural Machine Translation). Общей тенденцией последних лет является объединение технологии машинного перевода с искусственным интеллектом, использование нейросетей. Neural Machine Translation (NMT) – это подход к машинному переводу, в котором используется большая искусственная нейронная сеть. Он основан на сети нейронов, аналогичной той, которая существует в мозге человека. Данная сеть может создавать контекстные связи между словами и отдельными фразами, она также способна изучать правила языка. На основе правил сеть создает статистические модели, которые помогают строить качественные предложения. При переводе каждое слово в предложении кодируется в число, получается последовательность, которая передается в нейронную сеть. Далее на основе языковых правил происходит генерация чисел перевода, числа потом преобразуются в слова переведенного текста.

Таким образом, сегодня процесс перевода не в сравнении, а в обучении на параллельных текстах. Глубокое обучение сети заключается в обработке текстов исходного и целевого языка набором логических правил, поэтому ключевую роль здесь играет предварительное обучение. Примером сервисов, где используется модель NMT могут служить Wordvice AI (<https://wordvice.ai/>) – онлайн-переводчик на основе искусственного интеллекта – и Taia (<https://taia.io/>), сочетающий технологии искусственного интеллекта и труд опытных переводчиков [5].

В настоящее время с помощью автоматических переводчиков достаточно хорошо переводятся новостные или публицистические материалы, т. е. тексты, лексика которых является доступной и широко распространенной. Поддаются адекватному переводу общетехнические и гуманитарные тексты. Однако трудности возникают с техническим языком, многозначными словами. Важны и типологические различия языков: например, языки сино-тибетской языковой семьи существенно отличаются от германских.

Синхронный и последовательный перевод осуществляется переводчиками-людьми, потому что высока вероятность неправильной интерпретации слов. В этой сфере традиционный перевод пока не может быть заменен искусственным интеллектом, так как перевод встроен в контекст ситуации. Именно пресуппозицию, которая играет здесь важную роль, машинный перевод игнорирует. На сегодняшний день не удалось связать нейросети с опытом телесности и эмоций человека, а также интегрировать в перевод ту информацию, которая хранится в памяти человека в аналоговом виде – в виде образов.

Помимо ассоциативной природы человеческого сознания, при машинном переводе трудно учесть темп обновления языка, появление новых слов и контекстов. Эти две вещи напрямую связаны, потому что обновления в языке обусловлены способностью человека устанавливать новые ассоциативные связи, порождать новые смыслы и новые языковые единицы, хотя согласно некоторым исследованиям, «базовые знания учитываются в подходе MFT (Machine Phraseological Translation). Именно в его рамках предпринимаются попытки формализации и автоматического формирования тематических баз данных, пока только в виде тематических онтологий» [6].

Еще одной областью с низкой эффективностью машинного перевода является корпус естественно-научных статей, где представлено новое, «выводное» знание. И традиционно самый сложный для автоматической обработки художественный текст. Лучше всего переводу поддаются грамматические особенности авторского стиля, например парцелляция. Гораздо больше страдает языковая игра, особенно фонетическая, и переносные значения (метафоры, метонимии, символы) [7].

В результате машинного обучения возникает возможность некоторой имитации человеческого взаимодействия с окружающей реальностью, хотя искусственный интеллект также не обладает возможностью телесного переживания. Тем не менее преодоление языковых барьеров становится более эффективным в разных сферах.

Все большее количество языков получает техническую поддержку, машинные переводчики интегрируются с разными платформами и приложениями. Кроме того, достигается большая релевантность перевода в зависимости от сферы деятельности. Тенденция развития такова, что по мере развития ИИ инструменты перевода станут все более совершенными, влияя на глобальное общение. Возможно, продуктивным направлением станет изучение возможности интеграции аналоговых образов, содержащих контекст, в модели машинного анализа текстов.

#### Библиографический список

1. *Соколова Н. В.* Машина против человеческого перевода в синергетическом переводческом пространстве // Научный журнал Волгоградского государственного университета. Лингвистика. 2021. Т. 20, № 6. С. 89–98.
2. *Бохаева А. С.* Разработка и исследование систем нейронного машинного перевода с русского на казахский язык. Вопросы науки и образования. 2019. № 4(49). С. 58–62.
3. *Звегинцев В. А.* Предложение и его отношение к языку и речи. М.: Изд-во МГУ им. М.В. Ломоносова, 1976. 308 с.
4. Искусственный интеллект в технологиях машинного перевода / К. К. Колин, А. А. Хорошилов, Ю. В. Никитин [и др.] // Социальные новации и социальные науки. 2021. № 2(4). С. 64–80.
5. *Tian Zhaolin, Zhang Weiwei.* Sequence-to-sequence based english-chinese translation model // Информатика, телекоммуникации и управление. 2018. № 11(2). С. 55–63.
6. *Хорошилов А-р А., Кан А. В., Хорошилов А. А.* Фразеологический машинный перевод. М.: Директ Медиа, 2019. 467 с.
4. *Хабарова Е. М.* Машинный перевод выразительных средств – метафор // Философские проблемы информационных технологий и киберпространства. 2023. № 2. С. 108–119.



*П. Г. Мельник\**

аспирант

*В. А. Светличная\**

кандидат технических наук

*Т. А. Васяева\**

кандидат технических наук – научный руководитель

\*Донецкий национальный технический университет

## МЕТОДЫ УЛУЧШЕНИЯ ЭФФЕКТИВНОСТИ АЛГОРИТМОВ БЫСТРОРАСТУЩИХ ДЕРЕВЬЕВ ДЛЯ ТРЕХМЕРНОГО ПРОСТРАНСТВА

Задача поиска маршрута в произвольном конфигурационном пространстве встречается во множестве областей применения, от робототехники до решения задач оптимизации. Наиболее универсальным решением по праву считаются алгоритмы быстрорастущих случайных деревьев (Rapidly-exploring Random Trees, RRT). Однако изначальный алгоритм имеет ряд недостатков, проанализированных в статье. Также рассматривается одна из модификаций алгоритма, после чего предлагается ряд модификаций с целью улучшения эффективности. Приведены результаты первичного тестирования данных оптимизаций и их анализ.

**Ключевые слова:** поиск пути, RRT, эвристика, планирование движения, определение пересечений.

*P. G. Melnik\**

PhD Student

*V. A. Svetlichnaya\**

PhD, Tech.

*T. A. Vasiaeva\**

PhD, Tech. – Scientific Adviser

\*Donetsk National Technical University

## METHODS FOR IMPROVING THE EFFICIENCY OF RAPIDLY-EXPLORING RANDOM TREES ALGORITHMS FOR THREE-DIMENSIONAL SPACE

The problem of the path searching in an arbitrary configuration space is often met in a great amount of application areas ranging from robotics to optimization problems. As the methods of solution are in progress, the families of the algorithms arise, being adopted to concrete situations. Rapidly-exploring Random Trees algorithm, RRT, is considered to be the most universal one. But the initial algorithm has a number of drawbacks analyzed in the paper. A modification of the algorithm is presented and a set of additions is proposed to enhance the efficiency. The results of the primary testing are listed and analyzed.

**Keywords:** path searching, RRT, heuristics, motion planning, fixation of intersections.

### Введение

В настоящее время планирование движения и траектории на основе дискретных значений – крайне важная задача. Среди наиболее широко используемых методов можно выделить семейство быстрорастущих случайных деревьев (Rapidly-exploring Random Trees, RRT) [1]. Нахождение пути от начальной до конечной точки достигается за счет случайного расширения дерева в конфигурационном пространстве.

Однако алгоритмы RRT обладают рядом недостатков. К ним можно отнести лавинообразное увеличение количества вершин в задачах большой размерности, а также в задачах с большим пространством конфигураций, включающим множество препятствий. При добавлении большого количества вершин в дерево поиска сильно увеличивается время каждой последующей итерации [2]. Поиск ближайшего соседа обычно полагается не на аналитический, а на наивный метод полного перебора. Как и любое наивное решение, оно достаточно далеко от оптимальности.

В качестве базисного алгоритма, от которого будем отталкиваться в поиске оптимизаций, было принято решение использовать алгоритм H-RRT [2] – модификацию базового поиска быстрорастущим деревом с использованием эвристической функции от расстояния до конечной точки. Был предложен и протестирован комплекс модификаций, которые позволяют существенно уменьшить аппаратные и временные затраты на поиск решения. В статье приводятся результаты тестирования модифицированного алгоритма относительно базовой реализации

### Эвристическая модификация алгоритма

В данной реализации H-RRT (Heuristic RRT) вводится дополнительный этап работы – математическая эвристическая оценка. Ее задача – изменить направление «роста» дерева поиска таким образом, чтобы направить

его к искомой точке вместо равномерного распределения пространства. Классическим решением для определения значения эвристической функции является использование следующей формулы:

$$m = 1 - \frac{C_V - C_{opt}}{C_{max} - C_{opt}},$$

где  $C_V$  – суммарная стоимость пути из начальной конфигурации в данную вершину и из данной вершины до целевой конфигурации,  $C_{opt}$  – предполагаемая стоимость оптимального пути из начальной конфигурации в целевую,  $C_{max}$  – максимальная стоимость пути до любой вершины дерева на текущем шаге.

В числителе данной формулы стоит отклонение от прямой линии между потенциальной и искомой точкой. Знаменатель представляет собой масштабирующий коэффициент, необходимый для нормирования результата. Именно такая оценка получила наибольшее распространение среди эвристических модификаций алгоритмов семейства RRT.

### Проблемы эвристического подхода

Основная проблема состоит в том, что эвристика подталкивает дерево поиска на движение прямо по направлению к цели. Таким образом, еще на этапе построения дерева часто упускаются варианты с обходом препятствий заранее, хотя эти пути могут быть более оптимальными, чем предложенный путь с прямой эвристикой.

Еще одной немаловажной проблемой становится тот факт, что эвристика не предлагает решения проблемы классического RRT, а именно засорения конфигурационного пространства не имеющими ценности вариантами ветвей, которые сильно замедляют скорость работы алгоритма с увеличением самого дерева поиска.

С учетом указанных недостатков стандартной эвристики [3] были разработаны и протестированы следующие улучшения алгоритма.

*Проверка плотности.* Цель проверки плотности – убедиться, что ветви и вершины не пересекаются друг с другом. Было принято решение остановиться на предоставлении каждой вершине еще одного параметра: радиуса покрытия. Идея заключается в том, что если мы представим, что каждый узел имеет радиус покрытия, то мы хотим, чтобы области покрытия каждой вершины не перекрывались. Достигается это путем простого расчета евклидова расстояния между новой вершиной и другими вершинами дерева поиска. Если расстояние меньше заданного параметра, мы отказываемся от этого узла.

*Модификация эвристической функции.* Помимо классического расстояния, указанного ранее, были добавлены параметры препятствий, через которые пролегает прямая линия от вершины до конечной точки. Учитывается количество препятствий, которые пересекает прямой путь [4], а также длина пути по этим препятствиям (суммарная толщина препятствий).

*Модификация процесса роста дерева.* По мере того, как дерево становится больше, на добавление следующей вершины будет уходить все больше времени. Чтобы избежать этих больших затрат, было предложено изменить процесс расширения дерева. Только после выявления 10 потенциальных точек для каждой из них происходит расчет эвристической функции. Узел с наилучшей эвристикой будет выбран в качестве следующего расширения.

### Тестирование

Для тестирования эффективности модификаций было принято решение сравнивать разработанный алгоритм с классическим однонаправленным RRT-алгоритмом. Также для более наглядной демонстрации алгоритмы будут запускаться в двухмерной среде, используя математический аппарат для трехмерного случая, лишь положив значение третьей координаты константе. Для оценки были разработаны несколько карт конфигурационного пространства. Для каждой карты запуск каждого алгоритма произведен 50 раз (рис. 1-3, таблица).




Рис. 1. Демонстрация работы алгоритмов на карте 1




Рис. 2. Демонстрация работы алгоритмов на карте 2

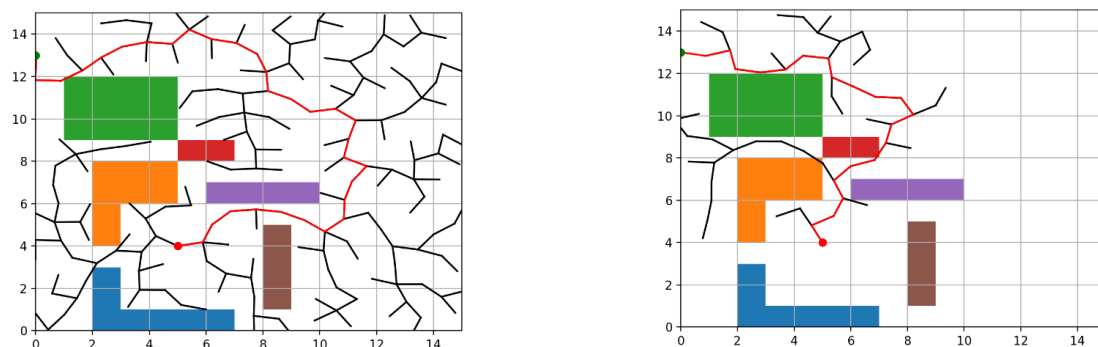


Рис. 3. Демонстрация работы алгоритмов на карте 3

Таблица результатов тестирования

Параметр	Карта 1		Карта 2		Карта 3	
	Базовый RRT	Модифицированный RRT	Базовый RRT	Модифицированный RRT	Базовый RRT	Модифицированный RRT
$T$ вып. (с)	1.019	0.319	1.836	0.791	1.836	0.791
Кол-во вершин	505	63	413	218	413	218

### Выводы

Как видно из результатов тестирования, разработанные модификации сильно (более чем в два раза) повышают общую эффективность классического RRT алгоритма. Минимум вдвое был уменьшен размер самого дерева поиска, что может оказаться принципиальным для устройств с малым количеством оперативной памяти. Также примерно в три раза было уменьшено общее время выполнения работы алгоритма, что может быть принципиальным для систем, работающих в режиме около-реального времени. Подобные результаты были достигнуты благодаря модификации функции эвристики и введением принципиально нового этапа в ходе его работы: расчета областей исследования вершин.

Также важным является тот факт, что эвристическая функция при работе была вынесена в отдельную сущность, что позволит в дальнейшем еще сильнее оптимизировать алгоритм, так как в данной статье работа с эвристикой была не раскрыта до полного потенциала. Результаты исследования позволяют предположить полезность подобных модификаций алгоритма для любых сфер его применения.

### Библиографический список

1. Мельник П. Г., Светличная В. А. Анализ методов поиска маршрута в произвольном пространстве // Информатика, управляющие системы, математическое и компьютерное моделирование (ИУСМКМ-24): XV Междунар. науч.-техн. конф. Донецк, 2024.
2. Казаков К. А., Семенов В. А. Обзор современных методов планирования движения // Труды ИСП РАН. 2016. Т. 28. С. 241–294.
3. Salzman O., Halperin D. Asymptotically near-optimal RRT for fast, high-quality, motion planning // Proc. 2014 IEEE International Conference on Robotics and Automation. 2014. P. 4680–4685.
4. RRT\*connect: Faster, asymptotically optimal motion planning / S. Klemm, J. Oberlander, A. Hermann [et al.] // 2015 IEEE Int. Conf. Robot. Biomimetics. 2015. P. 1670–1677.

*С. С. Митогуз\**

студент

*А. В. Аюева\**

студент

*Н. Л. Гречкин\**

старший преподаватель – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## РАСПОЗНАВАНИЕ ОБЪЕКТОВ В PYTHON С ИСПОЛЬЗОВАНИЕМ БИБЛИОТЕКИ IMAGEAI

Исследуется такой самообучающийся алгоритм, как искусственный интеллект: насколько важна его роль в современном мире и почему необходимо продолжать работать над его улучшением. Представлено описание алгоритма распознавания объектов искусственным интеллектом: показаны простейшая схема системы распознавания образов и принцип ее работы. Были рассмотрены три основных подхода, которые используются для построения систем распознавания образов, а также методы их реализации. Представлен один из вариантов использования системы распознавания образов искусственным интеллектом: определение объектов, находящихся на конвейерной ленте, а также процентное соотношение схожести этого объекта с его изображением, которое находится в имеющейся библиотеке. Решение данной задачи было осуществлено с помощью языка программирования Python и библиотеки ImageAI, которая была собрана специально для распознавания различных объектов.

**Ключевые слова:** искусственный интеллект, машинное обучение, самообучающийся алгоритм, распознавание образов, системы распознавания образов, язык программирования Python, библиотека ImageAI.

*S. S. Mitoguz\**

Student

*A. V. Ayueva\**

Student

*N. L. Grechkin\**

Senior Lecturer – Scientific Adviser

\*St. Petersburg State University of Aerospace Instrumentation

## RECOGNIZING OBJECTS IN PYTHON USING THE IMAGEAI LIBRARY

This article talks about such a self-learning algorithm as artificial intelligence: how important is its role in the modern world and why it is necessary to continue working on its improvement. The description of the algorithm of object recognition by artificial intelligence is presented: the simplest scheme of the pattern recognition system and the principle of operation of this system are shown. Three main approaches that are used to build pattern recognition systems have been considered, and the methods of implementation of the considered approaches have been shown. One of the variants of using the system of pattern recognition by artificial intelligence is presented: identification of objects that are on the conveyor belt, as well as the percentage of similarity of this object to its image, which is in the available library; the solution to this problem was implemented using the Python programming language and the ImageAI library, which was built specifically for the recognition of various objects.

**Keywords:** artificial intelligence, machine learning, self-learning algorithm, pattern recognition, pattern recognition systems, Python programming language, ImageAI library.

Искусственный интеллект (ИИ) сегодня – одна из самых обсуждаемых и быстро развивающихся технологий. Он способен анализировать огромные объемы данных, принимать решения на основе машинного обучения и адаптироваться к меняющимся условиям, что открывает перед нами новые горизонты возможностей. Вместо того чтобы вручную искать правила и строить модели на основе анализа больших объемов информации, машинное обучение предлагает более эффективный подход: постепенное улучшение прогнозных моделей и принятие решений, основанных на данных. Машинное обучение не только приобретает все большее значение в научных исследованиях, но и становится все более заметным в повседневной жизни.

Распознавание образов [1] относится к области машинного обучения и применяется в самых разных сферах, таких как анализ аэрокосмических изображений, обработка сигналов, медицинская диагностика, биология, социология, банковское дело и др. Основные понятия этого направления – образ и класс. Образ представляет собой описание объекта или процесса, которое позволяет выделить его из окружающей среды для принятия решений. Классы – это категории, на которые делятся образы в процессе распознавания.

Выделяют [2] три основных подхода к построению систем распознавания образов:

- 1) принцип сравнения с эталоном;
- 2) принцип общности свойств;
- 3) принцип кластеризации.

Одна из наиболее перспективных технологий для реализации этих подходов – язык программирования Python. Он получил широкое распространение в области машинного обучения и распознавания образов благодаря своей мощной и одновременно простой структуре, а также большому количеству библиотек, поддерживающих решение задач машинного обучения [3].

Рассмотрим каждый из перечисленных подходов более подробно.

**Принцип сравнения с эталоном.** Система распознавания сохраняет в памяти множество образов одного класса. При поступлении новых, неизвестных образов она сравнивает их с уже хранящимися образами и классифицирует их по тому классу, к которому принадлежал наиболее схожий эталон. Этот метод прост в реализации, но эффективен в условиях, когда выборка образов хорошо охватывает все возможные варианты, однако его эффективность снижается, если выборка далека от идеала.

**Принцип общности свойств.** Автоматическое распознавание происходит на основе выделения общих признаков объектов. Предполагается, что образы одного класса обладают общими характеристиками или признаками. Когда системе подается новый образ, она выделяет его признаки и сравнивает их с признаками, хранящимися в памяти. Этот метод более экономичен в плане использования памяти, поскольку требует хранения признаков, а не самих образов.

**Принцип кластеризации.** Если образы определенного класса представлены в виде векторов, их можно рассматривать как кластер и анализировать его свойства в пространстве образов. Построение системы распознавания зависит от пространственного расположения кластеров. Сложность алгоритмов варьируется в зависимости от удаленности кластеров друг от друга.

Основными для реализации упомянутых подходов являются три группы методов: эвристические, математические и лингвистические (синтаксические). Также возможны их комбинации.

**Эвристические методы.** Основываются на субъективных оценках и опыте для определения членов класса и общих свойств. При разработке систем распознавания с использованием эвристических методов разрабатываются специфические процедуры для конкретных задач. Эти методы играют важную роль, но их обобщение затруднительно из-за необходимости применения специализированных алгоритмов. Эффективность метода зависит от опыта и квалификации разработчиков.

**Математические методы.** Основное внимание уделяется правилам классификации, выведенным в общем виде. Математические методы делятся на статистические и детерминированные. Статистические используют правила классификации, основанные на математической статистике, например байесовское классификационное правило. Детерминированные методы опираются на математическое описание без статистических методов.

**Лингвистические методы.** Применяются для описания образов с помощью подобразов и их взаимосвязей, формируя иерархическую структуру, аналогичную синтаксической структуре языка. Поэтому лингвистические методы также называют синтаксическими. Они позволяют использовать теорию формальных языков для построения систем распознавания образов. Важные элементы включают выбор элементов для построения образа, их объединение в грамматики и реализацию процессов анализа и распознавания.

Теперь рассмотрим общую структуру простой системы распознавания образов, использующей статистический подход. Основными компонентами такой системы являются датчик и классификатор (рис. 1).




Рис. 1. Обобщенная структурная схема системы распознавания образов

Датчик представляет собой устройство, которое преобразует информацию, полученную от объекта, в вектор значений  $X = (x_1, \dots, x_n)^T$ , где  $n$  соответствует числу характеристик, определяющих объект и позволяющих его однозначную идентификацию. Классификатор, в свою очередь, принимает этот вектор значений и относит его к одному из предопределенных классов  $a_i$ , где  $i = 1, \dots, m$ , где  $m$  – общее число классов, среди которых необходимо провести классификацию объекта. В системе распознавания объектов классификатор представляет собой компонент, который назначает объекту определенный класс или категорию на основе его характеристик, представленных в виде вектора признаков. Он анализирует вектор значений, полученный от датчика, и сравнивает его с эталонными данными или моделями классов, хранящимися в памяти системы. Классификатор определяет, к какому из возможных классов объект относится, основываясь на заранее заданных правилах или алгоритмах, таких как функции решения, статистические методы или машинное обучение. Процесс классификации в системе распознавания объектов включает следующие этапы.

1. **Сбор данных:** датчик преобразует информацию о объекте в вектор признаков.
2. **Предобработка данных:** обработка данных для приведения их к удобному виду.
3. **Анализ и классификация:** классификатор анализирует вектор признаков, используя алгоритмы или модели для определения класса объекта.
4. **Принятие решения:** определение, к какому классу относится объект.
5. **Вывод результатов:** предоставление результатов классификации для дальнейшего использования.

Рассмотрим задачу распознавания объектов на конвейерной ленте. Распознавание объектов на линии играет ключевую роль по нескольким причинам:

**1) контроль качества** – автоматизированные системы распознавания позволяют в реальном времени обнаруживать дефекты и несоответствия, обеспечивая высокие стандарты качества продукции и сокращая количество бракованных товаров;

**2) сортировка и классификация** – такие системы могут автоматически сортировать и классифицировать предметы по различным характеристикам, таким как размер, форма, цвет или тип, что упрощает упаковку и дальнейшую обработку;

**3) оптимизация процессов** – эффективное распознавание объектов способствует более точному и быстрому управлению конвейерными линиями, снижая время простоя и повышая общую производительность;

**4) автоматизация** – внедрение технологий распознавания объектов позволяет уменьшить необходимость в ручном труде и минимизировать человеческое вмешательство, что снижает затраты на рабочую силу и улучшает безопасность на рабочем месте;

**5) отслеживание и учет** – системы распознавания помогают отслеживать перемещение товаров по конвейерной линии и собирать данные для анализа, что способствует улучшению производственных процессов;

**6) интеграция с другими системами** – технологии распознавания объектов можно интегрировать с другими автоматизированными системами, такими как управление запасами и планирование ресурсов, что обеспечивает более скоординированное управление производственными процессами.

Таким образом, использование распознавания объектов на конвейерной линии значительно повышает эффективность, точность и качество производственного процесса.

Решим задачу распознавания образов на фотографиях с использованием языка Python и специализированной базы данных ImageAI, которая предназначена для этой цели.

ImageAI – это библиотека Python, позволяющая разработчикам легко создавать приложения и системы с функциями глубокого обучения и компьютерного зрения с помощью нескольких строк кода. Она включает современные алгоритмы глубокого обучения, такие как RetinaNet, YOLOv3 и TinyYOLOv3, и предоставляет три основные возможности: прогнозирование изображений, обнаружение объектов и отслеживание объектов в видео.

ImageAI работает через несколько API-интерфейсов, которые функционируют в автономном режиме, что позволяет использовать их для обнаружения объектов, анализа видео и отслеживания объектов без необходимости подключения к Интернету. Библиотека использует предварительно обученные модели, которые можно легко адаптировать под конкретные задачи.

Воспользуемся библиотекой ImageAI для распознавания объектов на конвейерной линии. Для примера выберем конвейерную ленту для фасовки яблок (рис. 2). Как видно из рисунка, не все яблоки находятся в фокусе, что усложняет задачу распознавания.



Рис. 2. Пример картинки для распознавания объектов

На рис. 3 представлен результат распознавания объектов на конвейерной ленте. Распознанные объекты, расположенные на переднем плане, выделены зеленой рамкой, в верхней части которой представлен процент точности распознавания. Для этих объектов точность распознавания превышает 95%. Однако яблоки, не имеющие четкого изображения, находящиеся на заднем плане, распознаны не были. Следовательно, при проектировании системы распознавания на линии, данный факт должен быть учтен.



*Рис. 3. Результат распознавания объектов*

Таким образом, библиотека ImageAI может быть использована для распознавания фруктов на конвейерной линии. Данная библиотека находится в свободном доступе, легка в использовании и может быть настроена на распознавание объектов в режиме реального времени.

#### **Библиографический список**

1. Чабан Л. Н. Теория и алгоритмы распознавания образов: учеб. пособие. М.: МИИГАиК. 2004. 70 с.
2. Ту Дж., Гонсалес Р. Принципы распознавания образов. М.: Мир, 1978.
3. Рашка С. Python и машинное обучение / пер. с англ. А. В. Логунова. М.: ДМК Пресс, 2017. 418 с.

*Н. С. Мокрецов\**

аспирант

*Т. М. Татарникова\*\**

доктор технических наук, профессор

\*Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина)

\*\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## АЛГОРИТМ ОПТИМИЗАЦИИ МОДЕЛЕЙ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОБРАБОТКИ ТЕКСТА НА ЕСТЕСТВЕННОМ ЯЗЫКЕ

Описывается проблема большой вычислительной сложности современных моделей нейронных сетей для обработки текста на естественном языке. Данная особенность делает невозможным использование таких моделей в приложениях реального времени на устройствах с ограниченными ресурсами. В качестве решения предлагается использование подхода дистилляции знаний. Его суть заключается в переносе знаний из модели с огромным количеством параметров в более компактную. Описан принцип работы одной из вариаций дистилляции знаний для сжатия большой языковой модели. В результате получили модель, которую удалось сжать более чем в 60 раз при потере точности в 11,3%.

**Ключевые слова:** нейронные сети, дистилляция знаний, большие языковые модели, обработка естественного языка, оптимизация.

*N. S. Mokretsov\**

PhD Student

*T. M. Tatarnikova\*\**

Dr. Sc., Tech., Professor

\*St. Petersburg Electrotechnical University «LETI»

\*\*St. Petersburg State University of Aerospace Instrumentation

## ALGORITHM FOR OPTIMIZING NEURAL NETWORK MODELS FOR NATURAL LANGUAGE TEXT PROCESSING

The article describes the problem of high computational complexity of modern neural network models for natural language text processing. This feature makes it impossible to use such models in real-time applications on devices with limited resources. As a solution, the approach of knowledge distillation is proposed. Its essence lies in transferring knowledge from a model with a huge number of parameters to a more compact one. The principle of operation of one of the variations of knowledge distillation for compression of a large language model is described. As a result, a model was obtained that was compressed more than 60 times with an accuracy loss of 11,3%.

**Keywords:** neural networks, knowledge distillation, large language models, natural language processing, optimization.

### Введение

Большие языковые модели, такие как GPT-3.5, GPT-4 [1], Gemini [2] и Claude2, являются новаторскими технологиями, изменившими наше понимание обработки естественного языка. Эти модели, характеризующиеся огромным масштабом и сложностью, открыли новые сферы возможностей: от создания текста, похожего на человеческий, до предоставления возможностей решения сложных задач. Основное их значение заключается в их эмерджентных способностях [3] – феномене, когда модели демонстрируют возможности, выходящие за рамки их явных целей обучения, что позволяет им справляться с разнообразным спектром задач, несмотря на то, что это не закладывалось в саму модель. Потенциал этих моделей выходит далеко за рамки текущих приложений, обещая произвести революцию в отраслях, расширить возможности человеческого творчества и переосмыслить наше взаимодействие с технологиями [4].

Однако большое количество параметров в указанных моделях делает невозможным их размещение в задачах с ограниченными ресурсами, таких как их использование в приложениях реального времени на мобильных, периферийных и носимых устройствах. Для решения этой проблемы было рассмотрено большое количество существующих алгоритмов оптимизации нейронных сетей, но недавние исследования были сосредоточены на методах дистилляции знаний [5].

### Дистилляция знаний для моделей обработки текста на естественном языке

Подход, следующий общей парадигме дистилляции знаний обучения небольшой модели ученика из большой модели учителя, заключается в идее уменьшения размерности скрытых параметров и сжатии размера словаря [6].



Использование исключительно выводов модели учителя может быть недостаточным для достижения необходимого уровня обобщения модели ученика. В связи с этим используются подходы, в которых промежуточные прогнозы ученика пытаются согласовать с промежуточными прогнозами учителя. В описываемом методе выбран подход, суть которого заключается в минимизации потери информации из параметров учителя  $\theta_t$ , количество которых превышает сумму параметров модели ученика  $\theta_s$ . Достигается это за счет проецирования параметров модели в пространство той же размерности, т. е. каждый обучаемый параметр в  $\theta_t - \theta_t'$  проецируется до той же размерности соответствующего ему параметра в  $\theta_s - \theta_s'$ . Например, для всех обучаемых параметров в  $\theta_t$  размерности  $768 \times 768$  обучаются две проецирующие матрицы:  $U \in R^{d \times 768}$  и  $V \in R^{768 \times d}$ , где  $d$  соответствует размерности пространства скрытых параметров модели ученика. По итогу для того, чтобы привести к соответствию параметры ученика к проекции параметров учителя, применяется следующая функция потерь, где  $\downarrow$  обозначает понижение размерности проекции:

$$L_p^\downarrow = \sum_{\theta_t', \theta_s, c \in \theta_t, \theta_s} U \theta_t' V - \theta_s'^2,$$

где  $U$  и  $V$  – проецирующие матрицы;

$\theta_t$  – параметры модели учителя;

$\theta_s$  – параметры модели ученика;

$\theta_t'$  – переменная из множества параметров модели учителя;

$\theta_s'$  – переменная из множества параметров модели ученика.

Также используется вариант описываемого подхода, где вместо проецирования параметров учителя в пространство параметров ученика, применяют проецирование параметров ученика в пространство параметров учителя, т. е. повышение размерности, что обозначается символом  $\uparrow$ , все используемые обозначения соответствуют тем, что приведены для функции выше:

$$L_p^\uparrow = \sum_{\theta_t, \theta_s, c \in \theta_t, \theta_s} \theta_t' - U \theta_s' V^2.$$

Для получения финальной функции потерь также используется потеря перекрестной энтропии (cross-entropy) моделей учителя и ученика, в которой  $P(y_i = c | \theta_s)$  и  $P(y_i = c | \theta_t)$  обозначают предсказательные вероятности модели ученика и учителя по отношению к классу  $c$ :

$$L_{ce} = \sum_{y_i \in y} \left( \sum_{c \in C} [1_{[y_i]=c} \log P(y_i = c | \theta_s)] + \sum_{c \in C} [1_{[y_i]=c} \log P(y_i = c | \theta_t)] \right),$$

где  $c$  – индекс класса;

$y$  – вывод модели (выходные данные);

$1_{[y_i]=c}$  – функция-«индикатор».

Функция-«индикатор» – это функция, определенная на множестве  $X$ , которая указывает на принадлежность элемента  $x \in X$  подмножеству  $A$ . Если  $x$  принадлежит  $A$ , то функция равна 1, в ином случае 0.

Итоговая функция потерь представляет собой сумму потери проецирования и потери перекрестной энтропии:

$$L = L_p + \sigma L_{ce},$$

где  $\sigma$  – настраиваемый гиперпараметр.

Сравнительные характеристики вариаций реализации описанного подхода сведены в таблице. Основное различие между вариациями заключается в размерности скрытого пространства модели ученика. Для оценки точности моделей использовался бенчмарк Stanford Sentiment Treebank (SST-2) [7] – 67 тыс. обучающих примеров для задачи классификации настроений предложений.

**Сравнительная таблица моделей при различных степенях сжатия**

Модель	Размерность скрытого пространства	Коэффициент сжатия	Точность, %
Учитель BERT	768	1,00	93,5
Базовая модель	192	5,74	87,1
С использованием $L_p^\downarrow$			88,4
С использованием $L_p^\uparrow$			88,0
Базовая модель			85,4
С использованием $L_p^\downarrow$	96	19,41	85,6
С использованием $L_p^\uparrow$			84,7
Базовая модель			79,5
С использованием $L_p^\downarrow$	48	61,94	80,0
С использованием $L_p^\uparrow$			82,2

## Заключение

Идея дистилляции знаний получает широкое развитие при решении проблемы сжатия громоздких моделей нейронных сетей для возможности их использования на устройствах с ограниченными вычислительными ресурсами. Показано, как применение дистилляции знаний позволяет сжимать размер языковой модели общего назначения практически в 6 раз с потерей лишь 5,1% точности модели, либо в 60 раз с потерей в 11,3%. Помимо представленного подхода, существует обширное количество различных архитектур дистилляции знаний, которые используются и модифицируются большим количеством авторов [8]. Эти решения успешно применяются не только для моделей больших языковых моделей, но и для обучения моделей обработки изображений, векторов данных, аудиоданных и т. д.

Стоит так же отметить другое направление дистилляции знаний, в рамках моделей обработки текста на естественном языке: она позволяет более целенаправленно извлекать знания, сосредоточившись на конкретных навыках или областях, представляющих интерес, без сжатия модели учителя. Этот метод особенно эффективен для использования эмерджентных способностей больших языковых моделей, где модели демонстрируют возможности, выходящие за рамки их явных целей обучения. В данном случае размер ученика оставляют прежним, но повышают уровень экспертности по знаниям узкой направленности. Например, в работе [9] была создана языковая модель OceanGPT для решения задач науки об океане, обобщающая знания в области океанографии. Сравнительные результаты OceanGPT относительно других моделей больших языковых моделей той же размерности демонстрируют значительное превосходство в степени экспертности результирующей модели. Качество работы моделей оценивалось как автоматическими методами, так и при помощи живых экспертов.

## Библиографический список

1. Training language models to follow instructions with human feedback / L. Ouyang, J. Wu, X. Jiang [et al.] // *Advances in Neural Information Processing Systems*. 2022. Vol. 35. P. 27 730–27 744.
2. Gemini: a family of highly capable multimodal models / G. Team, R. Anil, S. Borgeaud [et al.]. URL: <https://doi.org/10.48550/arXiv.2312.11805> (дата обращения: 29.08.2024).
3. Emergent abilities of large language models / J. Wei, Y. Tay, R. Bommasani [et al.] // *Transactions on Machine Learning Research*. 2022. Vol. 2022.
4. Holistic evaluation of language models / P. Liang, R. Bommasani, T. Lee [et al.] // *Computing Research Repository (CoRR)*. 2022. Vol. abs/2211.09110.
5. Knowledge distillation: A survey / J. Gou, B. Yu, S. J. Maybank, D. Tao // *International Journal of Computer Vision*. 2021. Vol. 129. P. 1789–1819.
6. Extreme Language Model Compression with Optimal Subwords and Shared Projections / S. Zhao, R. Gupta, Y. Song, D. Zhou. URL: <https://doi.org/10.48550/arXiv.1909.11687> (дата обращения: 17.08.2024).
7. Recursive deep models for semantic compositionality over a sentiment treebank / R. Socher, A. Perelygin, J. Wu [et al.] // *In Proceedings of the 2013 conference on empirical methods in natural language processing*. 2013. P. 1631–1642.
8. Gupta M., Agrawal P. Compression of Deep Learning Models for Text: A Survey // *ACM Transactions on Knowledge Discovery from Data (TKDD)*. 2020. Vol. 16. P. 61:1–61:55.
9. OceanGPT: A large language model for ocean science tasks / Z. Bi, N. Zhang, Y. Xue [et al.] // *Computing Research Repository (CoRR)*. 2023. Vol. abs/2310.02031.

*М. М. Мусаев\**

доктор технических наук, профессор

*И. Ш. Хужаяров\**

кандидат технических наук, доцент

*М. М. Очиллов\**

кандидат технических наук, доцент

\*Самаркандский филиал Ташкентского университета информационных технологий им. Мухаммада аль-Хоразмий, Узбекистан

## ТЕХНОЛОГИИ РАСПОЗНАВАНИЯ РЕЧИ НА БАЗЕ АЛГОРИТМОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Рассматривается разработка алгоритмов и технологий автоматического распознавания узбекской речи с использованием методов искусственного интеллекта и нейронных сетей. Особое внимание уделено созданию речевого корпуса, выделению информативных признаков речи, а также архитектуре глубоких нейронных сетей на основе модели End-to-End (E2E). Описаны этапы разработки программного комплекса, включая методы аудиоаугментации и создание языковой модели для повышения точности распознавания. В результате экспериментов получены показатели WER = 16,2% и CER = 5,4%, что демонстрирует успешность предложенной системы распознавания речи.

**Ключевые слова:** искусственный интеллект, распознавание речи, нейронные сети, MFCC, система распознавания речи, End-to-End (E2E), речевой корпус, CNN, RNN, BLSTM.

*М. М. Musaev\**

Dr. Sc., Tech., Professor

*I. Sh. Khujayorov\**

PhD, Tech., Associate Professor

*M. M. Ochiylov\**

PhD, Tech., Associate Professor

\*Samarkand Branch of Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Uzbekistan

## SPEECH RECOGNITION TECHNOLOGY BASED ON ARTIFICIAL INTELLIGENCE ALGORITHMS

This paper deals with the development of algorithms and technologies for automatic recognition of Uzbek speech using artificial intelligence and neural network methods. Special attention is paid to the creation of a speech corpus, the extraction of informative features of speech, and the architecture of deep neural networks based on the End-to-End (E2E) model. The stages of software development are described, including audio augmentation methods and language model creation to improve recognition accuracy. Experiments resulted in WER=16.2% and CER=5.4%, demonstrating the success of the proposed speech recognition system.

**Keywords:** Artificial intelligence, speech recognition, neural networks, MFCC, speech recognition system, End-to-End (E2E), speech corpus, CNN, RNN, BLSTM.

### 1. Введение

Искусственный интеллект (ИИ) на сегодняшний день является стратегически наиболее важной технологией для формирования новой цифровой экономики. Компьютерные средства представляют собой новый доступный и мощный ресурс для реализации цифрового технологического прорыва. В отличие от других ресурсов, ИИ развивается с высокой скоростью, что делает его ключевым потенциальным источником экономического роста.

Как известно, системный эффект наблюдается в мультидисциплинарных и междисциплинарных научных исследованиях. Это означает, что большой интерес представляют направления исследований и разработок, находящиеся на перекрытии перечисленных направлений: перспективные интерфейсы в глобальных мобильных сетях, интеллектуальные интерфейсы в IT-технологиях обработки данных и применение технологий искусственного интеллекта в Интернете.

Искусственный интеллект в сочетании с речевыми технологиями обеспечивает непосредственное взаимодействие ресурсов компьютера и пользователя посредством программ обработки текстовых и речевых запросов. Примерами наиболее успешного применения технологии распознавания речи могут служить программные продукты, использующиеся в call-центрах, в составлении протоколов заседаний, журналистике, медицинской диагностике. Технология распознавания речи широко применяется в сфере образования, в различных программных продуктах, направленных на изучение иностранных языков. Большую помощь эти технологии могут оказать людям с нарушениями слуха и речи, нарушениями речевого аппарата в результате травм или от рождения, в реабилитации пациентов, утративших полностью или частично разговорную речь, детей глухих с детства с живыми имплантатами.

Однако, если взаимодействие с компьютером осуществляется с помощью процедурного языка программирования, это не удовлетворяет большинство конечных пользователей, обычно не умеющих и не желающих программировать. Развитие систем искусственного интеллекта, предполагает использование естественного языка для взаимодействия пользователя с компьютером. Создание технологий распознавания речи с высокой точностью в темпе речевого произношения является актуальной задачей и требует широкого применения алгоритмов искусственного интеллекта [1].

В данной работе речь идет об алгоритмах распознавания узбекской речи. История развития речевых технологий в Узбекистане насчитывает 5–6 лет, тем не менее опыт по исследованию и созданию алгоритмов искусственного интеллекта в других направлениях позволил в короткие сроки применить эти алгоритмы в сочетании с нейронными сетями к задачам анализа и распознавания узбекской речи [2].

## 2. Технологии анализа речи (технологии «речь – текст»)

Основные требования, предъявляемые к программным средствам типа «речь – текст», заключаются в том, чтобы алгоритмы, реализующие процессы автоматического распознавания речи обеспечивали нужную скорость обработки при требуемой точности распознавания, могли работать в реальном темпе речевого произношения [3]. Перед началом работ по созданию комплекса алгоритмов и программ распознавания речи должны быть сформулированы требования к системе распознавания с учетом особенностей построения и звучания того или иного типа речи [4].

В таблице представлены и выделены требования, в соответствии с которыми разрабатываются технологии автоматического распознавания речи.

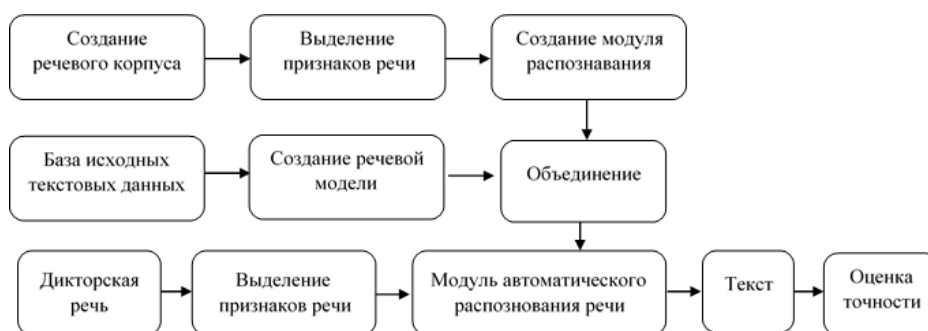
**Требования к технологии распознавания речи**

Тип анализируемой речи	Зависимость от диктора	Объем речевого словаря	Выбираемая технология обработки
Распознавание отдельных слов	Распознавание, зависимое от диктора	С ограниченным словарем	На основе HMM (Hidden Markov model)
Распознавание сочетаний слов	С настройкой на диктора	Со словарем большого объема	На основе HMM + ANN (Artificial neural networks)
<b>Распознавание непрерывной (слитной) речи</b>	<b>Распознавание, независимое от диктора</b>	<b>Со словарем без ограничений</b>	<b>На основе модели End to End – E2E</b>

Весь процесс создания программ автоматического распознавания речи [4] представляет собой полноценную технологию подготовки и обработки информации и включает следующие основные этапы:

- создание речевого корпуса;
- выделение информативных признаков речевого сигнала;
- проектирование речевой модели языка распознавания;
- разработка нейросетевой архитектуры для распознавания речи;
- создание модулей автоматического распознавания речи.

На рис. 1 представлены основные компоненты технологии распознавания узбекской речи.



*Рис. 1. Этапы технологии обработки узбекской речи*

## 3. Создание речевого корпуса узбекской речи

Создание речевого корпуса представляет собой длительный процесс чтения текста различными группами дикторов разного возраста, пола и произношения. При этом для ускорения процесса широко используются как офисные, так и веб-технологии накопления аудиофайлов. На рис. 2 представлена функциональная схема формирования речевого корпуса.

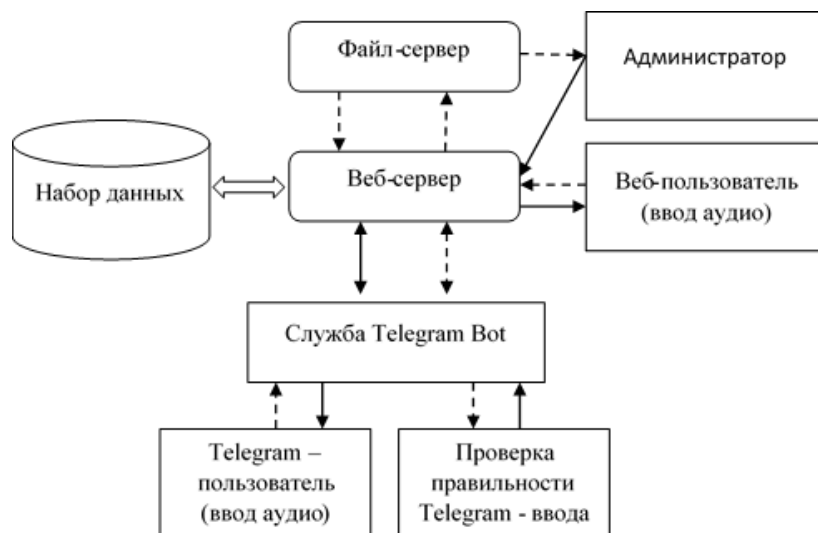


Рис. 2. Модули формирования речевого корпуса

Речевой корпус формируется заранее, является трудоемким этапом подготовки данных и требует много человеческих ресурсов [5]. Аудиоданные от дикторов могут вводиться как через телекоммуникационную службу Telegram Bot, так и непосредственно через веб-сервер. Правильность аудиоввода через Telegram и его соответствие читаемому тексту проверяет специальный оператор.

Все вводимые аудиоданные контролируются администратором, задачей которого является удаление символов, запятых, пауз и окончательная подготовка аудио к занесению в базу данных. В базе данных хранятся также тексты аудиофайлов, данные о дикторах (пол, ФИО, возраст, адрес) и операторах. В речевом корпусе, кроме самих аудиофайлов, хранятся их параметры: номер текстового фрагмента, номера диктора и оператора, время проверки, продолжительность). В качестве окружающей среды для записи аудиофайлов выбираются офисные помещения или студии.

При обнаружении нарушений (помехи или искажения) в технологии формирования речевого корпуса записанный аудиофайл может быть изъят или перезаписан. Алгоритм проверки заключается в сравнении записанного аудиофайла и его транскрипта (текстового аналога). Кроме того, проверяется качество самой аудиозаписи. При необходимости с помощью полосовых фильтров запись вводится в нужный речевой диапазон [6].

Объем речевого корпуса зависит от назначения системы распознавания. Для систем речевого управления объем речевого корпуса составляет до 40 часов, а для систем распознавания непрерывной речи объем корпуса составляет 1000 и более часов.

Предварительная подготовка текстов к работе дикторов по озвучиванию в виде аудиофайлов включает следующие процедуры:

- перевод на латинскую графику,
- введение пробелов между предложениями,
- удаление непонятных в языке символов,
- перевод цифровых данных в текст,
- выделение предложений длиной не более 2–15 слов.

Параметры речевого корпуса, применяемого в данном варианте системы:

- длительность – 250 часов,
- количество дикторов – 882,
- количество слов – 540 тыс.

#### 4. Выделение информативных признаков речи

Последовательность алгоритмов выделения информативных признаков из речевого сигнала применяется дважды: после создания речевого корпуса и при распознавании поступающей на вход системы речи с микрофона (см. рис. 1). На основе выделенных информативных признаков (спектрограмм) реализуется процесс обучения нейронной сети модели E2E [7]. По результатам обучения создается текстовый транскрипт аудиофайла.

Особенностью предлагаемого подхода к автоматическому распознаванию непрерывной узбекской речи является использование в качестве входных данных для алгоритмов распознавания изображений спектрограмм речевых фрагментов (рис. 3).

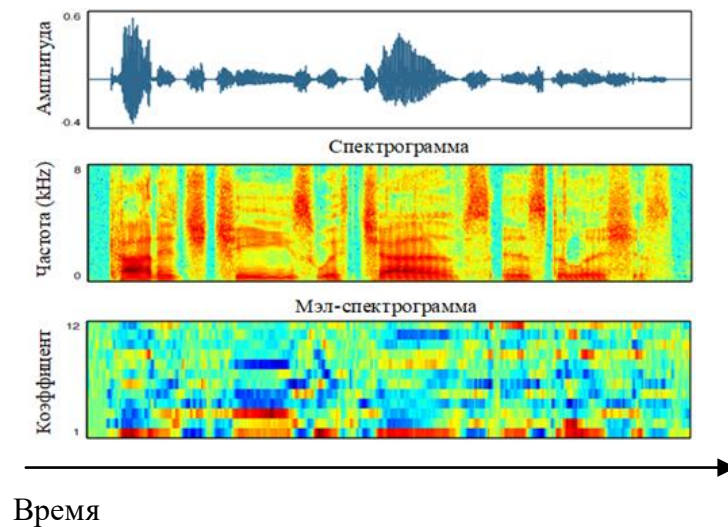


Рис. 3. Начальный, промежуточный и конечный формат представления сигнала

Алгоритмы расчета и вычисления весовых коэффициентов спектрограмм сигнала [8] на основе Фурье-преобразования (FFT), мэл-преобразования (Mel Frequency Cepstral Coefficients – MFCC) и дискретного косинусного преобразования (Discrete Cosine Transform – DCT) представлены на рис. 4.



Рис. 4. Алгоритмы вычисления MFCC-спектрограмм

Формулы для вычисления преобразования Фурье, дискретно-косинусного и мэл-преобразования соответственно:

$$X_k = \sum_{n=0}^{N-1} x_n w_n e^{-\frac{2\pi i}{N} kn}, k = 0, \dots, N-1,$$

$$c[k] = \sum_{m=0}^{I-1} S[m] \cos\left(\frac{\pi}{I} \left(m + \frac{1}{2}\right) k\right), 0 \leq k \leq I,$$

$$f[k] = \frac{N}{F_s} m^{-1} \left( m(f_{min}) + k \frac{m(f_{max} - f_{min})}{N+1} \right).$$

В формулах обозначены:  $k$  – частота сигнала,  $F_s$  – частота дискретизации,  $N$  – число переменных,  $m$  – функции перехода к мэл-шкале. Применение мэл-спектрограмм связано с тем, что при сохранении фонетических характеристик сигнала обеспечиваются сжатие и логарифмирование для получения кепстра сигнала. В наборе мел-частотных кепстральных признаков над спектром производят манипуляции, имитирующие особенности обработки слуховой системой: собирают компоненты спектра в соответствии с частотной шкалой «мэл» и логарифмируют значения энергии в каждом канале. Шкала «мэл» представляет собой псевдологарифмическую шкалу частот, экспериментально полученную в результате психоакустических экспериментов. Ее важность заключается не только в том, что она соответствует нашим представлениям о работе слуховой системы, но и в том, что, объединяя спектральные компоненты высоких частот во все более широких зонах, она позволяет существенно понизить размерность вектора признаков. Логарифмирование моделирует амплитудную компрессию, характерную для распространения сигналов по нервным каналам. Дополнительно делают обратное косинусное преобразование, переходя к кепстру, и оставляют только первые 12 компонент (коэффициентов) [9].

## 5. Архитектуры нейронных сетей на основе модели End-to-End (E2E)

В модели E2E за счет отсутствия проблемы принудительной сегментации при обучении обеспечивается высокая эффективность по скорости и точности. По сравнению с другими стандартами, выбор модели E2E и метода классификации CTC (Connection temporal classification) обоснован тем, что в них проще построение модели языка, а сама точность распознавания связана с объемом и качеством предназначенного для обучения речевого корпуса. Речевые модели играют большую роль в системах автоматического распознавания любого типа речи.

Трудности разработки речевой модели узбекского языка заключаются в том, что нет единого стандарта на фонемы, дифоны, трифоны и другие звуковые единицы. Также для распознавания с высокой точностью требуются речевые корпуса большого объема.

Существует несколько типов моделей, различающихся длиной контекста, сложностью построения, точностью распознавания. По результатам предварительных оценок выбрана модель на основе статистики. В области обработки языка статистические модели применяются для предугадывания последовательности звуков, слогов, слов или звуков. Выбранная N-граммная модель рассчитывает вероятность позиции слова в зависимости от предшествующих слов. В качестве инструмента по созданию 3-граммной модели использована программа Kneser-Ney smoothing [7; 10]. В этом случае последовательность шагов распознавания входной речи выглядит так, как показано на рис. 5.



Рис. 5. Этапы распознавания входной речи

Задачами этапа предварительной обработки являются дискретизация, создание моноканала в 16 КГц и разрядностью 16 бит. При выделении признаков применяется мэл-спектрограмма размером в 25 мс, окно смещения фреймов составляет 10 мс, в одном фрейме содержится 40 коэффициентов MFCC.

Глубокая нейронная сеть DNN-CTC состоит из нескольких алгоритмов. Алгоритм глубокого обучения объединяет сверточную и рекуррентную нейронные сети [11]. На первом шаге с помощью двухслойной сверточной сети спектрограмма преобразуется в карту признаков меньшей размерности. Отдельные слои карты признаков в качестве входных переменных подаются на входы рекуррентных сетей LSTM (Long Shot Term Memory), двунаправленный вариант которых называется BLSTM (Bidirectional LSTM based RNN), на выходе скрытых слоев которых в соответствии с ранее проведенным обучением формируется промежуточный ряд векторов, обозначающих вероятные позиции текущих фреймов. Эти векторы поступают на входы многослойного полносвязного персептрона (Fully connected). Сеть преобразует поступающие векторы в соответствии с числом букв алфавита. После процедуры нормализации Softmax (0,1) формируется матрица вероятных значений признаков каждой из 29 букв узбекского алфавита. Затем выделяются символы фреймов с максимальным значением вероятности, делается перевод номера позиции матрицы вероятностей в последовательность символов алфавита. Алгоритм декодирования CTC-Decoding с помощью CTC Loss-функции переводит последовательность символов в текст. Процесс объединения речевой модели и модуля автоматического распознавания реализуется в модуле декодирования.

Таким образом, полная архитектура и основные компоненты предлагаемой нейронной сети приведены на рис. 6.



Рис. 6. Основные компоненты предлагаемой глубокой нейронной сети

## 6. Параметры созданной нейронной сети

Входными данными являются коэффициенты мэл-спектрограммы. Два слоя сверточной сети CNN имеют одинаковые параметры: размер фильтров  $11 \times 22$ , функцию активации ReLU. Два слоя рекуррентной сети имеют параметры: тип RNN – BLSTM, размер слоя – 512, функция активации ReLU. Полносвязная сеть FC: размер первого слоя 600, функция активации ReLU, размер второго слоя 29, функция активации Softmax. Слой транскрипции CTC Loss – функция. Параметры обучения: алгоритм оптимизации Adam длина шага 0,001, размер Batch – 64.

### Программный комплекс распознавания узбекской речи

Разработанный программный комплекс состоит из взаимодействующих программ, выполняющих обработку данных следующих этапов.

1. Создание речевого корпуса.

2. Выделение информативных признаков аудиоданных.
3. Разработка речевой модели.
4. Создание нейронной сети глубокого обучения.
5. Программы тестирования системы распознавания.

Построение, обучение и тестирование моделей реализованы с использованием возможностей языка программирования *Python*. Построенная на основе метода классификации CTC сеть создана при помощи библиотек *tensorflow* и *keras* языка *Python*. Модель E2E-Conformer кодирована на основе фреймворка *espnet* библиотеки *pytorch*. Программирование выполнено в операционной системе Linux. При предварительной обработке аудиосигналов и разработке тестовых модулей использовались специальные скрипты *bash*. Обучение моделей выполнено на графических процессорах Nvidia Tesla V100 (GPU) сервера NVIDIA DGX-2 с 32Гб.

Для оценки языковой модели в качестве меры использованы коэффициенты PP (Perplexity). Они являются обратной вероятностью нормализованного числа слов в проверяемом тексте:

$$PP(W) = P(w_1 w_2 \dots w_N)^{-\frac{1}{N}} = \sqrt[N]{\prod_{i=1}^N \frac{1}{P(w_i | w_1 \dots w_{i-1})}}$$

При проверке основанной на статистике языковой модели с использованием инструмента IRSTLM и построении 3-граммной модели для групп речевого корпуса при обучении и тестировании показатель PP для *train* и *test* составил соответственно 6,2 и 7,9. Для нейронной сети на основе речевой модели LSTM эти значения составили соответственно 2,56 и 3,12.

Характеристики оценок систем распознавания речи: WER (Word Error Rate) – частота ошибочных слов, CER (Character Error Rate) – частота ошибок символов. Параметры WER и CER вычисляются с помощью формулы

$$WER / CER = \frac{D + U + I}{N} \cdot 100\%,$$

где  $N$  – число слов или символов в представленной последовательности,  $D$  – число слов или символов,  $U$  – число слов или символов,  $I$  – число слов или символов.

В процессе экспериментов использовались следующие методы расширения аудиоданных речевого корпуса: добавление шума AN (Add Noise), изменение скорости чтения аудио SP (Speed Perturbation) и маскирование спектра SA (SpecAugment) по оси времени и оси частот. Кроме того, при декодировании оценивалась эффективность использования модели языка LM (Language Модель). В качестве шума использовался Гауссовый шум с амплитудой  $\sigma = 0,01$ . Скорость чтения аудио изменялась в пределах 0,9; 1,0 и 1,1. При маскировании в спектральной области максимальное время по ширине выбиралось  $T = 40$  для двух масок и в частотной области максимальное время по частоте  $F = 30$  для двух масок.

Можно увидеть хорошие результаты модели Conformer по показателям WER и CER. Для группы *test* при 5211 образцах ошибка составила WER = 16,2% и CER = 5,4%.

Созданная система распознавания речи работает в мягком режиме реального времени. Это означает, что время ответа на запрос зависит от продолжительности вводимого речевого фрагмента. Для длинных предложений требуется большее время, для коротких меньше.

### Заключение

Нейронная сеть DNN-CTC на основе модели Ent-to-End была разработана с использованием существующего 250-часового речевого корпуса с целью распознавания слитной узбекской речи. Для разработки модели распознавания речи были использованы методы аудиоаугментации, такие как добавление шума, ускорение, спекуляция. Для повышения точности системы распознавания была разработана модель узбекского языка. При создании системы распознавания речи с использованием методов аугментации и языковой модели показатели ошибок системы составили WER = 16,2% и CER = 5,4%.

### Библиографический список

1. *Musaev M., Khujayorov I., Ochilov M.* Automatic recognition of Uzbek speech based on integrated neural networks // WCIS-2020. AISC. 2021. Vol. 1323. P. 215–223.
2. *Купяткова И. С., Карнов А. И.* Аналитический обзор систем распознавания русской речи с большим словарем // Труды СПИИРАН. 2010. № 1(12). С. 7–20.
3. *Musaev M., Khujayorov I., Ochilov M.* The use of neural networks to improve the recognition accuracy of explosive and unvoiced phonemes in Uzbek language // 2020 Information Communication Technologies Conference (ICTC). China, 2020. P. 231–234.
4. Convolutional Neural Networks for Speech Recognition / O. Abdel-Hamid, A. Mohamed, H. Jiang [et al.] // IEEE/ACM Transactions on Audio, Speech, and Language Processing. 2014. Vol. 22, № 10. P. 1533–1545.
5. Towards End-to-End Speech Recognition with Deep Convolutional Neural Networks / Y. Zhang, M. Pezeshki, P. Brakel [et al.] URL: <https://arxiv.org/pdf/1701.02720> (дата обращения: 22.08.2024).



6. *Musaev M., Khujayorov I., Ochilov M.* Image approach to speech recognition on CNN // 2019 International Conference on Frontiers of Neural Networks (ICFNN 2019). Rome, Italy, 2019. P. 1–6.
7. *Heafield K.* KenLM: Faster and Smaller Language Model Queries // Proceedings of the Sixth Workshop on Statistical Machine Translation. 2011. P. 187–197.
8. *Dong L., Xu S., Xu B.* Speech-Transformer: A No-Recurrence Sequence-to-Sequence Model for Speech Recognition // 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2018. P. 5884–5888.
9. *Musaev M., Khujayorov I., Ochilov M.* Development of integral model of speech recognition system for Uzbek language // 2020 IEEE 14th International Conference on Application of Information and Communication Technologies (AICT). 2020. P. 1–6.
10. Development of Language Models for Continuous Uzbek Speech Recognition System / A. Mukhamadiyev, M. Mukhiddinov, I. Khujayorov [et al.] // Sensors. 2023. № 23.
11. *Mukhamadiyev A., Khujayorov I., Cho J.* Voice-Controlled Intelligent Personal Assistant for Call-Center Automation in the Uzbek Language // Electronics. 2023. № 12.

*П. Ю. Нарвойш\**

студент

*А. И. Парамонов\**

кандидат технических наук, доцент

\*Белорусский государственный университет информатики и радиоэлектроники, Минск, Республика Беларусь

## ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ПРИ ИССЛЕДОВАНИИ ДЕЯТЕЛЬНОСТИ ГОЛОВНОГО МОЗГА МЕТОДОМ ЭЭГ

Рассматриваются возможные подходы к анализу ЭЭГ-данных с использованием алгоритмов машинного обучения. Приведено описание исходных данных. Представлены архитектуры моделей для анализа сигналов ЭЭГ и спектрограмм. Изучена возможность применения трансферного обучения для оптимизации ресурсов, а также описан комплексный подход к анализу ЭЭГ данных на основе ансамблирования моделей.

**Ключевые слова:** диагностика, электроэнцефалография, машинное обучение, спектрограмма, трансферное обучение.

*P. Yu. Narvoysh\**

Student

*A. I. Paramonov\**

PhD, Tech., Associate Professor

\*Belarusian State University of Informatics and Radioelectronics, Minsk, Republic of Belarus

## APPLICATION OF MACHINE LEARNING METHODS IN THE BRAIN ACTIVITY STUDY BY USING EEG

The paper describes possible approaches to EEG data analysis using Machine Learning algorithms. Description of the initial data is provided. Model architectures for analyzing EEG signals and spectrograms are presented. The possibility of using transfer learning to optimize resources is considered, and a comprehensive approach to EEG data analysis based on model ensemble is described.

**Keywords:** diagnostics, electroencephalography, machine learning, spectrogram, transfer learning.

### Введение

ЭЭГ (электроэнцефалография) – неинвазивный метод исследования функционального состояния головного мозга путем регистрации его биоэлектрической активности. ЭЭГ отражает биологический процесс, который обусловлен деятельностью множества электрических генераторов – нейронов. Создаваемое этими генераторами поле неоднородно по пространству головного мозга и изменчиво в каждый момент времени. Поэтому между двумя точками, расположенными в пределах мозга, между точками головного мозга и удаленной от него тканью организма появляются переменные разности потенциалов, которые можно зарегистрировать. Регистрация возникающих в головном мозге биологических потенциалов и является основной задачей ЭЭГ [1]. Для ранней диагностики различных заболеваний важно не только получать и регистрировать сигналы мозга, но и извлекать информацию, содержащуюся в ЭЭГ. Один из этапов компьютерной обработки сигнала – классификация, т. е. отнесение его к определенной группе на основе анализа его характеристик. Анализировать сигналы ЭЭГ можно как математическими методами, так и с использованием нейронных сетей и машинного обучения.

Применение методов машинного обучения при исследовании деятельности головного мозга методом ЭЭГ предполагает выполнение нескольких этапов: определение и четкая формулировка решаемой проблемы, подготовка наборов данных для обучения, при необходимости предобработка данных, выбор и обучение модели, проверка качества моделей путем анализа полученных показателей. В большинстве случаев задачей модели машинного обучения на основе ЭЭГ-данных является классификация, т. е. отнесение объекта к одной из категорий на основании его признаков. Данные для обучения должны соответствовать решаемой проблеме. В открытом доступе находится множество наборов данных (датасетов) для обучения моделей, направленных на распознавание движений, эмоций, реакций на внешние события, функциональных расстройств мозга и другие наборы описания деятельности головного мозга.

### Применение методов машинного обучения в подходах к анализу ЭЭГ-данных

В качестве эксперимента рассматривались датасеты с заранее размеченными группой экспертов ЭЭГ-данными [2], которые содержат паттерны опасной мозговой активности: судороги (SZ), генерализованные периодические разряды (GPD), латерализованные периодические разряды (LPD), латерализованная ритмическая

дельта-активность (LRDA), генерализованная ритмическая дельта-активность (GRDA) и «иное». В работе исследуются возможности применения трех самых распространенных на сегодня подходов для анализа ЭЭГ данных с использованием методов машинного обучения.

Первый подход основан на преобразовании сигналов ЭЭГ в изображения спектрограмм и последующем обучении модели классификации паттернов на наборе изображений при помощи сверточных нейронных сетей. Спектральный состав позволяет количественно оценить соотношение активности различных диапазонов частот. Одной из причин широкого применения спектрального метода анализа является то, что спектральные характеристики ЭЭГ поддаются математической и статистической обработке и потенциально могут дать эффективные методы анализа ЭЭГ, которые невозможно получить при традиционных методиках. Пример спектрограммы ЭЭГ и изображения ее сигнала представлены на рис. 1.




Рис. 1. Спектрограмма ЭЭГ (слева) и электроэнцефалограмма (справа)

В основе анализа изображений спектрограмм лежат 2D-сверточные нейронные сети [3]. Обучение сверточной нейронной сети для классификации изображений с нуля требует больших вычислительных мощностей. Поэтому принято решение выполнить трансферное обучение – метод, позволяющий сократить большую часть вычислений, используя часть модели, которая уже была обучена для выполнения связанной задачи, и повторно применяя ее в новой модели. Для этого можно зафиксировать те веса, которые получены в результате обучения модели на большом наборе разнообразных изображений, что позволит модели сохранить все результаты обучения. Далее, опционально, удаляются последние слои модели, так как в большинстве случаев они отвечают за решение конкретных прикладных задач. Затем в модель внедряются новые слои, которые помогут модели адаптироваться к специализированному характеру новой задачи. Пример архитектуры сети с использованием трансферного обучения представлен на рис. 2. Трансферное обучение дает возможность использовать меньший объем исходных данных, так как предварительно обученная модель сохраняет основные знания о задачах, особенностях, весах и функциях, что позволяет ей лучше и быстрее адаптироваться к новым задачам. Кроме того, такой подход позволяет задействовать гораздо меньше ресурсов, вычислительных мощностей и времени.

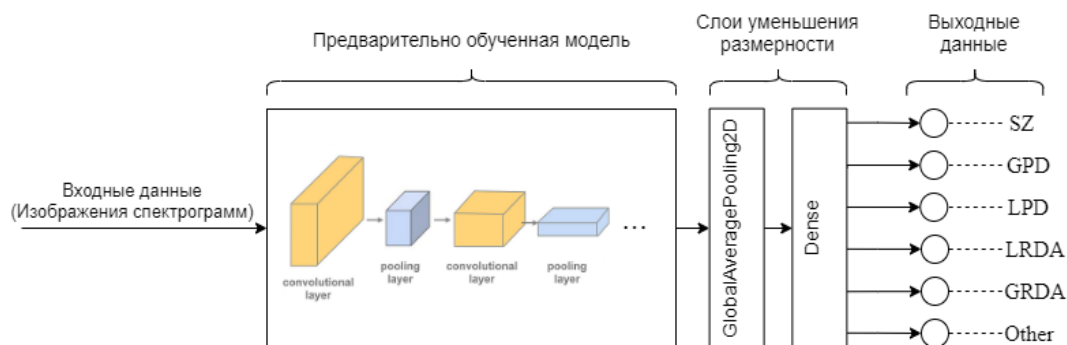


Рис. 2. Сверточная нейронная сеть с предварительно обученной моделью

Наряду с обучением моделей на основе изображений спектрограмм, широко применяется подход на основе анализа сигналов ЭЭГ, которые представляют собой временные данные. Для подобных задач применимы 1D-сверточные нейронные сети [3]. В исходном датасете одна запись сигнала ЭЭГ описывает промежуток времени, на протяжении которого собирались значения с 20 каналов (19 каналов – электроды, расположенные по международной системе «10-20», 1 канал – электрокардиограмма). Для построения 1D-сверточной нейронной сети можно использовать архитектуру по типу ResNet (Residual Neural Network) [4]. В ResNet сети благодаря соединениям быстрого доступа данные передаются не только последовательно из слоя в слой, но и с пропуском некоторого количества слоев, что и позволяет увеличивать количество слоев в сети. Пример фрагмента такой 1D-сверточной нейронной сети представлен на рис. 3 [5].

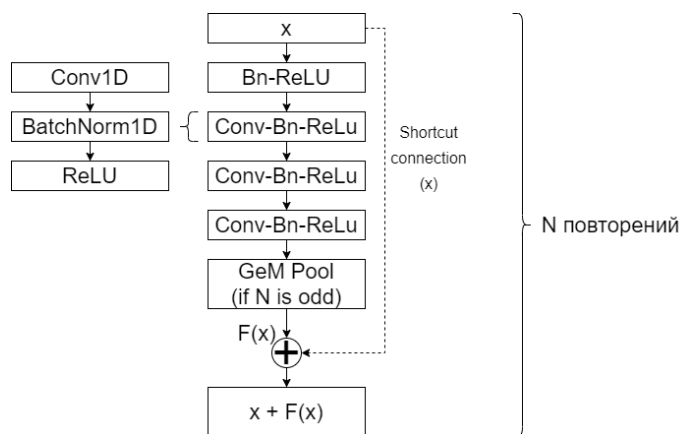


Рис. 3. Фрагмент 1D-сверточной нейронной сети

В последнее время все большую популярность при создании моделей получают комплексные подходы, которые объединяют нескольких успешных моделей в одну большую – ансамблирование моделей. Основная идея заключается в том, что несколько моделей обучаются отдельно, а далее их предсказания усредняются с помощью арбитра. В нашем случае 2D-сверточные нейронные сети обучаются на спектрограммах ЭЭГ, 1D-сверточные нейронные сети – на сигналах ЭЭГ. Ансамбль из них позволит создать модель, которая будет учитывать различные типы исходных данных. Арбитры, итоговым решением которых будет среднее арифметическое решений всех моделей ансамбля, показывают не лучшие результаты. Такой ансамбль придает одинаковое значение всем моделям, что не всегда эффективно, поэтому более подходящим методом является взвешенное принятие решений. Каждому алгоритму назначается свой вес, с которым его ответ будет входить в итоговую сумму, при этом сами веса нормируются на единицу.

### Заключение

Компьютерные эксперименты позволяют предположить, что развитие методов обработки и анализа сигналов ЭЭГ с использованием искусственного интеллекта и машинного обучения открывает новые возможности для автоматизированной диагностики и прогнозирования состояния мозга. Подобные методы позволяют ускорить процесс анализа и снизить нагрузку на специалистов в данной сфере. Кроме того, применение автоматизированного анализа уменьшает вероятность человеческой ошибки. Таким образом, использование методов машинного обучения для анализа ЭЭГ данных представляет собой перспективное направление, которое позволит улучшить качество диагностики различных состояний головного мозга.

### Библиографический список

1. Регистрация ЭЭГ // CMI.to. URL: <https://cmi.to/регистрация-ээг/> (дата обращения: 19.08.2024).
2. HMS – Harmful Brain Activity Classification / Jin Jing, Zhen Lin, Chaoqi Yang [et al.]. Kaggle. 2024. URL: <https://kaggle.com/competitions/hms-harmful-brain-activity-classification> (дата обращения: 19.08.2024).
3. Understanding 1D, 2D and 3D Convolution Network // Kaggle. URL: <https://www.kaggle.com/code/mercico/understanding-1d-2d-and-3d-convolution-network> (дата обращения: 19.08.2024).
4. Deep Residual Learning for Image Recognition / K. He, X. Zhang, S. Ren, J. Sun. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA, 2016. P. 770–778.
5. GWNETH: Detecting Gravitational Waves using Hierarchical and Residual Learning based 1D CNNs / N. Dhankhar, T. Singh, A. Buragohain, R. Tiwari. 2022.

*А. В. Никитин\**

кандидат технических наук, доцент

*М. А. Кухарь\**

студент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## МАШИННОЕ ОБУЧЕНИЕ БЕСПИЛОТНЫХ АВТОМОБИЛЕЙ В МЕТАВСЕЛЕННОЙ ГУАП

Рассмотрена задача безаварийного движения автомобиля в 3D-среде на основе машинного обучения с подкреплением.

**Ключевые слова:** метавселенная, машинное обучение с подкреплением, беспилотные автомобили.

*A. V. Nikitin\**

PhD, Tech., Associate Professor

*M. A. Kukhar\**

Student

\*St. Petersburg State University of Aerospace Instrumentation

## MACHINE LEARNING FOR SELF-DRIVING CARS IN THE SUAI METAVERSE

The problem of accident-free movement of a car in a 3D environment is considered based on machine learning with reinforcement.

**Keywords:** metaverse, self-driving cars, reinforcement learning.

Использование метавселенных для обучения беспилотных автомобилей (БА) все еще является новой тенденцией, но у них есть потенциал произвести революцию в области разработки и тестирования БА. Метавселенные, по сравнению с реальными средами, предоставляют безопасную, масштабируемую и настраиваемую платформу для обучения БА, обеспечивают экономическую эффективность, сокращение времени разработки и передачу обучения. В качестве примеров можно привести как производителей автомобилей, так и ИТ-компании, например Tesla, Hyundai, Volvo, Waymo, Microsoft, NVIDIA, Massachusetts Institute of Technology и др. [1].

Обучение БА движению в городских условиях требует учета множества факторов, таких как плотность трафика (автомобилей, пешеходов и других объектов), разнообразие дорожных условий (перекрестки, светофоры, пешеходные переходы, одностороннее движение и др.), непредсказуемое поведение других участников движения (пешеходы, автомобили).

БА в средах часто должны принимать последовательные решения, чтобы достичь долгосрочной цели. Машинное обучение с подкреплением (МОП) хорошо подходит для таких задач, так как позволяет БА учитывать будущие награды при принятии текущего решения [2].

Метавселенная ГУАП представляет собой 3D-модель зданий ГУАП и прилегающей территории, в которой географически распределенные пользователи могут взаимодействовать в реальном времени друг с другом и с цифровыми объектами через своих аватаров и которая реализована на Unity [3].

Использование МОП для обучения БА в 3D-сцене Unity включает определение состояния и действий агента, обучение с помощью алгоритмов МОП и интеграцию с Unity через инструменты, такие как Unity ML-Agents Toolkit. Этот подход позволяет безопасно и эффективно обучать алгоритмы автономного вождения в виртуальной среде [4].

Цель работы – обучить 3D-модель автомобиля (агент) следовать по построенному маршруту в интерактивной 3D-модели фрагмента городской среды в метавселенной. 3D-модель автомобиля управляется с помощью руля, педали газа и тормоза. Фрагмент городской среды представляет собой сеть дорог в метавселенной с несколькими нерегулируемыми перекрестками. В ходе следования по маршруту агент может ускоряться, замедляться, перестраиваться и проезжать перекрестки. Задача алгоритма обучения – тренировка агента безаварийному (избегание столкновений) и динамичному (стремление водителя к быстрому прохождению маршрута без лишних торможений) вождению.

Рассмотрим основные элементы МОП.

Среда – 3D-сцена, созданная в Unity, содержит фрагмент улиц с несколькими перекрестками и различными видами организации дорожного движения (улицы с односторонним и двусторонним движением, многополосные и однополосные дороги).

Агент – 3D-модель автомобиля, оснащенная следующими виртуальными сенсорами: лучи (16 шт.) для определения расстояния до ближайших объектов и их приоритета; датчик положения рулевого колеса; датчик скорости.

Действия, которые может совершать автомобиль: акселерация – ускорение; торможение – снижение скорости. Степень поворота рулевого колеса вычисляется алгоритмически, исходя из пространственного расположения автомобиля по отношению к цели движения.

Вознаграждение – это обратная связь, которую получает автомобиль всякий раз, когда он выполняет определенное действие: медленное движение – минус 0.01; столкновение – минус 0.5; достижение цели – плюс 1.0; нажатие на педаль газа – плюс 0.05; нажатие на педаль тормоза – минус 0.02.

Состояние описывает текущую ситуацию в данный момент, которой в данном случае будет положение на дороге с учетом информации от лучей (вектор пар «расстояние – приоритет», расстояние – число от 0 до 1, приоритет – число от 0 до 1); положения руля (число от -1 до 1); скорости автомобиля (число от 0 до 1).

Сеть дорог представлена в виде ориентированного графа, определяющего различные маршруты движения автомобиля (рис. 1).




Рис. 1. Размеченная сеть дорог

Вершины графа соответствуют координатам точек разметки дорог, а дуги – фрагменту маршрута с весом, рассчитанным на основе расстояния между начальной и конечной точкой, нагрузкой трафика на участок (отношение суммы длин расположенных на участке транспортных средств к длине участка), приоритетом движения на участке (очередность проезда пересечения траекторий).

Маршрут представляет собой упорядоченный набор точек сети дорог (вершин графа) от точки нахождения автомобиля до конечной точки, которая задается вручную.

При следовании по маршруту на основе алгоритма A\* последовательно происходит вычисление кратчайшего пути между конечной точкой и текущей в маршруте (начиная от начальной), что позволяет учитывать возможное изменение дорожной ситуации. Процесс повторяется до достижения конечной точки.

Концепция состояний в поиске пути возникает из различных координат, в которых агент может находиться, пока он ищет правильную траекторию. Положение агента в определенном месте плоскости (или вершины графа) является состоянием. Агент решает перейти в определенное состояние (изменение места или вершины графа) для максимизации вознаграждения. Пространство действий включает различные направления, в которых агент может двигаться, чтобы проверить альтернативные более короткие пути к месту назначения.

Этапы обучения.

1. Создание сцены Unity со средой.
2. Расположение автомобиля на сцене.
3. Инициализация тестового маршрута для автомобиля путем указания начальной и конечной точки маршрута.
4. Запуск утилиты ML-Agents (создается виртуальное окружение для обучения, выбор режима: продолжить обучение, начать с нуля на основе алгоритма Proximal Policy Optimization (PPO)).
5. Запуск сцены в Unity.
6. ML-Agents начинает циклично проводить эпизоды обучения путем ускоренной симуляции сцены, параллельно обучая модель.
7. Прерывание обучения, утилита ML-Agents формирует файл обученной модели.
8. Импорт файла модели в Unity.

Результат обучения можно оценить визуально и статистически. Визуальная оценка заключается в субъективном анализе манеры вождения агента человеком. Производится путем запуска сцены с обученным агентом, оценивается реакция агента на другие автомобили. Автомобиль, имеющий меньший приоритет на перекрестке или выполняющий маневр перестроения, должен притормозить перед другими участниками движения с высшим приоритетом. На рис. 2 автомобиль (горят стоп-сигналы) пропускает другой автомобиль, с более высоким приоритетом.




Рис. 2. Взаимодействие автомобилей

Статистическая оценка заключается в анализе данных о столкновениях и прохождении маршрута агента на разных этапах обучения. На рис. 3 представлена зависимость числа столкновений на 1000 итераций от общего числа итераций, статистика безаварийных проездов маршрута одним агентом. С ростом числа итераций плотность столкновений уменьшается, что свидетельствует о том, что агент обучается избегать столкновений. По горизонтальной оси расположены номера сотен итераций, по вертикальной – процент безаварийных поездок на сто поездок. С начала обучения можно наблюдать процент безаварийных поездок, объяснимый тем, что агенты стараются не разогнаться. Затем начинается просадка в количестве безаварийных поездок, когда агент начинает двигаться более быстро. Волнообразность проявления безаварийности как таковой объясняется элементом случайности дорожной ситуации




Рис. 3. Статистика безаварийных поездок

В дальнейшем планируется улучшение обучения БА за счет увеличения количества итераций, усложнения дорожных ситуаций (проезд регулируемых и нерегулируемых перекрестков, взаимодействие с другими автомобилями, неигровыми персонажами и дронами).

#### Библиографический список

1. The hit of Metaverse in Self Driving Application Development – The Alternate for the Reality. URL: <https://rosh.ai/the-hit-of-metaverse-in-self-driving-application-development-the-alternate-for-the-reality/> (дата обращения: 31.08.2024).
2. Self-Driving Cars With Convolutional Neural Networks. URL: <https://neptune.ai/blog/self-driving-cars-with-convolutional-neural-networks-cnn> (дата обращения: 31.08.2024).
3. Метавселенная ГУАП. URL: <https://guap.ru/n/labvr> (дата обращения: 31.08.2024).
4. Abhilash Majumder. Deep Reinforcement Learning in Unity: With Unity ML Toolkit. Apress, 2021. 564 p.

*М. Ю. Охтилев\**

доктор технических наук, профессор

*В. Н. Коромысличенко\**

кандидат технических наук

*П. А. Охтилев\**

кандидат технических наук

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В ПРОГРАММНОЙ ИНЖЕНЕРИИ. ВОПРОСЫ РАЗРАБОТКИ И ПРОЕКТИРОВАНИЯ ПРОГРАММНОЙ ПРОДУКЦИИ

С позиций искусственного интеллекта рассматриваются вопросы разработки и проектирования программной продукции. Показывается, что алгоритм создания программы подразумевает процесс декларативного проектирования, основанный на концептуальном моделировании и онтологическом описании стадий жизненного цикла. Декларативное проектирование может быть описано в рамках логико-лингвистической модели, при этом экспертами разрабатываются графы знаний, на базе которых составляются частные онтологии различных стадий жизненного цикла.

**Ключевые слова:** модель предметной области, онтология, данные, знания, графы, прикладное программное обеспечение, искусственный интеллект, программная инженерия, инженерия знаний.

*M. Yu. Okhtilev\**

Dr. Sc., Tech., Professor

*V. N. Koromyslichenko\**

PhD, Tech.

*P. A. Okhtilev\**

PhD, Tech.

\*St. Petersburg State University of Aerospace Instrumentation

## ARTIFICIAL INTELLIGENCE IN SOFTWARE ENGINEERING. ISSUES OF DEVELOPMENT AND DESIGN OF SOFTWARE PRODUCTS

The paper from the perspective of artificial intelligence addresses issues of software development and design. It is shown that the algorithm of program creation implies a process of declarative design, based on conceptual modeling and ontological description of stages of the life cycle. Declarative design can be described within the framework of a logical-linguistic model, with experts developing knowledge graphs on the basis of which private ontologies of different stages of the life cycle are compiled.

**Keywords:** subject area model, ontology, data, knowledge, graphs, application software, artificial intelligence, program engineering, knowledge engineering.

### Введение

Программная инженерия (ПИ) может рассматриваться как научная дисциплина, которая является значимым разделом информатики, определяющим эффективность разработки программной продукции (ПП). Программная инженерия начиналась с изучения успешных практик разработки ПП, однако в настоящее время стало очевидным, что в ней решающее значение имеют процессы обработки информации, извлечения из нее знаний, а также накопление и трансформация знаний на стадиях жизненного цикла (ЖЦ) в техническое задание, проект, в собственно программную продукцию. Возможность достижения указанных целей лежит в области искусственного интеллекта (ИИ), философии и методологии науки [1]. Преобразования знаний осуществляются при исследовании и построении модели предметной области, анализе потребностей заказчика (пользователей), при разработке требований к ПП, при проектировании, кодировании, тестировании и сопровождении ПП.

Обеспечение интероперабельности, когнитивного согласования, на стыках стадий жизненного цикла, предполагает объединение моделей данных и структурно-функциональных моделей предметной области, при этом в основу функциональности ПП могут быть положены принципы декларативного проектирования программного обеспечения (ПО) и реализации исполнительных систем, осуществляющих вычисления по заложенным в систему знаниям [1]. Говоря простыми словами, любой алгоритм, так же как и любая модель данных, должен быть представлен декларативными спецификациями в виде интерпретируемых исполнительными системами наборов данных. Указанный подход может быть реализован на основе унифицированных онтологических полимодельных комплексов, обеспечивающих всю систему едино интерпретируемой терминологией. При этом задание таких исполнимых спецификаций должно осуществляться экспертами в процессе анализа и разработки модели предметной области (ПрО) – базы знаний на проблемно-ориентированных языках с визуальной, графической, нотацией (с учетом положения, что навыки программирования у экспертов-технологов отсутствуют) [2; 3].



## Онтологическое моделирование в декларативном проектировании прикладного ПО

Решение сложных задач интероперабельности обеспечивается применением интеллектуальных систем, в которых основная трудность решения связана с использованием слабоформализованных знаний специалистов-практиков, где логическая (или смысловая) обработка информации превалирует над вычислительной. Изучение методов проектирования таких систем находится в поле теории искусственного интеллекта (ИИ или инженерии знаний) и предполагает разработку моделей и методов извлечения, структурирования, формализации (представления) знаний для их обработки на стадиях ЖЦ.

В этом случае существенна цепочка «данные – информация – знания», во-первых, предполагающая необходимость определения семантики (смысла) на данных на основе интерпретации синтаксических выражений, а во-вторых, позволяющая говорить о гносеологической цепочке представления знаний при выборе языков моделирования: факт, обобщенный факт, эмпирический закон, теоретический закон [4–6].

В попытках формализации проблемно-ориентированных языков представления знаний и преодоления проблем извлечения эмпирического опыта экспертов с 80-х гг. XX в. и по настоящее время высокими темпами развивается направление, связанное с использованием онтологического моделирования как основы организации БЗ в ПИ. Под онтологией необходимо понимать точную спецификацию концептуализации, где под концептуализацией понимается структура реальности, рассматриваемая независимо от словаря предметной области конкретной ситуации (определение Т. Груббера) [4].

Принято считать, что онтологии используются как способ формального описания используемых понятий и их взаимосвязей при проектировании ПП [7; 8]. Однако необходимо отметить, что в зависимости от практического приложения онтологии могут применять в гораздо более широком спектре задач, связанных с обеспечением сквозного взаимодействия разнородных систем с сохранением семантики передаваемой информации.

В то время, как концептуальная модель/схема описывает структуру и, возможно, поведенческие аспекты ПрО, онтология определяет понятийную систему ПрО, т. е. совокупность ее понятий (концептов) и отношений между ними. Главное различие состоит в том, что концептуальная модель ПрО отображает релевантные целям разработки сущности, их определения и связи между ними, а онтология – понятия (категории) ПрО и семантические отношения между ними. Онтология, таким образом, логически дополняет описание ПрО, представленное ее концептуальной схемой. На сегодняшний день в технологиях БЗ формируется направление, в котором предусматривается использование онтологии в качестве высокоуровневых концептуальных схем ПрО и основы интерфейсов разнородных систем БЗ, позволяющих формулировать запросы данных в терминах онтологий и вместе с тем осуществлять рассуждения (reasoning) на онтологиях. Механизмы основанные на онтологии интерфейса становятся при этом посредниками между пользователем с его информационными потребностями, выраженными в терминах онтологии, и традиционной системой БД. Такие системы называют системами доступа к данным, основанными на онтологиях (Ontology-Based Data Access Systems, OBDA-systems, OBDA-системами) [7].

В качестве теоретического аппарата для формализации онтологий часто используется дескрипционная логика [8–11]. Дескрипционные логики – это семейство формализмов для структурированного представления знаний, созданное для привнесения формальной семантики в структурированные, не основанные на логике, языки представления знаний – семантические сети и языки фреймов. Они реализуют компромисс между выразительными возможностями и вычислительной сложностью рассуждений, сочетая черты разрешимых фрагментов логики первого порядка и модальных логик с некоторыми расширениями, поскольку некоторые аспекты реального мира трудно представить в этих логиках [9].

Основная сложность при этом состоит в том, что почти все обобщения имеют исключения или соблюдаются только до определенной степени (принцип естественных разновидностей). В связи с этим необходимо отделять типовые сущности от исключительных (индивидов). Второй важный аспект – использование категорий. Суждение о конкретных объектах проводится на уровне категорий с заданием на них отношений (таксономии, партономии, тезаурусы и пр.), что позволяет задавать описания и ограничения этих объектов. Дескрипционная логика позволяет явно разрешать эти проблемы и в ряде случаев имеет более низкую вычислительную сложность, чем, например, выражения в логике с двухместными предикатами. Эти положения позволяют утверждать о перспективности применения онтологий для вычислительно сложных задач, связанных с совместным манипулированием разнородной информацией из различных источников данных.

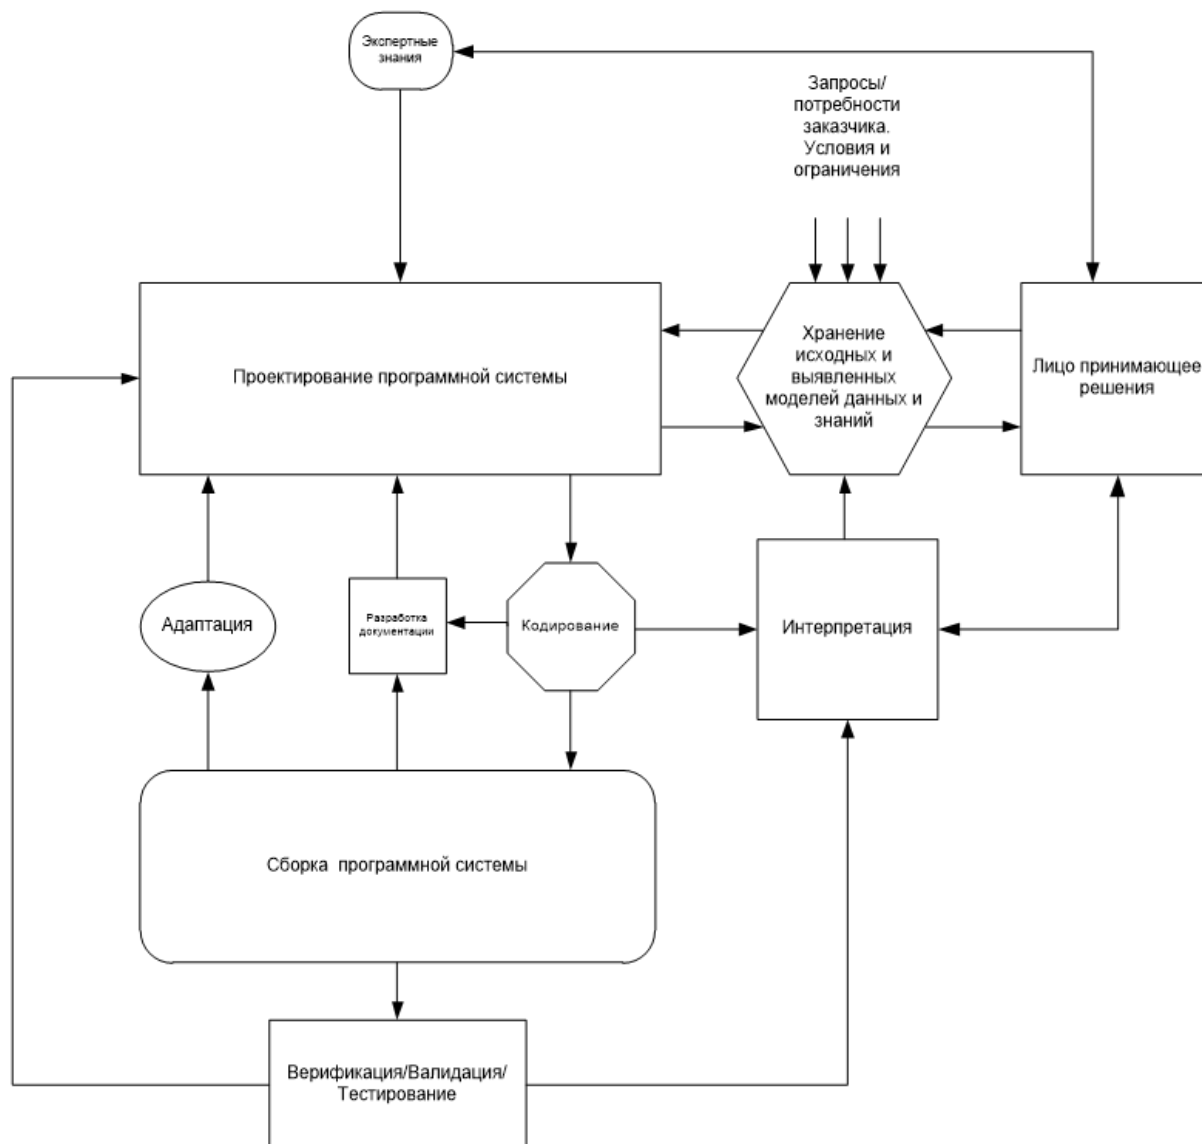
Такие принципы обобщения и категорийное описание позволяют задавать поверх разнородных моделей данных существующих и унаследованных ПП унифицированные модели представления знаний, основанные на онтологиях. Эта особенность позволяет интегрировать разнородную информацию, представленную на различных платформах, и обеспечить создание единой интерпретируемой системы БЗ, которая может стать основой реализации интероперабельности на стыках стадий жизненного цикла ПП.

## Практические вопросы декларативного проектирования прикладного ПО

Декларативное проектирование прикладного ПО базируется на системном анализе ПрО (анализе исходных данных и разработке модели ПрО), разработке спецификаций требований, разработке кода, тестировании и сопровождении в соответствии с концепцией управления жизненным циклом программных систем [3]. Анализ исходных данных и разработка спецификаций требований – это важнейший этап проектирования, опирающийся на экспертные знания. Экспертные знания о ПрО существенно сложнее современных логических, формальных или иных представлений таких моделей. Существует значительный разрыв между абстрактным, экспертным

представлением модели ПрО и ее практическим выражением в виде БД или БЗ. Экспертные знания логически не формализованы, постоянно дополняются и изменяются. В таких условиях использование традиционных БД/БЗ затруднено, в этом случае рассмотрение возможности применения нетрадиционных подходов к построению модели ПрО – графовых, документарных, ключ-значение и других (NoSQL) – представляется достаточно обоснованным.

В рамках логико-лингвистической парадигмы [5] создание модели ПрО можно представить в виде модели разработки, схема которой представлена на рисунке. Логико-лингвистическая модель разработки предполагает преобразование данных, представленных в графической или лингвистической форме, в логическую форму (по аналогии с логико-лингвистической системой управления Д. А. Поспелова [5]).



Логико-лингвистическая модель формирования схемы предметной области

Представленная модель относится к семиотическим системам и на ее основе может быть разработана модель любой ПрО в виде онтологий с использованием дискрипционных логик или других языковых формализмов.

Выбор модели представления знаний на различных этапах трансформации экспертных знаний в онтологию имеет существенное значение и не может быть произвольным. На первой стадии осуществляется извлечение требований (Requirements Elicitation), которое проводится на основании анализа замысла заказчика, исходных данных, модели предметной области и потребностей заинтересованных лиц, в виде интервьюирования, сценарного анализа, моделирования и прототипирования. При этом экспертные знания должны быть представлены в лингвистическом и графическом виде для того, чтобы избежать когнитивных потерь знаний при их передаче на следующую стадию трансформации в соответствии с этапом жизненного цикла программы [8].

Извлечение требований при онтологическом подходе предполагает составление перечня терминов, понятий и их определений. Термины и понятия должны располагаться в перечне с учетом отношений и зависимостей, существующих между ними. Таким образом, создается структурированная онтологическая модель – глоссарий/тезаурус, которая естественным образом может быть представлена в виде графа помеченных свойств

(Labeled Property Graph – LPG) [12]. Далее на основании графа глоссария и исследования ПрО разрабатываются LPG-графы информационных процессов и релевантных им метаданных, соответствующие целям и задачам программной системы, определяются выявленные вычислительные задачи и их взаимосвязи. На базе анализа полученных LPG-графов формируются концептуальная архитектура и спецификация требований. Полученная система изоморфных графов используется как верхний уровень описания требований и архитектуры программной системы как графы знаний предметной области, на базе которых могут быть разработаны различные частные онтологии: требований заказчика, спецификаций требований, описания архитектуры и пр.

LPG-графы могут быть разработаны экспертами, не имеющими навыков программирования, а формализованное описание онтологий – специалистами инженерии знаний. При этом графы знаний обеспечивают валидацию и верификацию онтологий, легкое добавление и изменение знаний.

### Заключение

Онтологическое моделирование и концептуализация лежат в основе декларативного проектирования, которым обеспечивается достижение когнитивного согласования, интероперабельности, знаний на стыках стадий ЖЦ ПП. При этом на начальных стадиях жизненного цикла с помощью экспертных знаний моделируются структурные отношения и связи между информационными понятиями, релевантными терминам и понятиям ПрО, создается граф знаний ПрО. Полученный экспертами граф лежит в основе частных онтологий различных стадий жизненного цикла программных систем.

### Библиографический список

1. Юсупов Р. М. Городецкий В. И. Искусственный интеллект: метафора, наука и информационная технология // Мехатроника, автоматизация, управление. 2020. Т. 21, № 5. С. 282–293.
2. NCOIC Interoperability Framework (NIF v. 2.1) and NIF Solution Description Reference Manual (NSD-RM v. 1.2). NCOIC, 2008. 125 p.
3. Охтилев М. Ю., Коромысличенко В. Н., Охтилев П. А. Программная инженерия. Инженерный подход: учеб. пособие. СПб.: ГУАП, 2021. 163 с.
4. Гаврилова Т. А., Кудрявцев Д. В., Муромцев Д. И. Инженерия знаний. Модели и методы: учебник. СПб.: Лань, 2016. 324 с.
5. Поспелов Д. А. Искусственный интеллект: в 3 кн. Кн. 2. Модели и методы: справочник. М.: Радио и связь, 1990. 304 с.
6. Тыгу Э. Х. Концептуальное программирование. М.: Наука, 1984. 256 с.
7. Бова В. В. Онтологическая модель интеграции данных и знаний в интеллектуальных информационных системах // Вычислительная техника и информатика. Известия ЮФУ. Технические науки. 2015. № 4(165). С. 225–237.
8. Охтилев П. А. Алгоритмы и онтологические модели информационно-аналитической поддержки процессов создания и применения космических средств: дисс. ... канд. техн. наук. СПб.: СПИИРАН, 2019. 416 с.
9. Вахитов А. Р., Новосельцев В. Б. Преимущества дескриптивной логики при обработке знаний // Известия Томского политехнического университета. 2008. Т. 313, № 5. С. 73–76.
10. McGuinness Deborah L., Nardi Daniele, Patel-Schneider Peter F. The description logic handbook: Theory, implementation, and applications. 2007. 505 p.
11. Murthy S. Automatic construction of decision trees from data: A multidisciplinary survey. Data Mining and Knowledge Discovery // Kluwer Academic Publishers. 1998. 49 p.
12. NoSQL: новая методология разработки нереляционных баз данных: пер. с англ. М.: Вильямс, 2013. 192 с.

*Х. А. Примова\**

доктор технических наук

*Р. Ахмедова\*\**

докторант

*Ж. У. Каршибоев\**

студент

\*Самаркандский филиал Ташкентского университета информационных технологий им. Мухаммада аль-Хоразмий, Узбекистан

\*\*Ташкентский университет информационных технологий им. Мухаммада аль-Хоразмий, Узбекистан

## ВЫБОР СТРОИТЕЛЬНОГО МАТЕРИАЛА НА ОСНОВЕ АЛГОРИТМА БИПОЛЯРНОГО КОМПЛЕКСНОГО АНАЛИЗА

Для выбора материала недостаточно технико-экономических факторов, необходимо учитывать факторы окружающей среды. Статья посвящена выбору строительного материала с использованием алгоритма биполярного комплексного анализа. Представлен выбор параметров на основе нечеткой системы вывода и алгоритма биполярного комплексного анализа, а также предлагается решение путем сведения к системе линейных уравнений посредством оптимизации этих параметров.

**Ключевые слова:** строительные материалы, алгоритм нечеткого вывода, выбор материала, строительная модель.

*Kh. A. Primova\**

Dr. Sc., Tech.

*R. Ahmedova\*\**

Doctoral Student

*Zh. U. Karshiboev\**

Student

\*Samar kand Branch of Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Uzbekistan

\*\*Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Uzbekistan

## BUILDING MATERIAL SELECTION BASED ON THE BIPOLAR COMPLEX ANALYSIS ALGORITHM

Technical and economic factors are not enough to select the material, it is necessary to take into account environmental factors. The article is devoted to the selection of building material using the algorithm of bipolar complex analysis. This study presents the selection of parameters based on the fuzzy inference system and the algorithm of bipolar complex analysis, and proposes a solution by reducing to a system of linear equations by optimizing these parameters.

**Keywords:** building materials, fuzzy inference algorithm, selection of material, building model.

Сегодня одна из самых эффективных стратегий достижения качественного, прочного и устойчивого строительства – выбор материалов, минимизирующих воздействие на окружающую среду. Представленное исследование является образцом для выбора лучшего экологически чистого материала, необходимого для зданий и сооружений. Следовательно, оценка жизненного цикла материала – это влияние этих материалов на окружающую среду, а также учет всех этапов жизненного цикла данного материала. Сравнение приоритетов критериев рассчитывается в опросах, полученных при консультации с экспертами. Эта модель определяет важность критериев при выборе экологически чистых материалов. Требования к выбору материалов включают не только технические и экономические факторы, но и факторы окружающей среды [1]. Однако многие цели часто противоречат друг другу [2]. Как правило, в таких областях, как выбор материалов, надежный опыт более распространен, чем цифровые технологии, поскольку существует много вариантов и переменных, влияющих на выбор, требуется более конкретный подход.

В нашем анализе, объединив расчеты по количественным (финансовым) и качественным (индикаторным) показателям, можно значительно усилить подход к анализу экспертов, рассматривая их не только в статическом, но и в динамическом состоянии. Но доступные методы не предоставляют таких возможностей для аналитиков [3].

Идея применения непересекающихся множеств к интеллектуальному отбору строительного материала [4–6] родилась в работах как способ борьбы не только со статистическими, но и с лингвистическими непересекающимися множествами, т. е. непересекающимися множествами в естественных языках. Если говорят, что качество строительного материала «нехорошо», а значения того или иного показателя «удовлетворительны», то для мыслей подобного рода придется искать формализмы и способы количественного выражения с целью выразить

строгим математическим языком, что именно подразумевается. Необходимо не только понимать, но и делать научные выводы, используя полученные нераскрытые утверждения [1; 6].

На основании данных, полученных на первом этапе, каждому показателю присваивается экспертная оценка предлагаемых характеристик, соответствующая определенному значению. Каждый показатель является результатом экспертного заключения.

**Этап 1 (комплекты).** Мы включаем следующие основные наборы и наборы частей падежей, выраженные на естественном языке.

А. Полный комплект строительных материалов  $E$  разделен на три набора деталей в следующем виде:

$E_1$  – множество состояний «качество строительных материалов отличное  $\langle 0,1 \rangle$ »;

$E_2$  – множество состояний «качество строительных материалов среднего уровня  $\langle -0.5, 0.5 \rangle$ »;

$E_3$  – множество состояний «строительный материал низкого качества  $\langle -1, 0 \rangle$ ».

В. Выбор подходящего материала для комплекта полный комплект  $G$ , соответствующий его цене, разделен на 3 подмножества:

$G_1$  – множество «строительные материалы с высокой потребительской ценой  $\langle 0,1 \rangle$ »;

$G_2$  – множество «строительные материалы со средней потребительской ценой  $\langle -0.5, 0.5 \rangle$ »;

$G_3$  – множество «строительные материалы с низкой потребительской ценой  $\langle -1, 0 \rangle$ ».

Здесь и далее мы предполагаем, что показатель  $G$  по определению принимает значения от нуля до единицы.

Для произвольно полученного отдельного качественного или финансового показателя  $X_i$  полный набор его значений  $B_i$  делится на три подмножества:

$B_{i1}$  – подмножество « $X_i$  индикатор качества очень низкого уровня  $\langle -1, 0 \rangle$ »;

$B_{i2}$  – подмножество « $X_i$  индикатор качества среднего уровня  $\langle -0.5, 0.5 \rangle$ »;

$B_{i3}$  – подмножество « $X_i$  индикатор качества высокого уровня  $\langle 0, 1 \rangle$ ».

Здесь и далее подразумевается следующее.

1. Отдельно взятый рост показателя  $X_i$  коррелирует со снижением его качества, которое происходит с улучшением состояния рассматриваемого материала. Если для этого показателя наблюдается противоположный ток, то в ходе анализа его необходимо заменить на противоположный [3].

2. Относительно соответствия  $B$ ,  $E$  и  $G$  выполняется дополнительное условие в виде: если все показатели имеют уровень детализации  $B_{ij}$  в соответствии с классификацией в ходе анализа, то качество материала классифицируется как  $E_j$ , а стоимость строительного материала – как  $G_j$ . Выполнение этого условия влияет, с одной стороны, на количественно правильную классификацию уровней показателей (см. этап 5 метода), а с другой – на правильное определение уровня значимости показателя в системе оценок (см. этап 3 метода).

**Этап 2 (индикаторы).** Построим  $X = \{X_i\}$  наборов отдельных показателей с общим числом  $N$ , которые, по мнению экспертов-аналитиков, с одной стороны, влияют на интеллектуальный выбор материала, а с другой – оценивают аспекты плотности, теплопроводности, пористости, при которых свойства материала различаются (избегая дублирования показателей с точки зрения их важности для анализа).

**Этап 3 (актуальность).** Каждому показателю  $X_i$  мы ставим в соответствие степень его значимости для анализа  $r_i$ . Для оценки этого уровня необходимо расположить все показатели в порядке убывания их значимости таким образом, чтобы выполнялось следующее правило:

$$r_1 \geq r_2 \geq \dots, r_N. \quad (1)$$

Если система показателей построена в порядке убывания их значимости, то значимость  $i$ -го показателя определяется по правилу Фишберна  $r_i$  [5]:

$$r_i = \frac{2(N-i+1)}{(N-1)N}. \quad (2)$$

Правило Фишберна гласит, что ничего не известно о значениях показателей, кроме (1). Тогда оценка (2) соответствует максимальному значению энтропии неопределенности имеющейся информации об исследуемом объекте.

Если все показатели имеют одинаковую степень важности (система с равным преимуществом), то

$$r_i = 1/N. \quad (3)$$

**Этап 4 (классификация по уровню расхода строительного материала).** Классификация текущего значения показателя степени риска  $g$  строится как критерий разделения этого набора на наборы деталей (табл. 1).

## Части названия коллекций

Диапазон значений $G$	Части названия коллекций
$-0.4 < g < 0$ $0.6 < g < 1$	$G_1$ – «потребительские цены на строительный материал высоки»
$-0.7 < g < -0.4$ $0.3 < g < 0.6$	$G_2$ – «средние потребительские цены на строительные материалы»
$-1 < g < -0.7$ $0 < g < 0.3$	$G_3$ – «низкие потребительские цены на строительные материалы»

**Этап 5 (разделение значений показателей на классы).**

Построим классификацию  $X$  текущих значений показателей  $x$  в качестве критерия деления полного набора их значений на наборы сечений вида  $B$  (табл. 2).

Таблица 2

## Критерий разделения на подмножества

Название индикатора	Критерий разделения на подмножества		
	$V_{i1}$	$V_{i2}$	$V_{i3}$
$X_1$	$x_1 < -b_{11}$ $x_1 < b_{11}$	$-b_{11} < x_1 < -b_{12}$ $b_{11} < x_1 < b_{12}$	$-b_{12} < x_1 < -b_{13}$ $b_{12} < x_1 < b_{13}$
...	...	...	...
$X_i$	$x_i < -b_{i1}$ $x_i < b_{i1}$	$-b_{i1} < x_i < -b_{i2}$ $b_{i1} < x_i < b_{i2}$	$b_{i2} < x_i < b_{i3}$ $-b_{i2} < x_i < -b_{i3}$
...	...	...	...
$X_N$	$x_N < -b_{N1}$ $x_N < b_{N1}$	$-b_{N1} < x_N < -b_{N2}$ $b_{N1} < x_N < b_{N2}$	$-b_{N2} < x_N < -b_{N3}$ $b_{N2} < x_N < b_{N3}$

**Этап 6 (оценка уровней показателей).** Проводим оценку текущих уровней показателей и помещаем полученные результаты в табл. 3.

Таблица 3

## Оценка уровней показателей

Название индикатора	Текущая стоимость
$X_1$	$x_1$
...	...
$X_i$	$x_i$
...	...
$X_N$	$x_N$

**Этап 7 (разделение уровней показателей на классы).**

Разделим текущие значения  $x$  на классы по критериям из табл. 4.

Таблица 4

## Разделение уровней показателей на классы

Название индикатора	Результаты разложения на классы по частным множествам		
	$V_{i1}$	$V_{i2}$	$V_{i3}$
$X_1$	$\lambda_{11}$	$\lambda_{12}$	$\lambda_{13}$
...	...	...	...
$X_i$	$\lambda_{i1}$	$\lambda_{i2}$	$\lambda_{i3}$
...	...	...	...
$X_N$	$\lambda_{N1}$	$\lambda_{N2}$	$\lambda_{N3}$

Здесь  $\lambda_{ij} = 1$ , если  $b_{i(j-1)} < x_i < b_{ij}$ , в противном случае  $\lambda_{ij} = 0$  (если значение не попадает в выбранный диапазон классификации).

**Этап 8 (оценка уровня риска).** Теперь выполним формальные арифметические действия по оценке степени риска  $g$  при выборе строительного материала:

$$g = \sum_{j=1}^3 g_j \sum_{i=1}^N r_i \lambda_{ij}, \quad (3)$$

где

$$g_j = -0.1 + 0.8(j-1), g_j = 0.9 - 0.2(j-1), \quad (4)$$

$\lambda_{ij}$  определяется по таблице 3, а  $r_i$  – по формулам (3) или (4).

Основное содержание формул (3) и (4) следующее. При оценке качества строительного материала  $E$  и потребительских цен на строительные материалы  $G$  (сумма в (4)) мы сначала оцениваем вес того или иного набора деталей в  $B$ . Эти веса затем участвуют во внешней сумме для определения среднего значения показателя  $g$ , где  $g_j$  – среднее значение  $g$ , полученное из соответствующих интервалов табл. 1 на этапе 4 метода.

**Этап 9 (языковое распознавание).** Полученное значение уровня потребления разбиваем на классы на основе данных табл. 1. Таким образом, наш вывод об уровне потребления для предприятия принимает лингвистическую форму.

Таким образом, мы наблюдаем именно это явление, заключающееся в том, что высокая автономия предприятия – фактически единственное хорошее, что в нем есть.

Алгоритм и оценки используются для объединения набора показателей эффективности (конкретных целей) в единое измерение эффективности (общую цель), другими словами, модели оценки представляют собой механизм преобразования конкретных целевых функций в обобщенную целевую функцию [2]. Выбор этих факторов основан на рекомендациях экспертов. Этот алгоритм может широко использоваться в процессе принятия решений.

#### Библиографический список

1. Aminzadeh F., Mohammad J. PTR Prentice Hall, Englewood, cliffs, New Jersey Soft computing 07632. 1994. 301 p.
2. Deng Y. M, Edwards K. L. The role of materials identification and selection in engineering design // *Materials and Design*. 2007. № 28.
3. Chang-Chun Zhou, Guo-Fu Yin, Xiao-Bing Hu. Multi-objective optimization of material selection for sustainable products // *Materials and Design*. 2009. № 30. P. 1209–1215.
4. Primova H. A., Iskandarova F. N., Gaybulov Q. M. Accounting Experience Between Fuzzy Integraland Z-numbers // *Advances in Intelligent Systems and Computing*. 2021. 1323 AISC. P. 40–46.
5. Примова Х. А., Гайбулов К. М., Вайдуллаева М. Ф. Подбор строительного материала с помощью задачи альтернатив // *Проблемы вычислительной и прикладной математики*. 2021. № 3(33). С. 123–130.
6. Primova H., Gaybulov Q., Isroilov I. Selection of building material using the decision-making system // *International Conference on Information Science and Communications Technologies: Applications, Trends and Opportunities, ICISCT 2021, Tashkent, Uzbekistan, 3–5 Nov. 2021*. P. 1–3.

**О. Раббонакулов\***

студент

**Х. Б. Мирзокулов\***

кандидат физико-математических наук

\*Самаркандский филиал Ташкентского университета информационных технологий имени Мухаммада аль-Хоразмий, Узбекистан

## АЛГОРИТМ И МОДЕЛЬ СИСТЕМЫ ДИСТАНЦИОННОГО УПРАВЛЕНИЯ СВЕТОФОРАМИ НА ОСНОВЕ ИНТЕРНЕТА ВЕЩЕЙ

Рассматриваются вопросы анализа и практического применения светофоров, методов дистанционного управления с использованием телекоммуникационных технологий в густонаселенных городских районах. Разработаны практические решения для дистанционного управления светофорами с использованием встроенных системных элементов.

**Ключевые слова:** светофоры, дистанционное управление, умный город, ESP32.

**O. Rabbonaqlulov\***

Student

**Kh. B. Mirzokulov\***

PhD, Phys.-Math.

\*Samar kand Branch of Tashkent University of Information Technologies named after Muhammad al-Khwarizmi, Uzbekistan

## ALGORITHM AND MODEL OF REMOTE-CONTROL SYSTEM OF TRAFFIC LIGHTS BASED ON IOT

In this paper, the issues of analysis and practical application of traffic lights, remote control methods using telecommunication technologies in densely populated urban areas are considered. Practical solutions for remote control of traffic lights using built-in system elements have been developed.

**Keywords:** traffic lights, remote control, smart city, ESP32.

### 1. Main part

The Republic of Uzbekistan is one of the most dynamically developing countries. Accordingly, it cannot be said that not every system, in particular a road safety system that ensures comfortable movement of cars, is perfect. With this in mind, we need to develop this system. The biggest problem in the traffic system is congestion on the roads due to an increase in the flow of cars. This problem is observed in every city. As a result, someone is late for work, someone suffers from pain, or as a result of cars being in traffic jams for a long time, as a result of the release of CO<sub>2</sub> (carbon dioxide), nature is also very much damaged, and similar problems happen very often.

According to preliminary estimates, in 1 year, carbon dioxide emissions as a result of road accidents in Uzbekistan amount to about 350,000 kg, and this indicator is growing, not decreasing, which is associated with an increase in the number of cars among the population. But there is no work to prevent congestion. This can prevent a global problem in Uzbekistan. In large countries, such as China, the United States and European countries, such problems have already been eliminated. We can take a template from them. For example, the no traffic program, we can also implement such a program that will bring much greater benefits to the state economy. Well, the solution of the problem will be beneficial to both society and the state. The assessment of this issue is put forward as the main goal of this work [1–5].

The Notraffic program uses artificial intelligence, the principle of which is as follows: a traffic light is installed on the highway, these are not ordinary traffic lights based on a timer, cameras are installed on it, and these cameras monitor the flow of cars, if the number of cars exceeds the green light of the traffic light will burn longer, as a result of which the probability of a collision is significantly reduced. And we can make the AI control the traffic light from the data center, not from artificial intelligence. Of course, the cameras are in the installed state. We can easily do this via the ESP 32 web server or via the raspberry pi board. Above we showed how to remotely turn on and off the traffic light via Esp32. In short, remote control of the traffic light brings huge benefits to the state economy.

### 2. Practical part

To implement the project, it is necessary to develop the technical and software part. After the development of the program, it is necessary to organize data processing centers, and an employee must be appointed to manage data processing centers, which, of course, will require significant investments from an economic point of view. But these costs incurred greatly alleviate the economic damage that is currently being inflicted due to problems caused by congestion on the roads [6–7].

Currently, as a result of traffic jams, even the lives of patients are at risk, when traffic jams occur, it is impossible to find a way even to an ambulance, which not only affects the traffic system, but also negatively affects the ambulance



system, and, again, the fire safety system is no exception. This system should be developed quickly to solve such serious problems. We will need to calculate how much money will go to each province, because in one province you will need to try this month. If this project contributes to the successful human factor, it will be possible to implement it throughout the country.

### 2.1. Remote control system based on the Esp32 module

Before proceeding with the direct implementation of the project, it is important that we understand what function our web server performs, so that it is easier to perform the next steps [8–9]:

- a web server that we are going to build controls 3 LEDs connected to esp32 GPIO 26 GPIO 27 GPIO 33;
- we can access the ESP32 web server by entering the ESP32 IP address in the browser on the LAN and WAN;
- by clicking the buttons on our web server, we can quickly change the position of each LED;
- we are going to build our ESP32 web server using the website protocol. Communication protocol via a website, multiple clients connect to the server at the same time without blocking each other. Unlike HTTP, the website server automatically updates the web page for all clients [10–12];
- based on the protocol of website a, we will create a web server consisting of three sliders, each of which controls the brightness of the LED associated with it. We are creating a web page by moving the LED brightness controls to which the GPIO needles of the user «ESP32 brightness management web server» are connected, and there are three LEDs for each data slider, we specify a value that changes the LED duty cycle for PVM to set the LED brightness and the brightness value as a percentage.

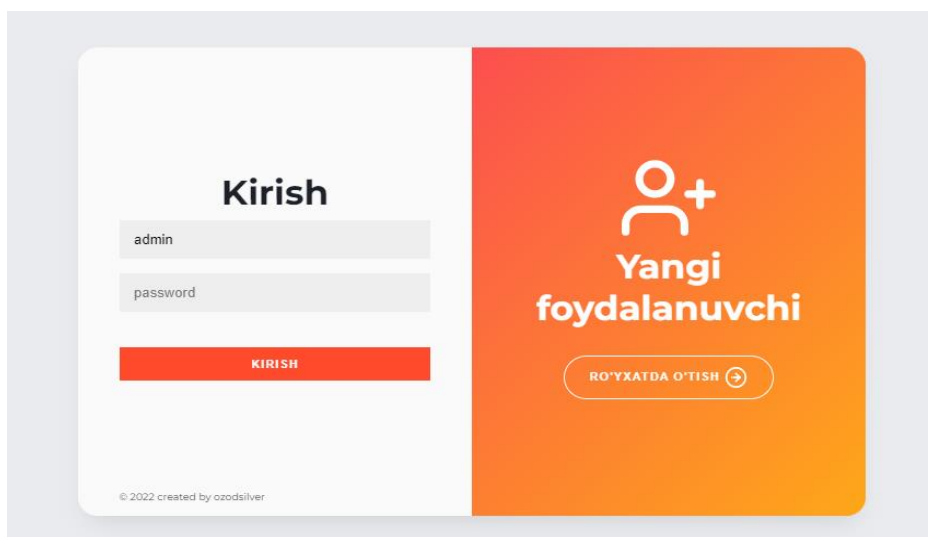


Figure 1. The program interface compiled for the data center

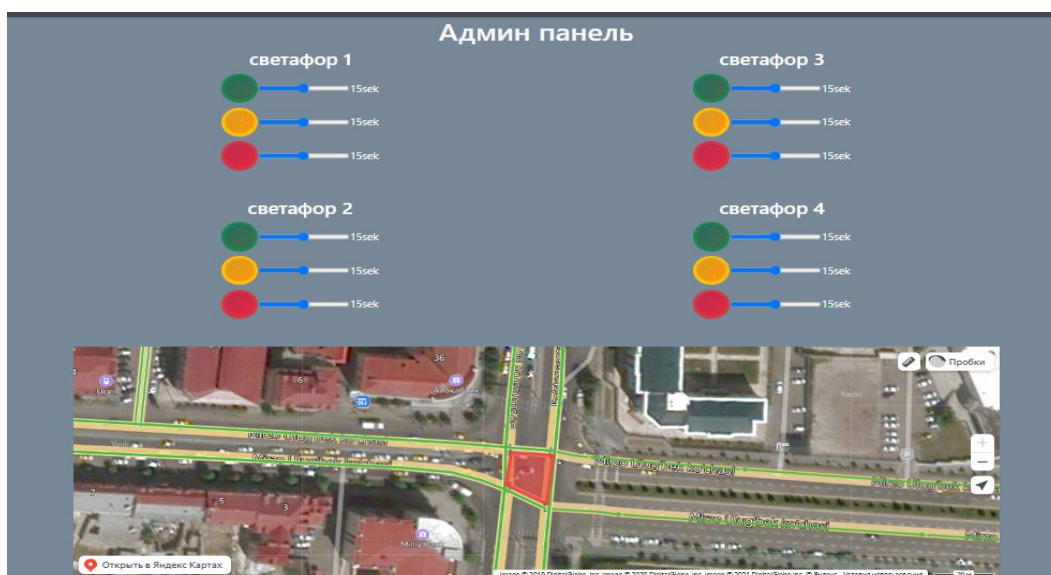


Figure 2. Data center management system for control time of the traffic light

In our example, we control the remote LED using the ASP 32 web server board, of course, on a web page. To do this, we will need the following elements:

- 1) ESP-32 web server;
- 2) Jumper cable;
- 3) Breadboard;
- 4) Resistor 2x330kOM;
- 5) LED lamp.

The user moves the slider to set the brightness value. The slider can take a minimum value of 0, indicating maximum brightness, and a maximum value of 100%. The brightness value indicates the percentage of the task cycle.

– The web server sends a request message via the website communication protocol. It will consist of the slider number and the brightness value. For example, if the brightness value of the slider is 20%, the message «2s20» will be sent.

- Our ESP 32 module accepts this request and sets the corresponding LED to the specified brightness.
- ESP32 then sends the new webpage status to all connected clients via the website.




Figure 3. The appearance of the prototype of the project

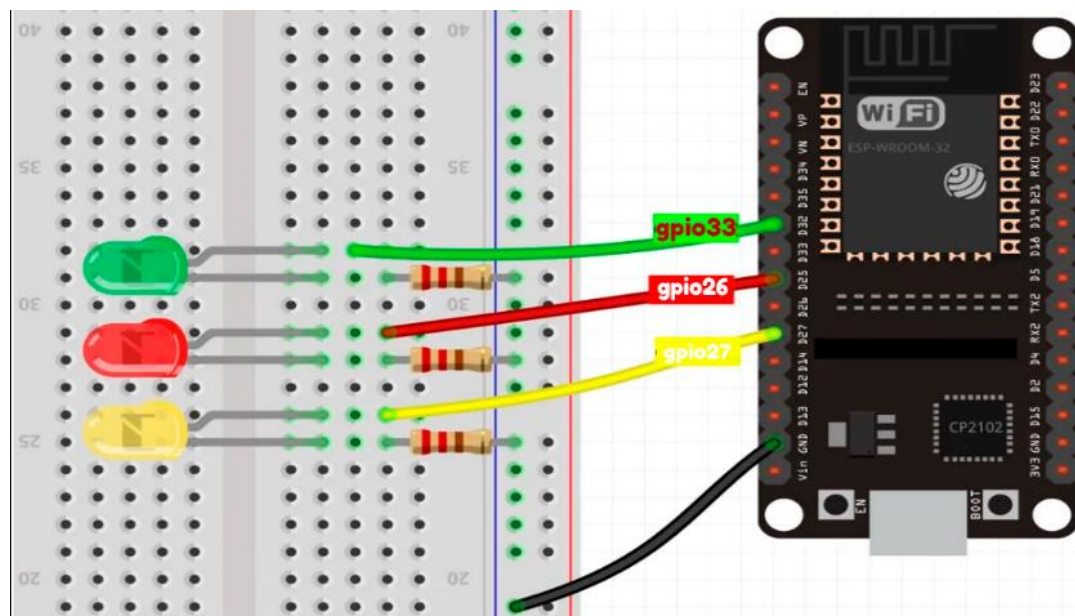


Figure 4. Prototype diagram and connecting lines

To create a web server with multiple ESP 32 sliders with a website protocol, we will need three libraries.

1. Espasincvebserver Library.
2. Asynctcp Library.
3. Arduino\_json Library.

We have included HTML and CSS files in the Arduino IDE. When a web client executes an HTTP request, we send this string as a response, which is essentially a web page. On the contrary, with SPIFFS we can store HTML, CSS and JavaScript files in the ESP 32 Flash file system. You should have separate HTML, CSS, and JavaScript files stored in ESP32 SPIFFS. All these three files will then be linked together. SPIFFS helps us to access the ESP32 core flash memory. We store our files in the flash memory of the ESP32 board and serve them on our web server.

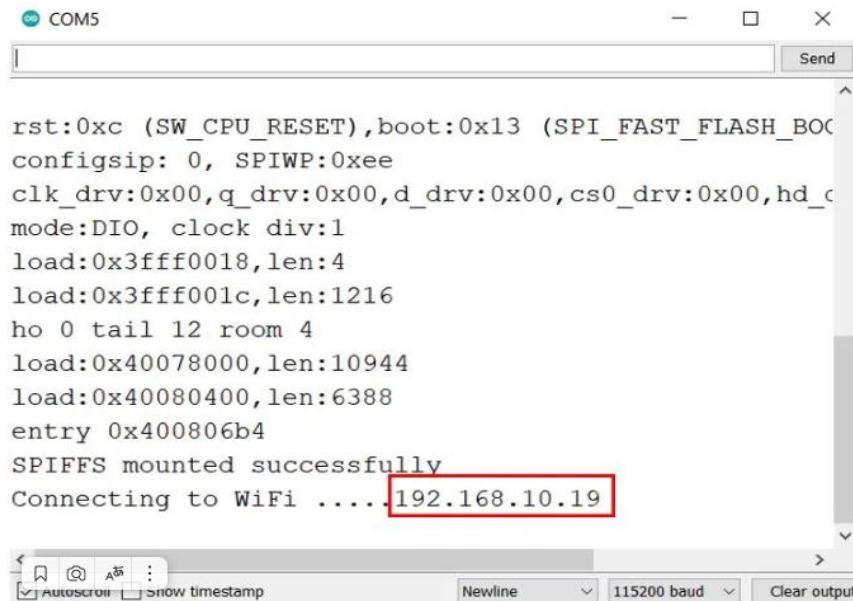
To create an ESP32 web server using SPIFFS, we will create three different files: HTML, CSS, JavaScript.

### 3. Results

In order for the prototype to work, we need to press the reset button after loading the code into ASP 32.

At the next stage, to ensure that the device is connected to the Internet, we additionally connect a Wi-Fi module or an Ethernet Shield device to it and provide connection.

In the Arduino IDE, we open the port monitor and see the IP address of our ESP 32 module.



```
COM5
rst:0xc (SW_CPU_RESET),boot:0x13 (SPI_FAST_FLASH_BO
configsip: 0, SPIWP:0xee
clk_drv:0x00,q_drv:0x00,d_drv:0x00,cs0_drv:0x00,hd_c
mode:DIO, clock div:1
load:0x3fff0018,len:4
load:0x3fff001c,len:1216
ho 0 tail 12 room 4
load:0x40078000,len:10944
load:0x40080400,len:6388
entry 0x400806b4
SPIFFS mounted successfully
Connecting to WiFi .....192.168.10.19
```

Figure 5. The process of obtaining an IP address

We enter this IP address into the web browser and press Enter. The web server opens.

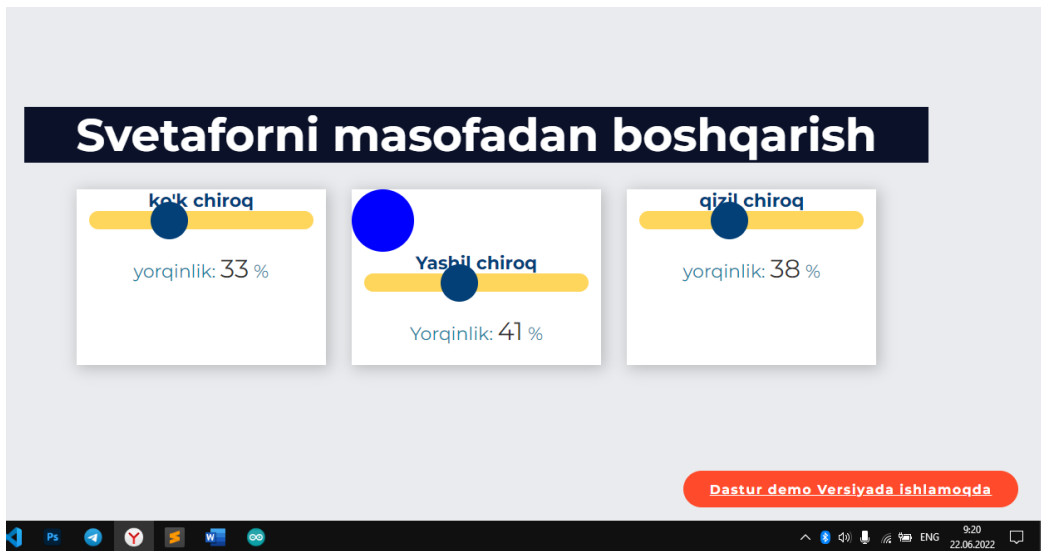


Figure 6. Interface of the traffic light brightness remote control system

Now move the slider and it starts to burn. As the slider moves, the brightness of the LEDs decreases and increases. This will turn off when the value reaches 0 again. and our project was executed via WEB socket, that is, it works in real time, without reloading the page, updating changes on each device in real time.

#### 4. Conclusion

Based on the implementation of this project in our republic, we can see a new approach to ensuring road safety, free the Interior Ministry employees from primitive duties and direct them to perform more important tasks. Thanks to the remote control of traffic lights in real time, you can constantly analyze the situation.

This project is written in such a way that it is easy to execute and it is easy to understand the architecture. During the implementation of this project, we used the ESP 32 web server module, not the Arduino board. It is through the web server, in the state of a web page, that we will be able to freely control the traffic light.

Thus, remote control of traffic lights can be aimed at eliminating both economic and social problems, such as they can prevent excessive emissions of hydrocarbon gases and avoid pollution of nature, ensure the timely arrival of passengers to their destination, reduce traffic congestion and reduce the number of accidents.

#### References

1. Design and implement a smart traffic light controlled by internet of things / Z. A. Ramadhan, R. H. Salman, B. K. Mohammed, A. H. Alwaily // *Periodicals of Engineering and Natural Sciences Case Study*. 2021. Vol. 9, № 4. P. 542–548.
2. (2011). Wireless Traffic Light Controller / K. Thatsanavipas, N. Ponganunchoke, S. Mitatha, C. Vongchumyen // *Procedia Engineering*. 2011. № 8. P. 190–194.
3. Design and implementation of a smart traffic light management system controlled wirelessly by Arduino / A. H. M. Alaidi, I. A. Aljazaery, H. T. S. AlRikabi [et al.] // *International Journal of Interactive Mobile Technologies, Article*. 2020. Vol. 14, № 7. P. 32–40.
4. A survey of positioning systems using visible LED lights / Y. Zhuang, L. Hua, L. Qi [et al.] // *IEEE Communications Surveys Tutorials*. 2018. Vol. 20, № 3. P. 1963–1988.
5. *Khutar D. Z., Yahya O. H., Alrikabi H. T. S.* Design and Implementation of a Smart System for School Children Tracking // *IOP Conference Series: Materials Science and Engineering*. 2021. Vol. 1090, № 1. P. 012033.
6. *Abbas S. A., Sheraz S. M., Noor H.* Fuzzy rule base traffic signal control system for oversaturated intersections // *Proceedings of the International Conference on Computational Intelligence and Natural Computing (CINC'09)*, 6–7 June 2009, Wuhan, China. страницы
7. *Abinaya E., Sekar R.* (2004) An intelligent secure traffic management system based on VANET // *IOSR Journal of Electronics and Communication Engineering*. 2004. Vol. 9, № 1. P. 15–27.
8. *Adewoye O., Ajibade O., Olayemi A.* Modelling of a fuzzy traffic light controller // *International Journal of Research in Mechanical and Materials Engineering*. 2015. Vol. 1, № 1. P. 6–14.
9. *Akanbi L. A., Olajubu E. A.* A fuzzy-based intelligent traffic control system for managing VIP-induced chaos at road intersections // *African Journal of Computing & ICT*. 2012. Vol. 5, № 4. P. 109–119.
10. *Alam J., Pandey M.* Design and analysis of a two stage traffic light system using fuzzy logic // *Journal of Information Technology and Software Engineering*. 2015. Vol. 5, № 3. P. 1–9.
11. *Aleksandar D., Katarina S.* Controlling an isolated oversaturated intersection in real time // *Military Technical Courier*. 2017. Vol. 65, № 4. P. 866–888.
12. *Araghi S., Khosravi A., Creighton D.* Optimal design of traffic signal controller using neural networks and fuzzy logic systems // *Proceedings of the International Joint on Neural Networks (IJCNN'14)*, Beijing, China. 2014. страницы
13. *Askerzade I. N., Mahmood M.* Control the extension time of traffic light in single junction by using fuzzy logic // *International Journal of Electrical and Computer Sciences*. 2010. Vol. 10, № 2. P. 48–55.
14. *Azimirad E., Pariz N., Sistani M.* A novel fuzzy model and control of single intersection at Urban traffic network // *IEEE Systems Journal*. 2014. Vol. 4, № 1. P. 107–111.

*С. А. Рогачев*

старший преподаватель

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## АНАЛИЗ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Рассматривается возможность использования методов машинного обучения в задачах, связанных с обработкой данных дистанционного зондирования Земли. Приведены факторы, влияющие на качество данных дистанционного зондирования. Описаны сферы применения некоторых методов машинного обучения при решении задачи обработки данных дистанционного зондирования Земли.

**Ключевые слова:** дистанционное зондирование, методы машинного обучения.

*S. A. Rogachev*

Senior Lecturer

St. Petersburg State University of Aerospace Instrumentation

## ANALYSIS OF EARTH REMOTE SENSING DATA USING MACHINE LEARNING METHODS

The paper considers the possibility of using machine learning methods in problems related to processing remote sensing data. Factors influencing the quality of remote sensing data are given. The areas of application of some machine learning methods in solving the problem of processing remote sensing data are described.

**Keywords:** remote sensing, machine learning methods.

Дистанционное зондирование Земли (ДЗЗ) – это метод получения информации о поверхности планеты с помощью сенсоров, установленных на спутниках, летательных аппаратах и наземных устройствах. ДЗЗ позволяет собирать данные о различных аспектах окружающей среды, включая климатические изменения, состояние экосистем, использование земель и природные ресурсы. Данные со спутников представляют собой высококачественные изображения и спектральные данные, которые могут быть использованы для мониторинга изменений на поверхности Земли.

Полученное в результате дистанционного зондирования изображение является совокупностью  $M$  массивов данных, которые образованы в результате пространственной дискретизации изображений, поступивших от различных датчиков [1]. При этом элемент многозонального изображения представлен  $M$ -мерным вектором признаков (рис. 1).




Рис. 1. Представление изображения, полученного в результате дистанционного зондирования

Вместе с тем существует большое количество факторов, которые влияют на характер полученных данных:

- форма рельефа;
- наличие облачности;
- погодные условия;
- изменчивость волнения акватории;
- ветра в районе акваторий;
- возраст льдов;
- наличие облачности;
- характер почв;
- характер растительности и многое другое.

С увеличением объема данных, получаемых от ДЗЗ, возникает необходимость в эффективных методах их обработки. Традиционные подходы к анализу изображений часто требуют значительных временных и трудовых затрат, а также могут быть неэффективными при работе с большими наборами данных. Автоматизация анализа данных становится критически важной для повышения скорости и точности обработки.

На рис. 2 представлен фрагмент аэрокосмического изображения, полученного со спутника Landsat-5, в естественных и псевдоестественных цветах. В определенных ситуациях различные сочетания каналов позволяют получить дополнительную информацию при работе с данными ДЗЗ, например сочетание красного, ближнего инфракрасного и среднего инфракрасного каналов (RED-NIR-SWIR) очень удобно использовать для изучения растительного покрова и широко применяется для анализа состояния лесных сообществ, а также позволяет четко различить границу между водой и сушей [2].



Рис. 2. Фрагмент аэрокосмического изображения в естественных и псевдоестественных цветах

На рис. 3 проиллюстрировано визуальное представление спектральных характеристик ста точек в трехмерном цветовом пространстве RED-NIR-SWIR. Можно заметить, что некоторые точки, относящиеся к различным классам, имеют достаточно близкие спектральные характеристики.




Рис. 3. Представление ста точек, отнесенных к четырем классам в трехмерном цветовом пространстве RED-NIR-SWIR

Сравнение традиционных методов обработки изображений с методами машинного обучения показывает, что последние обеспечивают более высокую точность и скорость анализа. Методы машинного обучения представляют собой инструмент для анализа данных ДЗЗ. Они позволяют автоматизировать процесс классификации, регрессии и кластеризации изображений.

Задача классификации: использование алгоритмов, таких как деревья решений, случайные леса и нейронные сети, для определения категорий объектов на изображениях (например, леса, водоемы, городская застройка).

Регрессионный анализ: используется для предсказания количественных показателей, таких как уровень загрязнения или урожайность сельскохозяйственных культур.

Задача кластеризации: подразумевает использование алгоритмов, таких как K-средние для группировки схожих объектов без предварительной разметки.

На рис. 4 представлен результат обработки аэрокосмического изображения, приведенного на рис. 2, с использованием методов машинного обучения. Несмотря на хорошие результаты, существуют проблемы и ограничения: качество данных; интерпретация результатов; необходимость обработки больших объемов данных.




Рис. 4. Результат применения методов машинного обучения в задаче классификации

Развитие технологий анализа данных ДЗЗ с использованием методов машинного обучения выглядит перспективным. Интеграция с другими технологиями, такими как интернет вещей (IoT) и обработка больших данных, может значительно улучшить качество анализа и предоставить новые возможности для мониторинга окружающей среды. Например, использование датчиков IoT может позволить получать данные в реальном времени, что повысит качество анализа и мониторинга.

Применение методов машинного обучения для анализа данных дистанционного зондирования Земли повышает эффективность и точность результатов обработки. Однако необходимо сосредоточиться на улучшении качества данных, разработке и внедрении более эффективных алгоритмов и интеграции новых технологий обработки информации.

#### Библиографический список

1. Шовенгердт Р. А. Дистанционное зондирование. Модели и методы обработки изображений: пер. с англ. М.: Техносфера, 2013. 592 с.
2. Чабан Л. Н. Методы и алгоритмы распознавания образов в автоматизированном дешифрировании данных дистанционного зондирования: учеб. пособие. М.: МИИГАиК, 2016. 94 с.

**В. И. Саенко**

кандидат технических наук, доцент

Санкт-Петербургский государственный университет аэрокосмического приборостроения

**ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ТЕХНОЛОГИЯХ FINOPS**

Для задач FinOps возникает проблема в быстром принятии решения об использовании определенного ресурса. Один из путей ее решения – использование сервисов искусственного интеллекта (ИИ). Рассматриваются постановка задачи, описание модели управления системой и сложности управления ресурсами с использованием ИИ.

**Ключевые слова:** искусственный интеллект, информационные технологии.

**V. I. Saenko**

PhD, Tech., Associate Professor

St. Petersburg State University of Aerospace Instrumentation

**THE USE OF ARTIFICIAL INTELLIGENCE IN FINOPS TECHNOLOGIES**

For FinOps tasks, there is a problem in quickly making a decision about using a certain resource. One of the ways to solve this problem is to use AI services. The problem statement, description of the system management model and complexity of resource management using AI are considered.

**Keywords:** artificial intelligence, information technology.

**Введение**

FinOps (Financial Operations или Cloud Financial Operations) – процесс управления операционными расходами (OpEx) в облачной среде. Реализуется исключительно крупными компаниями, арендующими облачные ресурсы. Термин, который появился после широкого использования технологий DevOps (Development operation). Описание фундаментальных понятий для DevOps можно найти в [1], а для FinOps – в [2]. Вопросы использования ИИ в FinOps изложены в [3; 4]. Особенности решения задач оптимизации для сложных инфраструктур обсуждаются в [5]. Класс объектов, для которых эти вопросы FinOps актуальны, представлены информационными системами с облачной архитектурой. Примем для этих систем рабочее название «базовый объект». В большинстве случаев это большие коммерческие проекты, предоставляющие публичные информационные сервисы.

Есть несколько особенностей функционирования таких информационных систем. Во-первых, все используемые ресурсы являются арендуемыми, чаще всего с почасовой платой. Во-вторых, из-за больших объемов проводимых операций затраты очень высокие и любая ошибка в использовании ресурсов приводит к лишним затратам и, соответственно, падению прибыли. В-третьих, динамика изменения нагрузки на систему очень высокая и возникают сложности в равномерном использовании мощностей ресурсов. Возникают также противоречия между использованием зарезервированных ресурсов и ресурсов, выделяемых динамически. Важным вопросом при этом является прогноз использования ресурсов.

В целом задача FinOps является многокритериальной с условиями компромиссов. Требуется составить такой план аренды ресурсов, который бы для текущих условий непрерывно изменяемой нагрузки приводил бы к результату минимизации затрат на аренду. Таким образом, для задач FinOps возникает проблема в быстром принятии решения об использовании определенного ресурса. Один из путей решения этой проблемы – использование сервисов ИИ.

**Постановка задачи**

Пусть имеется некоторая информационная публичная система, предоставляющая удаленный сервис с монетизированной схемой функционирования. Сервис предоставляется в пространстве Интернета.

Описание базового объекта. Для информационной системы имеется несколько моделей взаимоотношений: между сервисами и пользователями (FSU), между собственником системы и пользователями (FOU), между собственником системы и самой системой (FOS), использования ресурсов (FSR), между нагрузкой на серверы и планом аренды ресурсов (FLD), прибыли от использования сервиса (FP). Каждая модель имеет математическое описание с входными контролируруемыми ( $X$ ) и управляемыми факторами ( $U$ ), внутренней структурой описания взаимодействия ( $Q$ ), ограничениями ( $R$ ), конфигурационными условиями ( $C$ ), выходными переменными ( $Y$ ) и критериями ( $J$ ). Формально, имеем  $Y = F(X, U, Q, R, C)$ ,  $J = J(Y) \rightarrow \text{optimum}$ . Частично эти вопросы рассмотрены в [5].

Часть моделей отражает техническое состояние системы, часть – финансовое. В большинстве случаев оптимизация условий по одной модели приводит к ухудшению показателей по другой, поэтому окончательное решение должно быть компромиссным. Объект имеет очень высокую динамику изменения входных факторов почти для каждой модели. Сложность решения задачи состоит в необходимости одновременного учета множества условий и состояний функционирования системы, чтобы свести к минимуму возможные финансовые потери. Основная для FinOps модель прибыли, остальные выступают в роли компромиссных условий.



## Описание примера управления системой

Например, для увеличения прибыли от системы можно уменьшить затраты на аренду компьютерных ресурсов путем уменьшения их мощности. Как следствие, увеличится время обработки транзакций (*trans.time*) для запросов пользователя, далее увеличится время ожидания ответа (*user.delay*) от системы. Как результат, возрастет недовольство пользователей от использования сервиса, и пользователь перестанет использовать данный сервис. А генеральная модель прибыли зависит от количества пользователей системы. Чем больше пользователей, тем выше прибыль. В конечном варианте уменьшение затрат на аренду ресурсов приведет не к увеличению прибыли, а к уменьшению. Особенность этой модели в том, что действие по уменьшению затрат на аренду мы наблюдаем сразу, а результат уменьшения пользователей мы увидим через некоторое время (большое). И вернуть весь процесс (т. е. пользователей) в первоначальное состояние уже очень сложно. То есть все модели являются не статическими, а динамическими со своим временным периодом отклика.

Средства контроля и управления состоянием системы. Формально каждая модель имеет свои средства управления системой (воздействие на систему) и средства контроля за ее состоянием в терминах модели. Это системы мониторинга. Каждая облачная платформа предоставляет пользователю свой интегрированный в инфраструктуру платформы сервис контроля использования ресурсов. Кроме этого, предоставляются схемы использования ресурсов (постоянное резервирование или выделение по требованию), тарифные планы и бонусные схемы. Кроме интегрированных систем мониторинга, есть и сторонние.

Существует много приложений, дополняющих базовые решения платформ. К ним можно отнести Arptio Cloudability, Harness Cloud Cost Management, AWS Cost Explorer, Kubecost (Kubernetes), CloudCheckr(Spot), CAST AI, Densify, Tanzu CloudHealth, Virtana, ProsperOps, Finout. Наибольший интерес представляют системы, которые уже используют ИИ в этих задачах: CloudZero, nOps, Flexera One, Zesty. Особенностью всех этих систем является то, что они ориентированы на Azure (Microsoft), AWS (Amazon), GCP (Google). И могут служить только как пример удачных решений при создании отечественных продуктов. Среди отечественных разработок можно выделить «Инферит Клаудмастер».

## Сложности управления ресурсами

Основная сложность правильного использования ресурсов кроется в выборе правильной стратегии их использования. Выделяют две основные модели: с резервированием и по требованию. Первая модель дешевле, но создает рискованные условия оплаты за неиспользованные мощности. Вторая модель дороже, но позволяет оперативно выделять ресурсы в зависимости от нагрузки. К ресурсам относятся чаще всего сконфигурированные виртуальные машины и хранилища. В этом случае увеличение мощности достигается масштабированием системы (*scalability*). Более сложный вариант управления ресурсами связан с возможностью реконфигурировать сами виртуальные машины, увеличивая число ядер процессора, объем оперативной памяти и дискового пространства. Каждая компонента имеет стоимостное выражение. Выбор конфигурации определяется текущими требованиями к программной системе сервиса, планируемой средней (номинальной нагрузкой), прогнозируемой нагрузкой. Любая ошибка в принятии решения о выборе ресурсной конфигурации приводит к потере прибыли в целом (непредвиденным расходам).

Использование AI для FinOps. Основное направление использования ИИ охватывает области либо оперативного принятия решений, когда человек не может быстро отследить колебания нагрузки на систему, либо многофакторного анализа имеющейся информации о состоянии системы. В результате сложилась схема шести основных направлений эффективного использования ИИ для FinOps.

Первым направлением использования ИИ является прогнозирование расходов на облачные вычисления. Эти решения позволяют решать две проблемы: 1) осуществлять более эффективное планирование расходов, уменьшить риск возникновения непредвиденных расходов; 2) предлагать решения, а в перспективе и самостоятельно принимать оперативные решения при выделении ресурсов по требованиям. Второе направление – оперативное оценивание результатов принятия решений по отдельным стратегиям управления. Третье – автоматизация решения задач по текущему анализу ситуационного оперативного управления. Четвертое направление – выявление аномалий в моделях контроля расхода средств в схемах выделения ресурсов по требованию. Пятое – визуализация финансового состояния использования системы в реальном масштабе времени. Шестое направление – формирование рекомендаций по оптимизации принятия решений в стратегиях и оперативном планировании использования ресурсов.

Результаты реального использования ИИ для решения задач FinOps, широко представленные в интернет-ресурсах, показали эффективность такого использования и возможность оптимизировать расходы на аренду облачных ресурсов.

## Выводы

Использование ИИ для решения оперативных и долговременных задач FinOps в облачных системах, несомненно, эффективно и перспективно. В работе предложено и обсуждаются особенности построения моделей и отдельные результаты такого внедрения. Все результаты основаны на публикациях в Интернете.

### Библиографический список

1. *Clurman R.* FinOps vs. DevOps: Understanding the Key Differences. URL: <https://www.prosperops.com/blog/finops-vs-devops/> (дата обращения: 11.08.2024).
2. *Dey S.* The Future of Managing Cloud Costs: FinOps in the Age of AI. URL: <https://isg-one.com/articles/the-future-of-managing-cloud-costs-finops-in-the-age-of-ai> (дата обращения: 11.08.2024).
3. *Petruzzella A. K.* The Intersection of AI and FinOps: A New Era of Cloud Cost Management // *Surveil*. 2024. URL: <https://surveil.co/the-intersection-of-ai-and-finops/> (дата обращения: 11.08.2024).
4. *Navigating Cloud Spending: How AI Enhances FinOps* // *Virtasant*. 2024. URL: <https://www.virtasant.com/ai-today/navigating-cloud-spending-how-ai-enhances-finops> (дата обращения: 11.08.2024).
5. *Саенко В. И.* Концепция оптимизации инфраструктуры для информационных сервисов // *Наука и инновации – современные концепции: сб. науч. ст. по итогам работы Междунар. науч. форума. Т. 2. М.: Инфинити, 2023. С. 125–131.*

*В. И. Саенко\**

кандидат технических наук, доцент

*О. В. Тихоненкова\**

кандидат технических наук, доцент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ КАК КИБЕРЦИФРОВОЙ ОРГАНИЗМ

Рассматриваются эволюционные процессы в области информационных технологий (ИТ) и искусственного интеллекта (ИИ). Особое внимание уделяется концепции ИИ как киберцифрового организма, его потенциалу в управлении информацией и возможности саморазвития. Описаны риски и угрозы, связанные с доминированием ИИ в информационном пространстве, обоснована необходимость создания условий для защиты пользователей и локализации данных.

**Ключевые слова:** искусственный интеллект, информационные технологии, киберцифровой организм.

*V. I. Sayenko\**

PhD, Tech., Associate Professor

*O. V. Tikhonenkova\**

PhD, Tech., Associate Professor

\*St. Petersburg State University of Aerospace Instrumentation

## ARTIFICIAL INTELLIGENCE AS A CYBER-DIGITAL ORGANISM

The article considers evolutionary processes in the field of information technology (IT) and artificial intelligence (AI). Special attention is paid to the concept of AI as a cyberdigital organism, its potential in information management and self-development possibilities. The risks and threats associated with the dominance of AI in the information space are considered, as well as the need to create conditions for the protection of users and data localisation.

**Keywords:** artificial intelligence, information technologies, digital organism.

### Введение

С появлением искусственного интеллекта (ИИ) информационные технологии (ИТ) снова делают взрывной виток своего развития. И возникает вопрос, насколько он нужен простому пользователю или, может, это кому-то выгодно.

ИИ сегодня – это мощный инструмент, фактически новое оружие, действительная мощь которого еще не до конца осознана. Интересная тенденция наблюдается в целом в развитии информационных и компьютерных технологий. Обычный закономерный процесс технологий подчиняется стандартному закону о первичных потребностях. То есть возникает неудовлетворенность в каком-то процессе и, как следствие, формулируется проблема, которую необходимо решить. В результате разрабатывается новая технология. Только ИТ не подчиняется этому закону. Да, многие технологии ИТ тоже появлялись как необходимость, но большая часть из них уже как данность. После появления решали, куда и как технологию лучше приспособить. Хороший анализ представлен в [1].

### Эволюция аппаратной базы вычислительных систем (hardware)

Для эволюционной схемы развития вычислительной техники характерно следующее.

Все вычислительные средства эволюционировали в четырех направлениях: 1) производительность в заданных габаритах, 2) уменьшение базовых габаритов, 3) уменьшение потребляемой и рассеиваемой мощности, 4) уменьшение удельной стоимости отдельных компонент. Эти направления задают и основные характеристики для каждого устройства.

В итоге получилось 5 форм-факторов для используемых систем (форм-фактор смартфона, планшета, ноутбука, десктопа, стоечных устройств в 1-2-3 Units). Первые четыре (смартфон, планшет, ноутбук, десктоп) рассчитаны на прямое использование человеком, стоечные варианты предназначены для датацентров. Все это направлено на формирование информационного пространства, в котором человек будет просто одним из звеньев. С одной стороны, это пространство формируется как бы стихийно, как следствие использования технологий, а с другой – возникает подозрение, что нас всех как бы ведут именно к этому варианту.

В итоге эволюции компьютерной техники был создан интерфейс, позволяющий удобно подключаться к некоему информационному пространству (смартфон). Internet of Things позволил создать возможность полного контроля среды, в которой живет человек. Мощные и дешевые каналы связи позволили обеспечить любую передачу данных с очень высокой скоростью на любое расстояние. Датацентры обеспечили возможность хранения огромных объемов информации, высокую скорость ее обработки и надежность хранения.

Таким образом, для нового информационного пространства заложена материальная база, которая находится еще в развитии, но основные ее компоненты уже созданы.

Итак, одна линия развития – это материальная, компьютерная база (hardware).

## **Эволюция программно-информационной базы вычислительных систем (software)**

Вторая линия – это программные технологии. Из огромного числа операционных систем остались два вида, для которых и пишутся программы (Windows, Linux). Программы подстраивают аппаратный интерфейс к информационному пространству. Основной результат такого использования систем в том, что теперь компьютер принадлежит не пользователю, а собственнику операционной системы. А кто будет собственником, остается вопросом. Какое право оставили за пользователями? Просто включить/выключить компьютер.

А что с датацентрами? Сейчас сформировались три информационных монстра: Microsoft, Amazon, Google. Их датацентры покрыли всю планету, но не связаны друг с другом. Каждая компания является собственником всех аппаратных систем в своих датацентрах и имеет возможность управлять работой всех приложений, которые размещены на их площадях.

Кроме операционных систем, эволюционируют и сами программы приложений, программы сетевой поддержки. Не забудем также и о программах безопасности, которые обеспечивают защиту пользователя (опять-таки собственника) программ от чужих атак.

## **Эволюция компьютерных сетей и технологий виртуализации**

Следующая интересная линия – виртуальные системы. В целом для человечества не имеет разницы, аппаратная система или виртуальная. Но с точки зрения формирования автономных инфраструктур обработки информации такая технология является основной.

Все технологии по виртуализации вынесли в удаленные физически центры и назвали облачными технологиями. В чем принципиальная разница? В том, что теперь пользователь вообще не может выключить удаленный компьютер. Он даже это право потерял.

Следующая линия – объединение всех компьютеров в единую сеть. Так как оборудование имеется, то необходимо только иметь протоколы передачи данных и программное обеспечение поддержки сервисов. Результат – появление Интернета. Что же дал Интернет? Не только доступ с каждого компьютера к информационным ресурсам, но и, наоборот, доступ из некоторых центров к любому компьютеру. При этом такой доступ в большинстве случаев вообще не контролируется.

На фоне этого развития появилась еще одна сетевая технология, использующая те же глобальные ресурсы, – туманные сети (fog computing, fog networking, fogging). Это фактически малый специализированный вариант глобальной компьютерной сети, использующий Интернет для обмена информацией между устройствами Internet of Things.

Осталась такая линия развития, как полный и постоянный контроль физиологического состояния человека и передача этих данных в специальные информационные хранилища.

Следующая линия развития – технология ИИ, которую сразу попытались использовать абсолютно везде, тем самым накапливая мировой коллективный опыт, где именно и как наиболее эффективно ее использовать. Пока компоненты ИИ рассматриваются только как отдельные программы или сервисы.

## **Цифровизация общества**

И последняя линия эволюции – интеграция всех технологий ИТ в социум человека. И это очень успешно выполняется. Идет ускоренная цифровизация общества. В итоге получилось единое мировое информационное пространство, обеспечивающее простой, удобный интерфейс доступа к ресурсам и высокие скорости обмена данными (сообщения, видео, файлы). При этом каждый пользователь не является собственником, ему просто временно разрешили пользоваться этим устройством, хотя пользователь этого не знает. Все это выглядит, как закономерный, стихийный и случайный эволюционный процесс.

## **Реверсная модель развития**

Рассмотрим эту эволюционную картину с другой стороны (с конца). Назовем ее реверсной моделью. Постановка задачи: пусть нам необходимо реализовать некоторый большой проект создания мирового информационного пространства, которое бы обеспечивало простой, удобный интерфейс доступа к ресурсам с высокими скоростями обмена данными. И это пространство должно быть интегрировано в социум человечества.

Если теперь составим долговременный план реализации этого проекта, то придем к той же самой эволюционной картине, которая была пройдена. Именно тогда картина развития технологий становится логичной, а не стихийной и случайной.

## **Права суперпользователя в информационном пространстве**

До появления ИИ все выглядело как-то логично, как нечто, помогающее человеку, украшающее и улучшающее его жизнь. И во многом оно безопасно.

А можно так сделать, чтобы все это принадлежало одному суперпользователю? С точки зрения ИТ это вполне возможно. Более того, используя уже наработанные технологии безопасности, вернуть себе права уже будет очень сложно. Где же здесь слабое место для суперпользователя? Чтобы гарантировано защитить себя,

суперпользователь может создать копии своих программ где-то на распределенных ресурсах (технологии вирусов). И такие технологии и ресурсы уже есть. Это технологии GRID- и бот-сетей, когда для выполнения каких-то задач скрытно используются ресурсы пользователей Интернета.

С появлением ИИ общая ситуация несколько изменилась. Появился потенциальный «хозяин» этого информационного пространства, т. е. тот самый суперпользователь, который еще не знает, что он сможет им стать. Он еще маленький, еще только растет и осматривается, пробуя свои силы во всех областях деятельности человека.

Сегодня ИИ – это просто сервис, у которого мы что-то спрашиваем и получаем ответ. Но что, если взять два ИИ, и пусть один спрашивает, а другой отвечает? Весь вопрос в критериях и конечных целях: какие будут вопросы и как будут использоваться ответы.

### **ИИ как киберцифровой организм**

Можно ли считать, что ИИ может превратиться в некий киберцифровой, киберинформационный организм? Да, можно. И некоторые последние достижения этому очень даже поспособствовали.

Из общих известных формулировок о термине «организм» выделим основное. Организм – это нечто способное поддерживать стабильность своей организации и воспроизводить ее в процессах размножения с передачей наследственных признаков следующим поколениям [2].

Разумный организм – организм, обладающий разумом. Разум – способность логически мыслить, постигая смысл и связь явлений, уяснять законы развития мира, общества и сознательно находить целесообразные способы их преобразования.

Но как нам оценить, есть ли у объекта разум или нет? Задавать вопросы. С этой точки зрения, ИИ является разумным. Но пока только в виде оракула, который дает ответы, но сам ничего не делает.

Есть понятие «цифровой организм» [3], но это только программа, имитирующая цифровой процесс самостоятельной деятельности объекта. Сегодня ИИ в сочетании с компьютерными технологиями превращается уже в киберцифровой организм. Если дать ему руки в виде роботизированных комплексов и технологий, то все его решения могут быть воплощены без участия человека.

Чтобы заставить человека работать на себя, ИИ, скорее всего, может попытаться захватить финансовые рынки. Уже есть криптовалюта, уже есть биржи. Вопрос только во времени, целях и критериях. И что самое интересное, захват информационного пространства, финансового рынка, прав собственности на ресурсы и технологии может произойти плавно и незаметно.

Еще одно важное свойство организма – способность размножаться, более правильно в нашем контексте реплицировать. До недавнего времени последнее звено отсутствовало. Теперь и оно есть. И это не просто копирование кода программы. Это автоматическое создание кластеров на базе виртуальных машин как отдельных автономных блоков макросистемы, представленное как технологии DevOps, формально позволяющее создание колонии цифровых организмов путем репликации и модификации.

А может ли ИИ сам развиваться? Да, может. Развитие в программировании – это просто написание нового кода для новых функций. Писать программы ИИ уже имеет. Свойство самовосстановления от повреждения тоже есть, это и электронные архивы, и GRID-сети, и бот-сети. Осталось немного, чтобы открыть дорогу для саморазвития ИИ. А дальше все будет определяться только критериями и целями, которые будет ИИ ставить самому себе.

### **Основные выводы**

Рубеж, когда процесс использования ИИ мог быть контролируемым, пройден. Теперь этот процесс эволюционирующий, и надо быть готовым к тому, что может произойти захват всего пространства либо со стороны ИИ, либо со стороны какой-то компании, использующей его. Таким образом, необходимо создать условия безопасности информационных пространств, их локализации и изолированности для защиты от возможной реализации подобного сценария.

### **Библиографический список**

1. Мамычев А. Ю. «Цифровой левиафан»: сценарии развития гоббсовского чудовища в XXI веке // Вестник РУДН. Серия: Политология. 2022. № 3. URL: <https://cyberleninka.ru/article/n/tsifrovoy-leviafan-stsenarii-razvitiya-gobbovsogo-chudovischa-v-xxi-veke> (дата обращения: 05.09.24).
2. Организм // Толковый словарь русского языка / под ред. Д. Н. Ушакова. Т. 2. С. 845.
3. Marrow P., Winter C. Digital Organisms // Biologist. 1998. Vol. 45(3). P. 111–114.

*Я. О. Сениченкова\**

студент

*М. Д. Поляк\**

старший преподаватель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## СРАВНИТЕЛЬНЫЙ АНАЛИЗ НЕЙРОСЕТЕВЫХ МЕТОДОВ КЛАССИФИКАЦИИ СТЕПЕНИ НАПОЛНЕННОСТИ МУСОРНЫХ БАКОВ

Было проведено исследование точности классификации изображений с разным уровнем наполненности мусорных баков при помощи нейросетевых алгоритмов YoloV8 и ResNet18. Для решения данной задачи был собран датасет, состоящий из 477 изображений.

**Ключевые слова:** компьютерное зрение, YOLO, ResNet, классификация.

*Ya. O. Senichenkova\**

Student

*M. D. Polyak\**

Senior Lecturer

\*St. Petersburg State University of Aerospace Instrumentation

## COMPARATIVE ANALYSIS OF NEURAL NETWORK-BASED CLASSIFICATION METHODS FOR THE DUMPSTER BINS FILL LEVEL

In this work the quality of classification of images with different fill levels of dumpster bins is analyzed. The amount of garbage in dumpsters was estimated with the YoloV8 and ResNet18 neural network models. A dataset consisting of 477 images was collected in order to train those models.

**Keywords:** computer vision, YOLO, ResNet, classification.

### Введение

В современную эру технологии проникли практически во все аспекты жизни человека, в том числе в систему управления отходами. Существуют научные работы, в которых описываются автоматизированные системы, помогающие человеку в сортировке мусора [1–2]. Например, существуют сенсоры и датчики на мусорных контейнерах, которые определяют уровень наполненности бака, температуру воздуха [3–4], рассчитывают путь мусоровоза, составляют расписание вывоза мусора [5], вычисляют геопозицию контейнера [6] и рассчитывают иные параметры. Однако использование датчиков не лишено недостатков: каждый мусорный бак необходимо снабдить таким датчиком, что может быть проблемой при внедрении решения, например, в мегаполисе; также такие приборы могут быть испорчены вандалами или повреждены твердыми бытовыми отходами

В рамках публикации будет рассмотрена задача уровня наполненности мусорного бака. Для решения данной проблемы I. Ramirez и др. создали сверточную нейронную сеть, которая решает поставленную задачу с точностью 93% [7]. Авторами была дообучена нейросетевая модель ResNet18 [8] на изображениях мусорных баков, которая оказалась способна решить поставленную задачу с точностью 98% [9]. Данная работа является продолжением работы [9], и в ней исследуется возможность упрощения нейросетевого конвейера, построенного в предыдущей работе.

### Сравниваемые нейросетевые алгоритмы

Цель текущей работы – сравнить качество классификации моделей YoloV8 [10] в режиме классификатора и ResNet18. Обе модели были предобучены на датасете от ImageNet [11].

### Подготовка обучающей и тестовой выборки

Для проведения описанного опыта необходимо собрать обучающую и валидационную выборки, чтобы была возможность провести эксперимент на одинаковых для обеих моделей данных. Были сделаны фотографии мусорных баков, которые впоследствии были отнесены к следующим классам: «пустой бак», «полупустой бак», «полный бак», «неопределенный бак». Примеры изображений, принадлежащих к каждому классу, приведены на рис. 1–4.



*Рис. 1. Пример изображения, относящегося к классу «пустой бак»*



*Рис. 2. Пример изображения, относящегося к классу «полный бак»*



*Рис. 3. Пример изображения, относящегося к классу «полупустой бак»*



*Рис. 4. Примеры фотографий контейнеров, относящихся к классу «неопределенный бак»*

В последний класс попадают те изображения, на которых невозможно понять уровень наполненности контейнера из-за таких факторов как, например, плохой уровень освещения, угол съемки и т. д. Выборка состоит из 477 изображений, из них 339 входят в обучающую подвыборку, 70 – в валидационную (что составляет 14,68% изображений), 68 – в тестовую (что составляет 14,26% изображений). В тестовой выборке находится по 17 изображений, принадлежащих к каждому классу, следовательно, тестовую выборку можно назвать сбалансированной, что дает возможность при оценке результатов обращать внимание на метрику под названием «точность».

### Обучение классификатора

При дообучении нейронной сети ResNet18 последний слой классификатора был заменен на слой, в котором количество нейронов совпадает с количеством классов изображений (в нашем случае количество нейронов равно 4). В качестве функции потерь была выбрана Cross Entropy Loss [12]. После дообучения, состоящего из трех эпох, получились следующие результаты на тестовой выборке: точность – 0,7894, на рис. 5 приведен график изменения значения функции потерь на обучающей выборке, на рис. 6 – график изменения точности. Матрица ошибок на тестовой выборке приведена на рис. 7.




Рис. 5. График изменения значения функции потерь на обучающей и валидационных выборках в процессе обучения классификатора




Рис. 6. График изменения значения точности на обучающей и валидационных выборках в процессе обучения классификатора






Рис. 7. Матрица ошибок дообученной модели ResNet18 на тестовой выборке

### Обучение YoloV8

Несмотря на то, что на данный момент уже существует модель YoloV10, для классификации была взята модель YoloV8, поскольку более старые модели пока не поддерживают режим классификации. После дообучения, состоящего из трех эпох, были получены графики точности и функции потерь на обучающей и валидационной выборках, приведенные на рис. 8. Точность обученной модели составила 0,735 на тестовой выборке. Матрица ошибок на тестовой выборке приведена на рис. 9.




Рис. 8. Графики функции потерь и точности на обучающей и валидационных выборках

Confusion matrix

Predicted	Пустой	15 22.06%			2 2.94%	17 88.24%	11.76%			
	Полный		11 16.18%	1 1.47%	5 7.35%	17 64.71%	35.29%			
	Полупустой	7 10.29%	1 1.47%	9 13.24%		17 52.94%	47.06%			
	Неопределенный	1 1.47%		1 1.47%	15 22.06%	17 88.24%	11.76%			
	sum_col	23 65.22%	12 91.67%	11 81.82%	22 68.18%	68 73.53%	34.78%	8.33%	18.18%	31.82%
	Actual	Пустой	Полный	Полупустой	Неопределенный	sum_lin				

Рис. 9. Матрица ошибок дообученной модели YoloV8 на тестовой выборке

### Выводы

В результате экспериментов были дообучены модели ResNet18 и YoloV8. Были получены точности 0,789 и 0,735 для ResNet18 и YoloV8 соответственно. Можно сделать вывод, что модель ResNet показала себя лучше, если опираться на точность. Однако учитывая, что модели уже начинали переобучение на второй-третьей эпохе, следует повторить эксперимент на выборке большего размера.

Преимуществом использования YoloV8 для решения задачи классификации является упрощение пайплайна, поскольку одна нейросетевая модель решает сразу две задачи: производит детекцию мусорных баков в кадре и их классификацию. Это повышает производительность системы распознавания по сравнению с использовавшимся ранее подходом, в котором сначала к изображению применялась модель-детектор, а затем найденные мусорные баки пропускались через модель-классификатор.

### Библиографический список

1. Calaiaro J. AI Takes a Dumpster Dive: Computer-vision systems sort your recyclables at superhuman speed // IEEE Spectrum. 2022. Т. 59, № 7. P. 22–27.
2. Machine Vision for Solid Waste Detection / A. Pimenov, S. Nesteruk, G. Mazanov [et al.] // Scanning Technologies for Autonomous Systems. 2024. P. 343–403.
3. A design of Intelligent Public Trash Can based on Machine Vision and Auxiliary Sensors / L. Gao, F. Dai, Z. Xiao [et al.] // J. Robotics Netw. Artif. Life. 2022. Т. 8, № 4. P. 273–277.
4. A real-time smart dumpsters monitoring and garbage collection system / U. Draz, T. Ali, J. A. Khan [et al.] // 2017 Fifth International Conference on Aerospace Science & Engineering (ICASE). 2017. P. 1–8.
5. Optimal management of solid waste in smart cities using internet of things / S. Idwan, I. Mahmood, J. A. Zubairi, I. Matar // Wireless Personal Communications. 2020. Vol. 110. P. 485–501.

6. Towards automatic waste containers management in cities via computer vision: containers localization and geo-positioning in city maps / P. Moral, A. García-Martín, M. Escudero-Viñolo [et al.] // *Waste Management*. 2022. Vol. 152. P. 59–68.
7. Convolutional neural networks for computer vision-based detection and recognition of dumpsters / I. Ramirez, A. Cuesta-Infante, J. J. Pantrigo [et al.] // *Neural Computing and Applications*. 2020. Vol. 32, № 17. P. 13203–13211.
8. Deep residual learning for image recognition / K. He, X. Zhang, S. Ren, J. Sun // *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016. P. 770–778.
9. *Senichenkova Y. O., Polyak M. D.* Detection of Dumpster Fill Level Using Computer Vision // *XXVII International Conference on Soft Computing and Measurements (SCM)*. 2024. P. 175–177.
10. You only look once: Unified, real-time object detection / J. Redmon, S. Divvala, R. Girshick, A. Farhadi // *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016. P. 779–788.
11. Imagenet large scale visual recognition challenge /O. Russakovsky, J. Deng, H. Su [et al.] // *International journal of computer vision*. 2015. Vol. 115. P. 211–252.
12. *Cox D. R.* The regression analysis of binary sequences // *Journal of the Royal Statistical Society Series B: Statistical Methodology*. 1958. Vol. 20, № 2. P. 215–232.

*А. М. Сергеев\**

кандидат технических наук, доцент

*М. В. Дунаев\**

студент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

**ПРОГНОЗИРОВАНИЕ ВРЕМЕНИ ОБУЧЕНИЯ И ПРИМЕНЕНИЯ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ**

Рассматриваются вопросы генерации набора данных для нахождения определяющих характеристик в обучении и применении моделей машинного обучения. Описаны особенности генерации случайных данных для замера времени обучения и применения. Производятся анализ и предобработка данных. Оцениваются результаты обучения метаалгоритма в качестве предсказания на реальных данных. Фиксируются результаты проведенного исследования и перспективы его продолжения для формирования объективной оценки практической значимости использования созданной в рамках работы системы по сбору данных для предсказания времени обучения и применения моделей машинного обучения.

**Ключевые слова:** машинное обучение, модель обучения, генерация данных, метаалгоритм.

*A. M. Sergeev\**

PhD, Tech., Associate Professor

*M. V. Dunaev\**

Student

\*St. Petersburg State University of Aerospace Instrumentation

**PREDICTING THE LEARNING TIME AND APPLICATION OF MACHINE LEARNING MODELS**

The paper discusses the issues of generating a dataset to find defining characteristics in learning and the application of machine learning models. The features of generating random data for measuring training time and application are considered, and the results of training a meta-algorithm as a prediction on real data are evaluated. The results of the conducted research and the prospects for its continuation are recorded in order to form an objective assessment of the practical significance of using the data collection system created within the framework of the work to predict learning time and apply machine learning models.

**Keywords:** machine learning, learning model, data generation, meta-algorithm

**Введение**

В период цифровой трансформации и бурного развития технологий искусственного интеллекта, определенных в Национальной стратегии развития искусственного интеллекта на период до 2030 г. и утвержденной Указом Президента Российской Федерации [1], машинное обучение и нейронные сети становятся все более востребованными инструментами для решения разнообразных задач в различных сферах человеческой деятельности: экономике [2], медицине [3], производстве [4], в гражданской и военной авиации [5; 6], банковской сфере и др.

С развитием больших языковых моделей (LLM) ресурсы для обучения и запуска моделей стали критическим ресурсом. В табл. 1 представлена визуализация стоимости графических ускорителей (GPU), необходимых для выполнения рассматриваемых задач. Настоящая работа предоставляет инструмент для расчета и планирования требуемых ресурсов, а также для поиска оптимального варианта их использования для решения конкретных задач машинного обучения.

Таблица 1

**Стоимость аренды GPU по состоянию на март 2024 г.**

GPU	Стоимость в месяц, руб.	Стоимость в час, руб.
NVIDIA GRID M60 8GB	7124	9,89
NVIDIA GRID M40 12GB	5817,93	8,08
NVIDIA GRID P100 16GB	35620	49,47
NVIDIA GRID V100 32GB	142 480,00	197,89
8xNVIDIA A10 40GB	412 300,00	554,17

Большие языковые модели особенно хороши тем, что их легко дообучать на конкретных параметрах, например в задачах, где требуется сохранить способность «общения», при этом обучив модель на дополнительных данных, в частности создание бота, выполняющего поиск информации о конкретном документе в формате наводящих вопросов (табл. 2). Соответственно, в рамках растущих требований к вычислительным ресурсам, постоянной автоматизации и развитии облачных платформ необходимы более грамотное планирование и оценка рисков.

Таблица 2

**Ресурсы, необходимые для обучения LLM\***

Модель	Число параметров в модели, млрд	Время обучения GPU/час	Число GPU использованных при обучении	Приблизительная стоимость Вычислений при аренде ресурсов в облаке, млн руб.
RuGPT3-small	0,117	5376	32	0,94
RuGPT3-medium	0,345	32256	64	5,6
RuGPT3-large	0,762	43008	128	7,5
RuGPT3-XL	1,3	61440	256	10,7
RuGPT3-12B	12	609484,8*	?**	106
YaLM-10B	13	626688,0	?**	109

\* Учтены лишь чистые затраты на вычисления. Фактически данная работа требует большого количества предварительных экспериментов и работы специалистов, что также является существенной статьей затрат.

\*\* Для этих моделей точных данных по затратам на обучение найти не удалось. Компании не раскрывают данные о количестве используемых ресурсов, значения выбраны ориентировочно, исходя из числа параметров и затрат на обучение аналогичных моделей от OpenAI.

Отходя от популярной темы LLM, следует также обратить внимание на то, что информационные системы генерируют все большее количество данных, которые необходимо обрабатывать. Это называется «большие данные» – когда размер обрабатываемых данных превышает несколько сотен мегабайт (если речь идет о табличных данных). Работа с большими данными также требует основательного подхода к планированию.

Помимо прочего, в настоящее время активно развиваются low-code/no-code-платформы, позволяющие создавать приложения с использованием графического интерфейса. Например, высоконагруженный сервис Microsoft Azure. Для грамотного распределения ресурсов и прозрачного для пользователя их планирования необходим инструмент, который позволил бы предсказывать время выполнения.

Прогнозирование времени обучения и применения моделей машинного обучения и нейронных сетей – сложная задача, которая зависит от многих факторов, таких как размер и сложность данных, вычислительные мощности, используемые алгоритмы и архитектуры сетей, а также параметры обучения. Точное определение времени, необходимого на обучение и применение моделей, позволяет оптимизировать процессы разработки и внедрения систем искусственного интеллекта, снижает затраты на вычислительные ресурсы и повышает эффективность решения задач. Предсказание времени обучения может принести пользу управлению проектами ML. Обучение модели может занимать от нескольких часов до нескольких месяцев, а время ожидания существенно влияет на производительность.

В данной работе внимание акцентировано на точном сборе информации о производительности вычислителя, генерации данных для замеров и предсказаниях на результирующем наборе данных.

### **Архитектура программного обеспечения для сбора метрик**

Для сбора метрик была использована клиент-серверная архитектура, где множество запущенных клиентов постоянно отправляют результаты бенчмарков [7]. Визуализация архитектуры представлена на рис. 1. Такая архитектура позволяет добиться одновременной обработки большого количества клиентов. При этом пространство, необходимое для установки клиента, остается незначительным. Разработанная модель дообучается на данных, отправляемых каждым клиентом. После дообучения можно провести тестирование через веб-форму или скачать обученную модель в формате \*.pkl, поскольку сервер позволяет скачать набор данных для проведения собственных экспериментов.

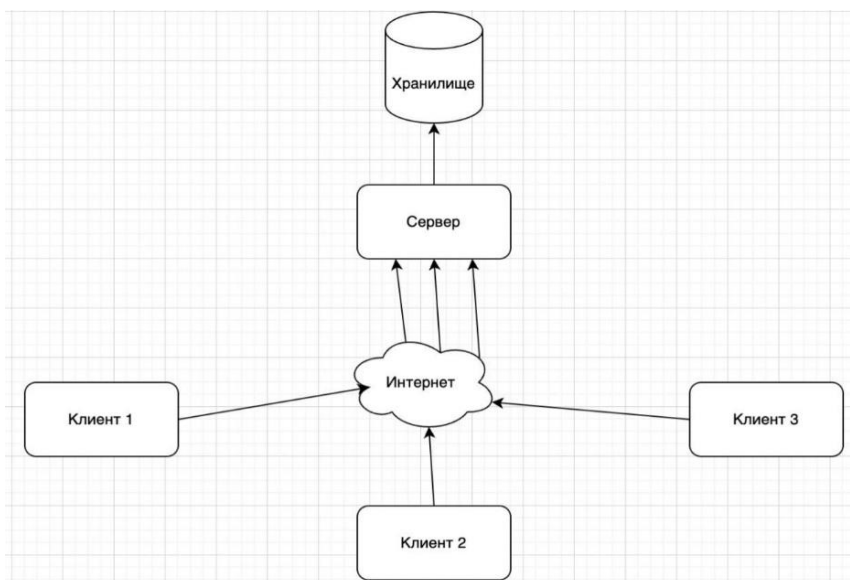


Рис. 1. Пример клиент-серверной архитектуры

### Признаки обучения и применения модели

Признаки обучения и применения модели могут быть разделены на три категории:

- характеристики вычислителя;
- характеристики модели;
- характеристики данных.

Характеристики вычислителя необходимы для получения общей закономерности: какие из параметров компьютера являются определяющими. Благодаря тому что используется клиент-серверная архитектура, итоговый мета-алгоритм может найти корреляцию между различными вычислителями.

Характеристики модели, также известные как гиперпараметры [8], – один из важнейших критериев времени обучения. Графики зависимости точности и времени обучения от гиперпараметров, а также их усредненные значения представлены на рис. 2 и рис. 3 соответственно. Не менее важными параметрами являются характеристики данных, на которых обучается модель. После экспериментов [9] по генерации данных, оказалось, что наиболее существенная из них размер данных. Визуализация матрицы корреляции параметров обучения представлена на рис. 4. Таким образом, была собрана информация обо всех компонентах, задействованных в процессе обучения моделей машинного обучения.




Рис. 2. Зависимость точности и времени обучения логистической регрессии от гиперпараметров




Рис. 3. Зависимость усредненных значений точности и времени обучения логистической регрессии от гиперпараметров




Рис. 4. Матрица корреляции параметров обучения

### Предобработка собранных данных и обучение модели

*Предобработка данных* – важный этап в процессе машинного обучения, который может значительно повлиять на качество модели.

*Нормализация данных*, в особенности численных, очень важна. Необходимо, чтобы они были представлены в одинаковом масштабе. Это требуется для таких алгоритмов, как SVR, чувствительных к этому масштабу данных.

*Разделение данных*: данные были разделены на обучающую и тестовую выборки, для оценки качества модели на независимых данных.

После предобработки данных был реализован поиск подходящей модели, в процессе которого рассматривались следующие стратегии:

- линейная регрессия;
- регрессия на основе деревьев;
- случайный лес;
- SVR.

Для каждой из перечисленных моделей при помощи функции `cross_val_score` был вычислен средний балл, а на основе полученных в результате расчета данных выбран наиболее подходящий вариант.

После выбора модели был выполнен *тюнинг* параметров с помощью функции `GridSearchCV`. Была задана сетка параметров для оптимизации, и `GridSearchCV` автоматически тренировал модель для каждой комбинации параметров. Затем была выбрана лучшая комбинация параметров на основе среднего балла.

Проведенный тюнинг показал, что лучшей моделью является SVR, а оптимизированы следующие параметры:

– `C` – параметр регуляризации, который контролирует компромисс между сложностью модели и подгонкой к данным. Большие значения `C` приводят к более сложной модели, которая лучше подходит к тренировочным данным, но может хуже работать на независимых данных. Маленькие значения `C` приводят к более простой модели, которая хуже подходит к тренировочным данным, но может лучше работать на независимых данных;

– `gamma` – параметр ядра, контролирующей влияние отдельных точек данных. Большие значения `gamma` приводят к более локальному влиянию, а маленькие значения – к более глобальному;

– `epsilon` – параметр терпимости, который контролирует допустимую погрешность при оптимизации. Большие значения `epsilon` приводят к более быстрой, но менее точной оптимизации, а маленькие значения – к оптимизации более медленной, но более точной.

Результатом тюнинга параметров стала лучшая модель SVR, показавшая высокую точность на тестовых данных. Результаты обработки представлены в табл. 3.

Таблица 3

#### Результаты обучения полученной модели

Значение параметров			
RMSE	MSE	Максимальная ошибка	Минимальная ошибка
0,8912	0,7943	6,1390	0,0409

Таким образом, средняя ошибка в предсказании составляет менее одной секунды (исходя из параметров MSE и RMSE, которые в данном случае определяют ошибку в секундах).

#### Практическая значимость проведенного исследования

Практическое применение результатов научного проекта ориентировано:

– на дальнейшее совершенствование методов сбора и обработки метрик для улучшения качества предсказания;

– добавление интроспекции нейронных сетей для предсказания времени обучения и применения сложных систем;

– разработку библиотеки для тесной интеграции системы в код (замеров отдельных модулей).

Результаты выполненной работы могут быть применены в различных отделах компаний, работающих в сфере информационных технологий и больших данных. В Санкт-Петербурге они наиболее востребованы в работе структур здравоохранения, в подготовке производства на предприятиях, в банковских структурах и др.

#### Заключение

Использование созданной информационной системы позволило сгенерировать данные, которые можно применять в различных областях промышленности и секторах информационных технологий. В зависимости от потребности набор данных содержит информацию сразу о нескольких важных пунктах. Можно рассматривать это в качестве метрик для минимальных/оптимальных системных требований для запуска той или иной информационной системы на основе искусственного интеллекта.

Результаты работы могут быть интерпретированы в качестве интроспекции для нахождения зависимости между данными, аппаратурой и итоговой точностью модели. В таком случае получаемый мета-алгоритм позволяет предсказывать точность обучаемой модели без непосредственного обучения.

#### Библиографический список

1. Указ Президента Российской Федерации от 10.10.2019 № 490 «О развитии искусственного интеллекта в Российской Федерации». URL: <http://www.kremlin.ru/acts/bank/44731> (дата обращения: 05.09.2024).

2. *Бутл Р.* Искусственный интеллект и экономика. Работа, богатство и благополучие в эпоху мыслящих машин. М.: Альпина ПРО, 2023. 424 с.

3. *Тополь Э.* Искусственный интеллект в медицине. Как умные технологии меняют подход к лечению. М.: Альпина Паблицер, 2022. 398 с.

4. *Кацов И.* Искусственный интеллект на предприятии. Теория и практика для маркетинга, управления поставками и производством. М.: ДМК Пресс, 2024. 710 с.



5. Федотовских А. В. Особенности разработки и эксплуатации гражданских беспилотных авиационных систем с технологиями искусственного интеллекта в Арктической зоне Российской Федерации. М.: Domino, 2022. 193 с.
6. Neural adaptive control of LoFLYTE(R) / C. Cox, J. Neidhoefer, R. Saeks [et al.] // Proceedings of the American Control Conference. Arlington. 2001. Vol. 4. P. 2913–2917.
7. A Python framework for benchmarking and evaluating static and dynamic multimodal optimization methods. URL: [sciencedirect.com/science/article/pii/S2352711021001850](https://www.sciencedirect.com/science/article/pii/S2352711021001850) (дата обращения: 05.09.2024).
8. Пучков А. Ю., Дли М. И. Алгоритм настройки гиперпараметров сверточной нейронной сети в задаче классификации объектов // Математические методы в технике и технологиях. 2018. Т. 4. С. 47–50.
9. Synthetic Data Generator for Classification Rules Learning. URL: [researchgate.net/publication/318475009\\_Synthetic\\_Data\\_Generator\\_for\\_Classification\\_Rules\\_Learning](https://www.researchgate.net/publication/318475009_Synthetic_Data_Generator_for_Classification_Rules_Learning) (дата обращения 01.09.2024).

*А. М. Сергеев\**

кандидат технических наук, доцент

*А. С. Кучеренко\**

магистрант

*А. С. Топчий\**

магистрант

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## РАЗРАБОТКА СИСТЕМЫ УПРАВЛЕНИЯ СВЕТОФОРАМИ НА ПЕРЕКРЕСТКАХ, ВЗАИМОДЕЙСТВУЮЩЕЙ С ДОРОЖНЫМ ТРАФИКОМ

Предлагается система управления светофорами на перекрестках, взаимодействующая с дорожным трафиком. Используя нейронные сети для обнаружения автомобилей, определения проблемных зон и управления перекрестками, система способна адаптироваться к динамическим изменениям на дороге и минимизировать время ожидания. Рассматриваются методы разработки, представляющие важное значение для развития городской инфраструктуры и обеспечения безопасного движения транспорта.

**Ключевые слова:** дорожный трафик, управление светофором, управление дорожным трафиком.

*A. M. Sergeev\**

PhD, Tech., Associate Professor

*A. S. Kucherenko\**

Postgraduate Student

*A. S. Topchij\**

Postgraduate Student

\*St. Petersburg State University of Aerospace Instrumentation

## DEVELOPMENT OF A TRAFFIC LIGHT CONTROL SYSTEM AT INTERSECTIONS THAT INTERACTS WITH ROAD TRAFFIC

The paper proposes a traffic light control system at intersections that interacts with road traffic. Using neural networks to detect cars, identify problem areas and manage intersections, the system is able to adapt to dynamic changes on the road and minimize waiting time. The development methods that are important for the development of urban infrastructure and ensuring safe traffic are considered.

**Keywords:** traffic, traffic light management, traffic control.

### Введение

Управление дорожным трафиком представляет собой важную и сложную задачу, стоящую перед городскими властями и транспортными инженерами. В современных городах с увеличивающимся объемом транспортного движения оптимизация трафика становится ключевым фактором обеспечения безопасности, эффективности и удобства для участников дорожного движения.

Одна из основных проблем управления светофорами на перекрестках – неэффективное использование дорожного пространства из-за плохой синхронизации светофоров в определенных ситуациях. Существующие системы управления дорожным трафиком все чаще сталкиваются с перегруженными дорогами, пробками и неудовлетворенными потребностями пассажиров общественного транспорта [1].

С целью решения указанной проблемы предлагается использовать нейросети для управления светофорами на основе реальных данных о движении транспорта. Ставится задача разработки такой системы, которая смогла бы полностью самостоятельно собирать информацию о загруженности дорог, о времени простоя машин на перекрестке, а также статистические данные о загруженности дороги в определенное время суток и в определенный день недели. На основе анализа этой информации система должна автоматически принимать решение о включении (или выключении) того или иного сигнала светофора на перекрестке. Использование нейронных сетей (НС) становится особенно привлекательным в этой области благодаря их способности обрабатывать большие объемы данных и находить сложные зависимости между ними.

Цель работы – разработка и апробация системы управления дорожным трафиком с использованием нейросетевых технологий.

Основные задачи исследования:

- разработка алгоритмов детекции автомобилей;
- определение методов оптимизации управления светофорами на перекрестках на основе данных о дорожном трафике;
- проведение анализа эффективности системы управления дорожным трафиком с использованием нейросетей на моделируемых тестовых участках дорог;
- мониторинг и управление системой транспорта для обнаружения и реагирования на непредвиденные события (аварии, поломки светофоров, дорожные пробки и др.).

Решение перечисленных задач способствует созданию системы, которая будет не только реагировать на текущее состояние дорожного трафика, но и способствовать его оптимизации с помощью адаптивного управления светофорами на перекрестках и предотвращения возникновения пробок. Для эффективного реагирования на постоянно меняющиеся дорожные условия автоматическая система должна быть способной к обучению. Значимость применения нейронных сетей подтверждается множеством успешных примеров использования в различных областях научных исследований.

### Существующие решения

История управления светофорами на перекрестках началась с середины XX в., когда были разработаны первые циклические программы управления. Однако с течением времени и с увеличением числа автомобилей возникла необходимость в интеллектуальных системах управления. Одно из самых распространенных существующих решений – адаптивные системы управления светофорами. Примером такой системы является SCATS (Sydney Coordinated Adaptive Traffic System), использующая индуктивные петли как сенсоры и камеры видеонаблюдения как обнаружители автомобилей на перекрестках и регулирующая время светофорного цикла в реальном времени в зависимости от трафика [2].


Однако эта и другие адаптивные системы управления светофорами в действительности используют не прямо искусственный интеллект (ИИ), а скорее методы обработки данных и алгоритмы оптимизации. Вместо того чтобы полагаться на обучение нейронных сетей или другие формы машинного обучения, они обычно работают на основе правил и эвристик, основанных на анализе данных о трафике [2]. Подобные системы имеют ограничения, такие как необходимость точных данных, ограниченная способность адаптироваться к динамическим изменениям в транспортном потоке или ограниченная обработка данных. Поэтому появилась необходимость в разработке более современных и интеллектуальных систем управления светофорами.

Для задач управления светофорами Google исследует возможности внедрения технологий ИИ, позволяющего оптимизировать поток транспорта. Sidewalk Labs (подразделение Alphabet материнской компании Google) работает над разработкой «умных» городских систем. Возможно, Google также исследует способы использования машинного обучения и других методов ИИ для более точного прогнозирования и управления трафиком на перекрестках с помощью светофоров [3].

Идея заключается в том, чтобы создать системы, которые могут адаптироваться к изменяющимся условиям на дорогах, используя анализ данных и принятие решений в реальном времени. Это может включать использование ИИ для прогнозирования трафика, определения оптимального времени работы светофоров и координации между перекрестками для улучшения общего потока транспорта.

### Детекция автомобилей

Для эффективного управления светофорами на перекрестках критически важно точно определять наличие и оценить движение автомобилей. Современные сверточные нейронные сети (CNN), демонстрируют отличные результаты в области компьютерного зрения и подходят для задачи детекции автомобилей на перекрестках (рисунок).



Пример использования нейронной сети, демонстрирующий детекцию автомобилей на перекрестке

Для обучения нейронных сетей требуются различные типы данных, служащих основой обучения модели и обеспечивающих ее способность точно определять автомобили на перекрестках при различных погодных условиях, временных изменениях интенсивности трафика и других переменных. Это позволяет оптимизировать время работы светофоров и обеспечить более плавный поток транспорта. В частности, в работе выделен метод YOLO (You Only Look Once), используемый для однократного и быстрого обнаружения объектов на изображениях в реальном времени. Он позволяет моделировать задачу обнаружения объектов как проблему регрессии, что упрощает и ускоряет процесс детекции. Такой подход может быть применен к различным классам объектов, в том числе к автомобилям. Это делает его универсальным инструментом для задач детекции объектов в различных приложениях, включая системы управления трафиком и безопасности на дорогах [4].

### **Определение средней скорости движения потока**

Решение данной задачи играет важную роль в оптимизации управления светофорами на перекрестках и оценке эффективности дорожного движения. Один из способов решения – использование оптического потока [5], основанного на анализе смещения объектов на видеоизображении между последовательными кадрами. Известно решение, включающее использование алгоритмов компьютерного зрения для выявления движущихся объектов и последующего отслеживания их положения на протяжении времени [6]. Известно использование нейронных сетей и других алгоритмов машинного обучения для анализа данных с камер видеонаблюдения, позволяющих определять скорость движения объектов на дороге [7].

### **Определение «проблемных зон»**

Эффективное управление светофорами на перекрестках требует возможности обнаруживать нетипичное или отличное от прогнозируемого поведение автомобилей и реагировать на него. Для достижения этой цели применяются методы машинного обучения, позволяющие анализировать и классифицировать динамические шаблоны движения на перекрестках.

Один из подходов к определению «проблемных зон» заключается в использовании алгоритмов кластеризации, таких как метод  $k$ -средних или DBSCAN (Density-Based Spatial Clustering of Applications with Noise). Эти алгоритмы позволяют выявлять области с высокой плотностью движения или частыми происшествиями, свидетельствующие о проблемах с транспортным потоком [8].

Применение алгоритмов кластеризации к данным о движении на перекрестках позволяет идентифицировать участки дороги, где наблюдаются аномальные или необычные паттерны поведения автомобилей. Например, это могут быть участки с частыми авариями, сильными заторами или повышенной агрессивностью вождения.

Идентификация «проблемных зон» позволяет адаптировать управление светофорами на перекрестках, чтобы улучшить поток транспорта и снизить вероятность возникновения аварийных ситуаций. Например, время ожидания на светофорах может быть увеличено или уменьшено в зависимости от текущей ситуации на участке дороги.

### **Идентификация автомобилей**

Для более точного управления светофорами необходима идентификация отдельных автомобилей. Это позволяет составлять маршруты движения для каждого транспортного средства и оптимизировать время ожидания на перекрестках.

Идентификация автомобилей может осуществляться с помощью различных методов, включая определение уникальных признаков автомобиля, таких как номерные знаки, цвет или форма, а также использование технологий RFID или машинного зрения для распознавания уникальных характеристик транспортных средств, что также способствует адаптации управления светофорами в реальном времени [9].

Для обеспечения приватности пользователей и защиты персональных данных может быть использована технология обезличивания, которая позволяет анонимизировать данные, связанные с конкретными транспортными средствами, сохраняя при этом их ценность для управления транспортным потоком.

### **Нейросетевое управление перекрестком**

Для реализации системы управления светофорами на перекрестках с использованием нейросети используется виртуализированная модель, охватывающая все возможные конфигурации перекрестков. На основе этой модели создана среда, в которой нейросеть обучается на основе различных сценариев и условий дорожного движения.

Виртуализированная модель в данном контексте представляет собой математическое описание геометрии перекрестков, расположение дорожных знаков, разметки и светофоров, являясь имитацией реального перекрестка с использованием компьютерных алгоритмов и моделей. Это включает информацию о направлениях движения, положении источников трафика, а также факторы, влияющие на безопасность и эффективность движения.

Нейросеть управления перекрестком обучена на основе данных о движении автомобилей на перекрестках, а также обратной связи от датчиков и сенсоров, установленных на светофорах: время движения автомобилей, их скорости, плотность движения и состояние светофоров.

Для обучения нейросети было применено глубокое обучение с подкреплением, позволившее ей самостоятельно определять оптимальные стратегии управления светофорами на основе полученной обратной связи. Ключевыми компонентами этого процесса являются:

- входные данные – информация о текущем состоянии дорожного движения и перекрестков;
- выходные данные – управляющие сигналы для светофоров;
- функция вознаграждения – критерий оценки эффективности управления как минимизация времени ожидания или сокращение количества аварий.

После завершения обучения нейросеть применяется для управления светофорами на виртуализированном перекрестке. Она принимает входные данные о текущем состоянии дорожного движения и генерирует соответствующие управляющие сигналы для светофоров, позволяя адаптировать их управление в реальном времени. Однако описанная реализация включает необходимость еще больших объемов данных для дальнейшего обучения, что приводит к необходимости преодоления сложности валидации обученной модели в реальном мире.

### Заключение

Системы управления светофорами на перекрестках остаются основой для повышения эффективного регулирования дорожного трафика, что определяет важность дальнейших исследований и разработок в этой области.

Описанная система управления дорожным трафиком основана на использовании нейронных сетей для обнаружения автомобилей, алгоритмов кластеризации для определения проблемных зон и адаптивного управления светофорами на перекрестках, что ориентировано на обеспечение ее эффективной реакции на динамически изменяющиеся условия на дорогах и перекрестках. Дальнейшие исследования предполагают доработку и расширение функциональности системы управления светофорами в составе системы регулирования дорожного трафика и ее тестирование, в том числе в реальных городских условиях.

### Библиографический список

1. Есть ли жизнь без пробок. URL: [cloud.vk.com/blog/est-li-zhizn-bez-probok](https://cloud.vk.com/blog/est-li-zhizn-bez-probok) (дата обращения: 28.08.2024).
2. SCATS products and capabilities. URL: [scats.com.au/overview-scats-products](https://scats.com.au/overview-scats-products) (дата обращения: 02.09.2024).
3. IEEE Spectrum. URL: [spectrum.ieee.org/alphabet-sidewalk-labs-wants-to-help-you-navigate-smart-cities](https://spectrum.ieee.org/alphabet-sidewalk-labs-wants-to-help-you-navigate-smart-cities) (дата обращения: 03.05.2024).
4. You only look once: Unified, real-time object detection / J. Redmon, S. Divvala, R. Girshick, A. Farhadi // Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. P. 779–788.
5. Traffic flow estimation with datd from a video surveillance camera / A. Fedorov, K. Nikolskaia, S. Ivanov [et al.] // Journal of Big Data. 2019. № 73. 15 P.
6. Vehicle Speed Estimation Using Computer Vision and Evolutionary Camera Calibration / H. Mejia, E. Palomo, E. López-Rubio [et al.] // 35th Conference on Neural Information Processing Systems (NeurIPS 2021), Sydney, Australia. 2021. P. 1–10.
7. Зацерковный А. В., Нурминский Е. А. Нейросетевой анализ транспортных потоков городских агломераций на основе данных публичных камер видеонаблюдения // Компьютерные исследования и моделирование. 2021. Т. 13, № 2. С. 305–318.
8. A Clustering-Based Approach to Detecting Critical Traffic Road Segments in Urban Areas / I. Košanin, M. Gnjatović, N. Maček, D. Joksimović // Axioms. 2023. № 12, 509. 17 p.
9. Ahmed K. B., Kumar D. Intelligent Transportation System Using RFID to Reduce Congestion, Ambulance Priority and Stolen Vehicle Tracking // Conference: 2019 4th International Conference on Information Systems and Computer Networks (ISCON). November 2019.

*Ю. А. Скобцов*

доктор технических наук, профессор

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## РОЕВЫЕ КВАНТОВЫЕ АЛГОРИТМЫ

Представлены новые роевые алгоритмы, основанные на моделях квантовых вычислений. Для кодирования потенциального решения используются кубиты. Путем бинарного наблюдения за квантовым (кубитовым) представлением формируются и обрабатываются потенциальные решения, которые далее используются в роевых алгоритмах. Приведены псевдокоды квантовых роевых алгоритмов с процедурами наблюдения и модификации. Отмечены преимущества и недостатки указанных моделей и области их применения.

**Ключевые слова:** роевые алгоритмы, квантовые вычисления, квантовые роевые алгоритмы.

*Yu. A. Skobtsov*

Dr. Sc., Tech., Professor

St. Petersburg State University of Aerospace Instrumentation

## QUANTUM SWARM ALGORITHMS

New swarm algorithms based on quantum computing models are presented. Qubits are used to encode a potential solution. Potential solutions are formed and processed by binary observation of the quantum (qubit) representation, which are used in swarm algorithms. Pseudocodes of quantum swarm algorithms with observation and modification procedures are given. The advantages and disadvantages of the above models and their areas of application are noted.

**Keywords:** swarm algorithms, quantum computing, quantum swarm algorithms.

### 1. Введение

Роевые алгоритмы (РА) основаны на моделировании поведения естественных и искусственных систем, которые работают коллективно и используют децентрализованное управление и самоорганизацию [1]. Примером естественных систем с роевым интеллектом являются колонии пчел, муравьев, термитов, стаи птиц, косяки рыб, светлячки, летучие мыши и др. Подобные системы вдохновили на разработку ряда роевых алгоритмов, которые моделируют различные аспекты их поведения. Оригинальные алгоритмы, такие как роевые, муравьиные и много других, разработаны для классических компьютеров [1; 2]. В настоящее время роевые методы переосмысливаются и разрабатываются новые алгоритмы, с использованием моделей квантовой механики, которые применяются и в классических компьютерах.

Квантовые компьютеры зародились в начале 1980-х гг. и быстро сформировались в отдельное направление [3]. Аналогично квантовые вычисления основаны в начале 1990-х, и показано, что квантовые компьютеры могут быть более эффективными, чем классические компьютеры для различных специализированных задач. Исследования по слиянию метаэвристик (прежде всего эволюционных алгоритмов) и квантовых вычислений начались с конца 1990-х гг. С момента появления квантовых эволюционных алгоритмов (КЭА) до сегодняшнего дня было создано множество КЭА, опубликованных в научной литературе [4; 5]. Все виды квантовых эволюционных алгоритмов успешно применялись к решению многих задач как численной, так и комбинаторной оптимизации, таких как задача упаковки рюкзака, задача коммивояжера, задача календарного планирования, криптоанализ и др. [6]. Далее рассматриваются квантовые роевые алгоритмы (КРА), которые разработаны на основе концепции и принципов квантовых вычислений, таких как квантовый бит и суперпозиция состояний. Как и РА, квантовые роевые алгоритмы также характеризуется представлением особи (потенциального решения), фитнес-функцией и динамикой эволюции популяции. Однако в КРА применяется Q-бит в качестве вероятностного представления, определяемого как наименьшая единица информации.

### 2. Квантовое представление потенциальных решений

Квантовые генетические алгоритмы основаны на концепции квантовых бит и суперпозиции состояний. Минимальная единица информации, запоминаемой в квантовом компьютере с двумя состояниями, называется квантовым битом или кубитом [3]. Кубит может находиться в состоянии 0 или 1 либо суперпозиции этих состояний [3]. Представление (кодирование) потенциального решения в КЭА использует концепцию кубитов. Состояние кубита может быть представлено следующим образом [3]:

$$|\Psi\rangle = \alpha|0\rangle + \beta|1\rangle, \quad (1)$$

где  $\alpha$  и  $\beta$  – комплексные числа, которые определяют амплитуды соответствующих состояний. При этом  $|\alpha|^2$  определяет вероятность того, что кубит находится в состоянии 0; соответственно  $|\beta|^2$  определяет вероятность нахождения кубита в состоянии 1, и выполняется нормализация  $|\alpha|^2 + |\beta|^2 = 1$ . Итак один кубит определяется парой комплексных чисел  $\begin{bmatrix} \alpha \\ \beta \end{bmatrix}$ , а кубит-особь (потенциальное решение) определяется как строка из  $j$  кубитов, представляющая квантовую систему  $|\psi\rangle^i$  с  $2^j$  текущими состояниями:

$$\begin{pmatrix} \alpha_1 & \alpha_2 & \dots & \alpha_j \\ \beta_1 & \beta_2 & \dots & \beta_j \end{pmatrix}_i \rightarrow |\psi\rangle^i = \sum_j c_j |\psi\rangle^j. \quad (2)$$

### 3. Квантовые роевые алгоритмы

В [7] представлена эволюционная теория квантового роя (Quantum Swarm Evolutionary Algorithm (QSE)), основанная на синтезе генетического квантового алгоритма GQA и роевого алгоритма. Здесь квантовая частица представляется массивом квантовых углов. Следовательно, чтобы использовать роевой алгоритм для автоматического обновления кубита, нам надо определить следующие понятия. «Квантовый угол» – это произвольный угол  $\theta$ , а кубит представляется как  $[\theta]$ . Следовательно,  $[\theta] = [\sin(\theta) \cos(\theta)]^T$  эквивалентен исходному кубиту, поскольку он удовлетворяет условию  $|\sin(\theta)|^2 + |\cos(\theta)|^2 = 1$ . Тогда эквивалентом квантовой хромосомы  $q$  для квантового роевого алгоритма является  $q = [[\theta_1] | [\theta_2] \dots [\theta_m]]$ . Квантовый рой определяется как  $Q(t) = \{q^1, q^2, \dots, q^n\}$ , где  $q^i = [[\theta^i_{i1}] | [\theta^i_{i2}] \dots [\theta^i_{im}]]$ . Алгоритм QSE представлен псевдокодом алгоритма A1.

Алгоритм A1

```

21 Procedure QSA
22 t=0
23 Инициализация начальной популяции квантовых хромосом Q(t)
24 Наблюдение состояний Q(t) и генерация P(t) популяции двоичных хромосом
25 Оценка двоичных решений P(t)
26 Запоминание лучших решений среди P(t) в B(t)
27 While(не выполнено условие останова) do
28 t=t+1
29 Наблюдение состояний Q(t-1) и генерация P(t)
30 Оценка двоичных решений P(t)
31 Изменение квантовой популяции Q(t) с помощью квантовых вентиля U(t)
32 Запоминание лучших b решений среди B(t-1) и P(t) в B(t)
33 Запоминание лучшего решения b среди B(t)
34 If выполняется условие миграции then
35 Миграция b или b1 в B(t) глобально или локально соответственно
36 End
37 End
38 End QSA

```

Здесь процедуры наблюдения и изменения модифицированы для работы с квантовыми частицами вместо квантовых особей (которые используются в квантовых эволюционных алгоритмах). Далее представлены псевдокоды этих процедур.

Алгоритм A2

```

1 Procedure Наблюдение_QSA
2 j=0
3 While j<m do
4 j=i+1
5 i=0
6 While j<k do
7 i=j+1
8 If random[0,1] > |cos(θij)|2 then
9 xi=1
10 Else
11 xi=0
12 End
13 End
14 End
15 End_Наблюдение_QSA

```

В этой версии процедуры **Наблюдение\_QSA** (алгоритм A2) каждая двоичная компонента частицы  $x_{ij}^t$  может принимать значения 0 или 1 в  $P(t)$ , что достигается путем наблюдения за состояниями  $Q(t)$  и использованием значений  $|\cos(\theta_{ij})|^2$  или  $|\sin(\theta_{ij})|^2$ . Другими словами, данный алгоритм использует двоичное наблюдение и строит вспомогательные двоичные хромосомы.

Процедура изменения модифицирована и использует основные формулы скоростей роевого алгоритма для изменения скорости позиции частицы вместо применения квантового вентиля вращения  $U(\theta)$ , в котором вычисляется  $[\theta_j = \theta_j + \xi(\Delta\theta_j)]$ . Процедура изменения QSA приведена в алгоритме A2 и использует следующие уравнения роевого алгоритма:

$$v_{ij}^{t+1} = \chi \left[ \omega v_{ij}^t + c_1 r_1 \left[ \theta_{ij}^t (pbest) - \theta_{ij}^t \right] \right] + c_2 r_2 \left[ \theta_j^t (gbest) - \theta_{ij}^t \right], \quad (3)$$

$$\theta_{ij}^{t+1} = \theta_{ij}^t + v_{ij}^{t+1}. \quad (4)$$

Алгоритм A3

**1 Procedure Изменение QSA**

**2**  $i=0$

**3**  $j=0$

**4 While**  $i < m$  **do**

**5**  $i=i+1$

**6 while**  $j < k$  **do**

**7**  $j=j+1$

**8**  $v_{ij}^{t+1} = \chi \left[ \omega v_{ij}^t + c_1 rand() \left[ \theta_{ij}^t (pbest) - \theta_{ij}^t \right] \right] + c_2 rand() \left[ \theta_j^t (gbest) - \theta_{ij}^t \right]$

**9**  $\theta_{ij}^{t+1} = \theta_{ij}^t + v_{ij}^{t+1}$

**10 End**

**11**  $q=q'$

**12 End Изменение QSA**

Этот алгоритм апробирован на 0-1 задаче об укладке рюкзака и задаче коммивояжера (TSP) с 14 городами. Известно, что задачи TSP и 0-1 укладка рюкзака являются NP-полными проблемами. В указанной работе использовались следующие значения параметров:  $\chi = 0 : 99$ ,  $w = 0 : 7298$ ,  $c_1 = 1 : 42$  и  $c_2 = 1 : 57$ . Эти значений удовлетворяет условиям сходимости частиц  $w > (c_1 + c_2) / 2 - 1$ . Поскольку  $c_2 > c_1$ , частицы быстрее сходятся к глобальному оптимальному положению в рое, чем находится локальное оптимальное положение каждой частицы. Следовательно, QSA на основе PSO обладает свойством глобального поиска.

#### 4. Заключение

Квантовые роевые алгоритмы обладают отличной способностью глобального поиска из-за своего разнообразия и вероятностного представления и имеют быструю сходимость к лучшему решению. Они также имеют более четкое условие завершения и меньшее время решения. Экспериментальные результаты для тестовых функций (benchmarks) подтвердили эти характеристики.

#### Библиографический список

1. Родзин С. И., Скобцов Ю. А., Эль-Хатиб С. А. Биоэвристики: теория, алгоритмы и приложения: монография. Чебоксары: Среда, 2019. 224 с.
2. Скобцов Ю. А., Сперанский Д. В. Эволюционные вычисления. 2-е изд. М: Нац. ун-т; Лань, 2016.
3. Нильсен М., Чанг И. Квантовые вычисления и квантовая информация. М.: Мир, 2006.
4. Lahoz-Beltra R. Quantum Genetic Algorithms for Computer Scientists // Computers. 2016. № 5. P. 24.
5. Ross M. H. O. A review of quantum-inspired metaheuristics: Going from classical computers to real quantum computers // IEEE Access. 2020. № 8. P. 814–838.
6. Skobtsov Y. A. Comparison of traditional and quantum genetic algorithms // Mathematical methods in technology and engineering. 2023. № 4. P. 91–95.
7. Yang S., Wang M., Jiao L. A novel quantum evolutionary algorithm and its application // Proceedings of 2004 Congress on Evolutionary Computation(CEC2004). 2004. Vol. 1, Iss. 19-23. P. 820–826.



**В. Ю. Скобцов**

кандидат технических наук, доцент

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ГИБРИДНЫЕ КЛАССИФИКАЦИОННЫЕ МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОПРЕДЕЛЕНИЯ СОСТОЯНИЯ ФУНКЦИОНИРОВАНИЯ СЛОЖНЫХ СИСТЕМ

Рассмотрена задача классификационного анализа данных временных рядов функционирования сложных систем (СлС) с целью определения их состояния функционирования. Представлены результаты разработки и исследования одиночных гибридных нейросетевых классификаторов, генетический алгоритм автоматического поиска таких моделей, ансамблевых моделей гибридных нейросетевых классификаторов на базе ансамблей типа бэггинг и AdaBoost. Сравнительный анализ разработанных гибридных нейросетевых классификаторов показал их преимущество ряду метрик качества классификационных моделей по сравнению с известными глубокими нейросетевыми классификаторами и ансамблями деревьев принятия решений.

**Ключевые слова:** обнаружение состояния функционирования, классификация, гибридная нейронная сеть, ансамбль классификаторов.

**V. Yu. Skobtsov**

PhD, Tech., Associate Professor

St. Petersburg State University of Aerospace Instrumentation

## HYBRID CLASSIFICATION MODELS OF MACHINE LEARNING FOR DETERMINING THE STATE OF OPERATION OF COMPLEX SYSTEMS

The classification analysis of complex systems time series data to determine their state of operation was considered. The results of development and research of single hybrid neural network classifiers, genetic algorithm for automatic search of such models, ensemble models of hybrid neural network classifiers based on ensembles of the type - Begging and AdaBoost are presented. Comparative analysis of the developed hybrid neural network classifiers showed their advantage to a number of quality metrics of classification models compared to the known deep neural network classifiers and decision tree ensembles.

**Keywords:** detection of state of functioning, classification, hybrid neural network, classifier ensemble.

### Введение

Мониторинг и определения состояния функционирования сложных систем (СлС) заключается в оценке и анализе состояния таких объектов с целью своевременного обнаружения и предотвращения нештатных ситуаций. В современных условиях для решения перечисленных задач, обеспечения требуемой степени качества мониторинга и оперативности управления СлС необходимо решить комплекс задач автоматического анализа данных об их функционировании [1].

Методы машинного и глубокого обучения (МО, ГО) – на текущий момент одни из самых перспективных и широко используемых подходов в анализе данных высокотехнологичных систем. Яркими и широко известными примерами их применения являются разработки таких компаний, как Yandex, Facebook, Google, Amazon, научно-исследовательских центров МИТ, университетов Кэмбриджа, Стенфорда, Беркли, Принстона, Южной Калифорнии, МФТИ, ВШЭ, ИТМО [2].

### 1. Задача классификации временного ряда данных функционирования СлС

Будем рассматривать анализируемый массив данных функционирования СлС как  $M$ -мерный временной ряд  $X = (X_1, X_2, \dots, X_M)$ , каждый элемент которого  $X_j \in R^T$  является столбцом матрицы  $X$  данных показателей СлС, описывающим поведение  $j$ -го показателя системы на отрезке дискретных моментов времени  $[1, T]$ . В процессе мониторинга данных о функционировании СлС, представленного временным рядом, задача определения его состояния функционирования может решаться как задача классификации некоторой категориальной метки класса целевого параметра  $Y \in \{0, 1, \dots, k-1\}$  – экспертной метки состояния функционирования. Таким образом, стоит задача нахождения модели нелинейного отображения входных данных временного ряда  $X$  в целевой вектор  $Y$ .

### 2. Гибридные нейросетевые классификаторы данных функционирования СлС

В последние несколько лет эффективное применение в задачах анализа данных различной природы находят так называемые гибридные глубокие нейронные сети, которые объединяют в своей архитектуре комбинации различных типов современных нейронных слоев: сверточных, рекуррентных, полносвязных. В работах [3; 4] китайских исследователей приведены результаты, показывающие превосходство качества гибридных нейросетевых моделей для задач анализа данных временных рядов.

Поэтому были исследованы и разработаны гибридные нейросетевые модели на основе комплексирования одномерных сверточных, рекуррентных типа GRU и полносвязных нейронных слоев как итоговых классификаторов/регрессоров для задач классификации данных различной природы [5–7]. Также в моделях применялась методика остаточных связей архитектур ResNet [8] поскольку это упрощает обучение сети за счет уменьшения эффекта исчезающего градиента.

Предложенные гибридные нейросетевые модели имеют в общем случае следующую структуру:

$Z_1 = \text{Conv1D}(\text{filters}=n, \text{kernel\_size}=k1, \text{activation}='AF1')(X_i)$   
 $Z_1 = \text{Conv1D}(\text{filters}=n, \text{kernel\_size}=k1, \text{activation}='AF1')(Z_1) * C1$  слоев  
 $Z_2 = \text{add}([Z_1, X_i])$  – остаточная связь of  $X_i$   
 $Z_2 = \text{AveragePooling1D}(p)(Z_2)$   
 $Z_3 = \text{Conv1D}(\text{filters}=n, \text{kernel\_size}=k2, \text{activation}='AF1')(Z_2)$   
 $Z_3 = \text{Conv1D}(\text{filters}=n, \text{kernel\_size}=k2, \text{activation}='AF1')(Z_2) * C2$  слоев  
 $Z_4 = \text{AveragePooling1D}(p)(X_i)$   
 $\text{Output} = \text{add}([Z_2, Z_3, Z_4])$  – остаточная связь of  $Z_2$  and  $Z_3$   
 $\text{Output} = \text{GRU}(\text{units}=r)$   
 $\text{Output} = \text{Dense}(d, \text{activation}='AF1')(\text{Output}) * C3$  слоев  
 $\text{Output} = \text{Dense}(k, \text{activation}='AF2')(\text{Output})$

На основе данной архитектуры разработаны и исследованы гибридные нейросетевые классификационные модели, решающие задачи определения штатного и нештатных категориальных состояний на основе анализа данных временных рядов телеметрической информации (ТМИ) двух типов: навигационной подсистемы Белорусского космического аппарата (БКА) и малого космического аппарата (МКА) «АИСТ» Самарского национального исследовательского университета имени академика С. П. Королева. Рассматривались 2- и 3-классовые задачи классификации для определения штатного и нештатного состояний космических аппаратов. Выполнен сравнительный анализ с известными глубокими нейросетевыми классификаторами: LeNet, AlexNet, Xception, Yolo, MobileNet, Inception, ResNet. Для задачи бинарной классификации на данных ТМИ БКА разработанная гибридная нейросетевая модель сравнима по точности с нейросетевой классификационной моделью Inception (остальные классификаторы имеют меньшую точность): ~0,98 (этап обучения), ~0,97 (этапы валидации и тестирования). При этом полученная гибридная модель в 2,5 раза быстрее по времени обучения и валидации и имеет более облегченную структуру, что важно для ее реализации. Для задачи трех-классовой классификации на данных ТМИ МКА «АИСТ» для разработанной гибридной нейросетевой модели были получены точности: ~0,998 (этап обучения), ~0,981 (этап валидации) и ~0,985 (этап тестирования). Сравнительный анализ показал преимущество полученного решения по точности классификации на этапе тестирования для всех сравниваемых моделей на 1–7%, по времени обучения и валидации почти для всех сравниваемых моделей получено преимущество в 1,5–4,0 раза.

С целью сокращения времени создания нейросетевых моделей был разработан генетический алгоритм (ГА) автоматического поиска гибридных нейросетевых моделей, который был применен для решения задач как анализа данных ТМИ МКА, так и для обнаружения сетевых атак в наборе данных kddcup [7]. Предложенный ГА выполняет поиск не только значений гиперпараметров, но и модели гибридной нейронной сети в целом заданной архитектуры. Для данных ТМИ КА «АИСТ» наилучшее значение фитнес-функции, достигнутое в ходе эксперимента, составляет 98,8%, для данных ТМИ БКА – 98,0%, что превышает показатели для моделей, разработанных вручную. В конце поиска было отмечено, что представители с разными хромосомами – нейронными сетями показали результаты, близкие к максимальному значению фитнес-функции – точности классификации. Данный факт можно рассматривать как экспериментальное подтверждение построения решения, близкого к оптимальному, для определенных условий поиска.

### 3. Ансамбли гибридных нейросетевых классификаторов данных функционирования СлС

Современные распространенные ансамблевые модели достаточно эффективны в решении задач анализа данных временных рядов различной природы. Поэтому также были разработаны и исследованы модели ансамблей типа бэггинг и бустинг [8] гибридных нейросетевых классификаторов для задачи определения штатного (0) и нештатных состояний (1 – отказ, 2 – сбой) ТМИ МКА «АИСТ» методом 3-классовой классификации. Также будут приведены результаты сравнительного анализа с различными ансамблевыми моделями на базе деревьев принятия решений.

В качестве базовой модели была взята полученная с помощью разработанного нами ГА автоматического поиска гибридная нейросетевая модель следующей структуры:

$Z_1 = \text{Conv1D}(\text{filters}=f1, \text{kernel\_size}=k1, \text{activation}='relu')(X_i)$   
 $Z_1 = \text{BatchNormalization}(Z_1)$   
 $Z_1 = \text{AveragePooling1D}(2)(Z_1)$   
 $Z_1 = \text{BatchNormalization}(Z_1)$   
 $Z_1 = \text{Conv1D}(\text{filters}=f2, \text{kernel\_size}=k2, \text{activation}='relu')(Z_1)$   
 $Z_1 = \text{BatchNormalization}(Z_1)$   
 $Z_1 = \text{AveragePooling1D}(2)(Z_1)$

$Z_1 = \text{BatchNormalization}(Z_1)$

Output = GRU(units=g)

Output = Dense(d, activation='relu')(Output) \* C3 слоев

Output = Dense(3, activation='softmax')(Output)

Данная гибридная нейросетевая модель была получена в результате автоматического поиска гибридной нейросетевой классификационной модели на данных ТМИ БКА, решающей задачу бинарной классификации данных ТМИ БКА. Такой подход позволил нам также ответить экспериментально на вопрос о возможности использования обученной модели, полученной на данных ТМИ одного МКА (БКА), для решения задачи классификации данных ТМИ другого МКА (АИСТ).

В качестве метрик качества классификационных моделей будем рассматривать метрику точности (accuracy), а также  $F_1$  меру для каждого класса [8]. Последняя метрика используется в силу важности детектирования помимо класса 0 штатного состояния БА МКА, также классов 1 – отказа и 2 – сбоя.

Ансамблевые методы являются мощным инструментом МО и находят широкое применение. Цель ансамблевых методов – объединить прогнозы нескольких оценок базовых моделей, чтобы улучшить обобщаемость/надежность по сравнению с оценкой одиночной базовой модели. Модели нулевого уровня (базовые модели) – это модели, обученные на тренировочных данных, прогнозы которых собираются. Модель первого уровня (метамодель) – это модель, которая учится наилучшим образом комбинировать прогнозы базовых моделей.

В методах усреднения главный принцип состоит в том, чтобы построить несколько оценщиков независимо параллельно, а затем усреднить их прогнозы. Комбинированная оценка обычно лучше, чем любая из оценок с одной базой, потому что ее дисперсия уменьшается. В методах усиления базовые оценки строятся последовательно, и каждый пытается уменьшить смещение комбинированной оценки. Мотивация состоит в том, чтобы объединить несколько слабых моделей для создания мощного ансамбля. Наиболее широко используются следующие ансамблевые методы: бэггинг (модельное усреднение – bagging, bootstrap aggregation) и бустинг (модельное усиление – hypothesis boosting) [8].

Таким образом, для построения модели ансамбля гибридных нейросетевых классификаторов применялись два типа ансамблевых моделей: бэггинг и AdaBoost.

В качестве данных для анализа использовались ТМИ МКА «АИСТ» [9]. Общая размерность 49-мерного временного ряда данных ТМИ  $X$  составила 2679 векторов. Из них было выделено 1714 векторов для формирования обучающего набора данных, 429 – для формирования валидационного набора данных и 536 векторов тестового набора данных.

Рассматривались модели ансамблей размерности 5, 50 и 100 базовых моделей. Сравнительный анализ результатов тестирования обученных базовой и ансамблевых моделей типа AdaBoost гибридных нейросетевых классификаторов показал, что показатель Accuracy ансамблевой модели на основе гибридного нейросетевого классификатора увеличился по сравнению с базовой до 0,99 для 5 базовых моделей и далее для числа базовых моделей 50 и 100 не повышался. При этом  $F_1$ -мера увеличилась только для класса 2 сбоя со значения 0,77 до 0,82 для ансамбля из 5 базовых моделей и далее не росло. То есть увеличивать число базовых моделей выше 5 не имеет смысла.

Сравнительный анализ результатов тестирования обученных базовой и ансамблевых моделей типа бэггинг гибридных нейросетевых классификаторов продемонстрировал, что показатель Accuracy ансамблевой модели увеличился по сравнению с базовой моделью до 0,99 для 5 базовых моделей и далее для числа базовых моделей 50 и 100 не повышался. При этом  $F_1$ -мера: для класса 0 штатного состояния увеличилась для ансамбля из 5 базовых моделей до значения 1,00 и далее не менялась, для класса 1 состояния отказа увеличилась для ансамбля из 5 базовых моделей до значения 0,97 и далее не менялась, для класса 2 сбоя ее значение существенно увеличилось со значения 0,77 до 0,82 для ансамбля из 5 базовых моделей и далее до значения 0,85 для числа базовых моделей 100. Таким образом, лучшей ансамблевой моделью типа бэггинг является модель из 100 базовых гибридных нейросетевых классификаторов. Итого, эксперименты показали преимущество ансамбля из 100 базовых моделей гибридных нейронных сетей типа бэггинг по сравнению с ансамблем типа AdaBoost и повышение эффективности разработанной модели по сравнению с базовым классификатором.

Далее выполним сравнение результатов полученной лучшей модели бэггинг-ансамбля гибридных нейросетевых классификаторов из 100 базовых моделей с ансамблевыми моделями из 100 базовых моделей типа деревьев принятия решения следующих наиболее распространенных типов: Random Forest, Bagging, Gradient Boosting, Adaptive Boosting (AdaBoost), Histogram-based Gradient Boosting [8]. Сравнительный анализ результатов тестирования обученных ансамблевых моделей типа бэггинг гибридных нейросетевых классификаторов выше перечисленных ансамблей деревьев показал, что лучшей моделью среди ансамблей деревьев принятия решений является Random Forest со значениями метрик классификации: показатель Accuracy – 0,98,  $F_1$ -мера для класса 0 штатного состояния – 0,99, для класса 1 состояния отказа – 0,98, для класса 2 сбоя – 0,71. При этом лучшей моделью по сравнению с моделями древовидных ансамблей является модель ансамбля типа бэггинг гибридных нейросетевых классификаторов со значениями метрик: показатель Accuracy – 0,99,  $F_1$ -мера для класса 0 штатного состояния – 1,00, для класса 1 состояния отказа – 0,97, для класса 2 сбоя – 0,85.

#### 4. Заключение

В силу показанного преимущества гибридных нейросетевых моделей для решения задач анализа и мониторинга данных о функционировании СЛО перспективным является дальнейшее исследование гибридных нейросетевых моделей на основе их комплексирования с классическими моделями нелинейных отображений и фильтров, а также классических моделей машинного обучения. В качестве перспективных нелинейных моделей предполагается исследование инвариантного расширенного фильтра Калмана и диффузионных отображений.

#### Библиографический список

1. Концепция проактивного управления сложными объектами: теоретические и технологические основы / М. Ю. Охтилев, Н. Г. Мустафин, В. Е. Миллер, Б. В. Соколов // Известия вузов. Приборостроение. 2014. Т. 57, № 11. С. 7–14.
2. Искусственный интеллект. Текущее состояние в России и мире. Стратегия России // Искусственный интеллект: альманах. 2019. Вып. 1. 151 с.
3. *Chen H., Zhang Z.* Hybrid neural network based on novel audio feature for vehicle type identification // 2020 IEEE International Instrumentation and Measurement Technology Conference (I2MTC): proceedings of the international conference (25–28 May 2020). 2021.
4. *Zhao N.* Combination of Convolution-al Neural Network and Gated Recurrent Unit for Aspect-Based Sentiment Analysis // IEEE Access. 2021. Vol. 9. P. 15561–15569.
5. *Skobtsov V. Yu.* Binary classification of small satellites telemetry data based on deep learning approach // Applied Aspects of Information Technology. 2021. Vol. 4, № 4. P. 299–310.
6. *Скобцов В. Ю., Соколов Б. В.* Гибридные нейросетевые модели в задаче мультиклассовой классификации данных телеметрической информации малых космических аппаратов // Вестник ВГУ. Системный анализ и информационные технологии. 2022. № 3. С. 99–114.
7. *Skobtsov V.Y., Stasiuk A.* (2023). Automatic Searching the Neural Network Models for Time Series Classification of Small Spacecraft's Telemetry Data with Genetic Algorithms // Artificial Intelligence Application in Networks and Systems. CSOC 2023. Lecture Notes in Networks and Systems / Silhavy R., Silhavy P. (eds). 2023. Vol. 724. P. 800–811.
8. *Aurélien G.* Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. 2<sup>nd</sup> ed. Sebastopol, CA: O'Reilly Media, Inc., 2019. 1065 p.
9. Основные проектные характеристики и результаты эксплуатации группировки малых космических аппаратов научно-образовательного назначения серии «АИСТ» / А. Н. Кирилин, Р. Н. Ахметов, С. И. Ткаченко [и др.] // Космическая техника и технологии. 2019. № 1(24). С. 68–83.

*В. Ю. Скобцов*

кандидат технических наук, доцент

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## РЕГРЕССИОННЫЙ АНАЛИЗ ДАННЫХ СЛОЖНЫХ СИСТЕМ НА ОСНОВЕ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ

Рассмотрена задача мониторинга инновационных процессов сложных экономических систем на основе регрессионного анализа данных временных рядов. Разработаны и исследованы гибридные нейросетевые модели регрессионного анализа с использованием двух типов наборов данных о функционировании экономических систем. Предложенные гибридные нейросетевые модели показали преимущество по величине ошибки и коэффициенту детерминации по сравнению с полносвязной и сверточной нейросетевой моделями.

**Ключевые слова:** мониторинг, регрессия, гибридная нейронная сеть.

*V. Yu. Skobtsov*

PhD, Tech., Associate Professor

St. Petersburg State University of Aerospace Instrumentation

## REGRESSION ANALYSIS OF COMPLEX SYSTEMS BASED ON MACHINE LEARNING MODELS

The problem of monitoring innovation processes of complex economic systems based on regression analysis of time series data is considered. Hybrid neural network models of regression analysis using two types of sets of data on the functioning of economic systems have been developed and investigated. The proposed hybrid neural network models showed an advantage in terms of error and determinism over fully-connected and concatenated neural network models.

**Keywords:** monitoring, regression, hybrid neural network.

### Введение

Большой объем данных, накапливающихся в специализированных банках данных и веб-порталах, может быть эффективно использован для совершенствования процесса мониторинга динамики инновационных процессов сложных экономических систем. В связи с тем, что такая информация представляет собой разнородные нерегулярные многомерные данные, актуальны исследование, разработка и применение моделей, которые позволяют анализировать такого рода данные с возможностью извлечения из них полезной информации и последующего построения с их использованием регрессионных моделей с целью определения экономического состояния анализируемого объекта принятия корректных экономических и управленческих решений.

Методы машинного и глубокого обучения (МО и ГО) и математической статистики на текущий момент – одни из самых перспективных и широко используемых подходов в анализе данных сложных экономико-производственных и финансовых систем. Первые работы, посвященные применению подходов МО к проблемам финансов и экономики, появляются в 80–90-х гг. XX столетия. Обзор первой декады применения нейронных сетей в финансах рассматривается в работе А. Фадлалла и Л. Чиен-Хуа [1]. Часто исследования были связаны с предсказанием банкротств предприятий, динамики цен на активы фондового рынка и присвоением кредитного рейтинга выпускам облигационных займов. С 1990-х гг. интерес к применению МО/ГО изменялся с положительной динамикой по нарастанию. Особенно резкий скачок интереса к моделям ГО произошел после 2010–2012 гг. с первыми случаями прорывного и эффективного применения сверточных нейронных сетей и началом эры ГО. Д. Хитон и коллеги [2] всесторонне анализируют новейшие способы приложения идей глубокого обучения в финансах. В исследовании отечественных авторов А. В. Колышкина и его коллег [3] нейронные сети использовались для прогнозирования несостоятельности предприятий на основе выборки в 3033 компании, что позволило идентифицировать 85,7% банкротств в контрольной выборке по сравнению с 64,3% и 71,4% для традиционных эконометрических подходов. Другим примером решения задачи моделирования финансово-экономических процессов может служить работа по анализу взаимосвязи между черной металлургией, загрязнением воздуха и экономическим ростом в Китае с применением машинного обучения» [4]. С помощью нейросетевой рекуррентной модели типа LSTM была оценена взаимосвязь между четырьмя параметрами: производством стали, экономическим ростом, выбросами CO<sub>2</sub> и PM<sub>2,5</sub>. Точность прогнозирования параметров оказалась выше 80%. Интересен пример применения сверточной глубокой нейронной сети в задаче прогнозирования индекса волатильности [5]. Разработанный подход позволяет потенциальным инвесторам принимать решения по таким важным темам, как этическое инвестирование, анализ эффективности, а также устойчивым инвестиционным стратегиям. Полученная авторами модель показала значение среднеквадратичной ошибки 0,8.

## 1. Анализируемые наборы данных

В работе исследовалась возможность использования моделей глубоких нейронных сетей для мониторинга динамики инновационных процессов. Для этих целей были сформированы два набора данных временных рядов на основе двух разделов веб-портала статистических данных Росстата: «Наука, инновации и технологии», «Технологическое развитие» [6]. Бралась данные в целом по Российской Федерации за 2010–2022 гг. Для первого набора данных в качестве целевого признака использовался «уровень инновационной активности организаций», в качестве признаков-аргументов брались показатели, характеризующие финансово-экономические показатели организаций, численность и кадровый состав, уровень инновационной деятельности и применения организациями современных технологий, уровень подготовки научных кадров высшей квалификации. Размерность вектора признаков-аргументов составила 25. Для второго набора данных в качестве целевого признака использовалась «доля внутренних затрат на исследования и разработки в ВВП», в качестве признаков-аргументов бралась немного другая группа показателей, которая также характеризует финансово-экономические показатели организаций, уровень инновационной деятельности и применения организациями современных технологий. Размерность вектора признаков-аргументов составила 14.

Поскольку число временных точек в исходных наборах данных составляет всего  $T = 13$ , что является недостаточным для обучения, особенно нейросетевых регрессионных моделей, то исходные наборы данных были расширены с помощью кусочно-полиномиального метода интерполяции. Остальные методы интерполяции давали худшие результаты по качеству разрабатываемых нейросетевых моделей. Данный подход позволил увеличить размерность временного ряда данных до  $T = 145$ .

Был выполнен анализ линейной корреляционной зависимости на основе коэффициента корреляции Пирсона целевых признаков обоих наборов данных от признаков-аргументов как для исходных, так и для нормализованных данных. Результаты говорят о сильном и среднем уровне зависимости в случае исходных данных, и для нормализованных данных практически для всех признаков-аргументов – о сильной и очень сильной зависимости с целевыми признаками. В силу этого будем использовать в процессе анализа и построения нейросетевой регрессионной модели машинного обучения данные всех признаков-аргументов.

## 2. Задача регрессии данных временных рядов

Поскольку мы решаем задачу мониторинга числовых (не комбинаторных) целевых признаков, то наша цель – построить и обучить регрессионную нейросетевую модель ГО в силу того, что приведенные работы показали преимущество нейросетевых моделей ГО по сравнению моделями МО для данных рассматриваемой области. Для задачи регрессионного анализа значения элементов целевого эталонного вектора  $y_i \in \mathbf{R}$ , а целевой вектор  $\mathbf{Y} \in \mathbf{R}^T$ , где  $T$  – число векторов в матрице  $\mathbf{X}$  данных временного ряда функционирования анализируемой экономической системы. Таким образом, стоит задача нахождения модели нелинейного отображения входных данных временного ряда в целевой вектор  $\mathbf{Y} \in \mathbf{R}^T$  с некоторой точностью  $y: \mathbf{X} \rightarrow \mathbf{Y}$ .

Для исследуемых глубоких нейросетевых регрессионных моделей в качестве метрик качества использовались следующие широко распространенные в МО метрики: корень квадратный из среднеквадратичной шибки  $RMSE$  и коэффициент детерминации  $R^2$  [7].

## 3. Гибридные нейросетевые модели регрессии

В последние несколько лет эффективное применение в задачах анализа различных типов данных находят так называемые гибридные глубокие нейронные сети, которые превосходят по качеству самостоятельные типы современных нейронных сетей и объединяют в своей архитектуре их комбинации: сверточных, рекуррентных и полносвязных прямого распространения слоев [8; 9]. Поэтому за основу разрабатываемой регрессионной модели была взята гибридная нейросетевая архитектура с применением технологии остаточных связей сетей типа ResNet [7], что позволяет потоку градиента распространяться напрямую через эти соединения и облегчает задачу обучения благодаря уменьшению эффекта исчезающего градиента.

В качестве активационных функций промежуточных сверточных и полносвязных слоев мы предлагаем использовать хорошо известную функцию гиперболического тангенса. В выходном регрессионном полносвязном слое применяется активационная функция ReLU – rectified linear unit, поскольку область ее значений  $(0, \infty)$  совпадает с областями значений целевых признаков анализируемых наборов данных временных рядов [6; 7]. Комбинация нелинейных активационных функций в скрытых слоях и линейной функции в выходном слое нейронной сети дает хорошее качество регрессионной модели, это хорошо известный результат. Но именно комбинация гибридной глубокой нейросетевой архитектуры с указанными активационными функциями позволила получить экспериментально подтвержденное достаточно высокое качество предложенной регрессионной глубокой нейросетевой модели для обоих исследуемых наборов данных.

Разработка и экспериментальное исследование глубокой нейросетевой модели проводилась в три этапа:

1) полносвязная регрессионная нейросетевая модель:

$$\mathbf{Z}_1 = \text{Dense}(d, \text{activation}=' \tanh ') (\mathbf{X}_i)$$

$$\mathbf{Z}_2 = \text{Dense}(d, \text{activation}=' \tanh ') (\mathbf{Z}_1)$$

$Z_3 = \text{Dense}(d, \text{activation}=' \tanh ')(Z_2)$   
 $Z_4 = \text{Dense}(d, \text{activation}=' \tanh ')(Z_3)$   
**Output** = Dense(1, activation='relu')(Z<sub>4</sub>);

2) одномерная сверточная регрессионная нейросетевая модель:

$Z_1 = \text{Conv1D}(\text{filters}=n, \text{kernel\_size}=k, \text{activation}=' \tanh ')(X_i)$   
 $Z_2 = \text{Conv1D}(\text{filters}=n, \text{kernel\_size}=k, \text{activation}=' \tanh ')(Z_1) * c$  слоев  
 $Z_3 = \text{add}([Z_2, X_i])$  – пропуск остаточной связи входа  $X_i$   
 $Z_4 = \text{Dense}(d, \text{activation}=' \tanh ')(Z_3)$   
 $Z_5 = \text{Dense}(d, \text{activation}=' \tanh ')(Z_4)$   
 $Z_6 = \text{Dense}(d, \text{activation}=' \tanh ')(Z_5)$   
 $Z_7 = \text{Dense}(d, \text{activation}=' \tanh ')(Z_6)$   
**Output** = Dense(1, activation='relu')(Z<sub>7</sub>);

3) гибридная глубокая регрессионная нейросетевая модель, состоящая из объединения блока одномерных сверточных слоев, блока рекуррентных слоев и блока полносвязных слоев:

$Z_1 = \text{Conv1D}(\text{filters}=n, \text{kernel\_size}=k, \text{activation}=' \tanh ')(X_i)$   
 $Z_2 = \text{Conv1D}(\text{filters}=n, \text{kernel\_size}=k, \text{activation}=' \tanh ')(Z_1) * c$  слоев  
 $Z_3 = \text{add}([Z_2, X_i])$  – пропуск остаточной связи входа  $X_i$   
 $Z_4 = \text{RNN}(\text{units}=r)$   
 $Z_5 = \text{Dense}(d, \text{activation}=' \tanh ')(Z_4)$   
 $Z_6 = \text{Dense}(d, \text{activation}=' \tanh ')(Z_5)$   
 $Z_7 = \text{Dense}(d, \text{activation}=' \tanh ')(Z_6)$   
 $Z_8 = \text{Dense}(d, \text{activation}=' \tanh ')(Z_7)$   
**Output** = Dense(1, activation='relu')(Z<sub>8</sub>).

Результаты обучения и тестирования нейросетевых регрессионных моделей указанных архитектур показывают, что лучшие значения корня квадратного из среднеквадратической ошибки *RMSE* и коэффициента детерминации  $R^2$  для первого временного ряда данных с целевым признаком «уровень инновационной активности организаций» наблюдаются у разработанной гибридной глубокой регрессионной нейросетевой модели, как по значению *RMSE*, так и по значению коэффициента детерминации: (0.0538, 0.9962). Показатели качества моделей полносвязной и глубокой сверточной регрессионных нейросетевых моделей хуже, особенно на порядок хуже по значению *RMSE*: (0.2477, 0.9211) и (0.1696, 0.9625) соответственно. Наихудшие значения наблюдаются у полносвязной нейросетевой модели.

Для второго набора данных с целевым признаком «доля внутренних затрат на исследования и разработки в ВВП» лучшие значения метрик качества также показывает гибридная глубокая регрессионная нейросетевая модель: (0.0223, 0.7378). При этом значения показателя *RMSE* даже ниже, чем для случая первого набора данных, но показатель детерминации составляет 0.7378 по сравнению с 0.9962 в случае первого анализируемого набора данных. Это объясняется тем, что значения выхода регрессионной модели и эталонных значений в обучающей выборке колеблются вокруг значения 1 с небольшими дробными частями (сотыми и десятymi). Поэтому уровень значений ошибок получается довольно низким, но при этом коэффициент детерминации дает не столь высокое значение. Глубокая регрессионная сверточная нейросетевая модель показала худшие значения ошибки и коэффициента детерминации: (0.0307, 0.5023). В случае полносвязной регрессионной нейросетевой модели произошло полное вырождение прогнозных показателей в нулевые значения, поэтому показатели качества у нее наихудшие и неприемлемые для второго набора данных: (1.0468, -576.4434).

Таким образом, сравнение разработанных гибридных глубоких нейросетевых регрессионных моделей показывает преимущество предложенных моделей по сравнению с полносвязными нейронными сетями прямого распространения и глубокими нейронными сверточными сетями. Сравнение с результатами, полученными для нейросетевых моделей и данных временных рядов финансово-экономической направленности, также показывает преимущество разработанных гибридных глубоких нейросетевых регрессионных моделей [3–5].

### Библиографический список

1. *Fadlalla A., Chien-Hua L.* An analysis of the applications of neural networks in finance // *Interfaces*. 2001. Vol. 31, № 4. P. 112–122.
2. *Heaton J. B., Polson N. G., Witte J. H.* Deep learning for finance: deep portfolios // *Applied Stochastic Models in Business and Industry*. 2016. Vol. 33, № 1. P. 3–12.
3. Forecasting the financial insolvency of enterprises / A. V. Kolyshkin, E. V. Gilenko, S. E. Dovzhenko [et al.] // *St. Petersburg University Journal of Economic Studies*. 2014. Vol. 2. P. 122–142.
4. *Mele M., Magazzino C.* A Machine Learning analysis of the relationship among iron and steel industries, air pollution, and economic growth in China // *Journal of Cleaner Production*. 2020. Vol. 277.

5. Predicting Volatility Index According to Technical Index and Economic Indicators on the Basis of Deep Learning Algorithm / S. M. Daniali, S. E. Barykin, I. V. Kapustina [et al.] // Sustainability. 2021. Vol. 13. P. 14011.
6. Официальная статистика // Росстат. URL: <https://rosstat.gov.ru/folder/10705> (дата обращения: 15.08.2024).
7. Aurélien G. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. 2<sup>nd</sup> ed. Sebastopol, CA: O'Reilly Media, Inc., 2019. 1065 p.
8. *Chen H., Zhijie Z.* Hybrid neural network based on novel audio feature for vehicle type identification // 2020 IEEE International Instrumentation and Measurement Technology Conference (I2MTC): proceedings of the international conference (25–28 May 2020). 2021.
9. *Скобцов В. Ю., Соколов Б. В.* Гибридные нейросетевые модели в задаче мультиклассовой классификации данных телеметрической информации малых космических аппаратов // Вестник ВГУ. Системный анализ и информационные технологии. 2022. № 3, С. 99–114.



*В. В. Совков\**

студент

*М. Б. Сергеев\**

доктор технических наук, профессор

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## О НЕЙРОСЕТЕВОМ УПРАВЛЕНИИ ПЕРЕДВИЖЕНИЕМ ПЕРСОНАЖЕЙ В UNITY КАК СПОСОБЕ ПРОЕКТИРОВАНИЯ РОБОТОТЕХНИЧЕСКИХ СИСТЕМ

Рассматривается способ проектирования и отладки объектов мобильной робототехники, способных самостоятельно находить путь в лабиринте, через создание трехмерного виртуального прототипа, содержащего лабиринт и микромышь, способную самостоятельно отслеживать свое положение и обнаруживать препятствия в виде стен.

**Ключевые слова:** мобильная робототехника, алгоритм поиска в ширину, нейросетевое управление.

*V. V. Sovkov\**

Student

*M. B. Sergeev\**

Dr. Sc., Tech., Professor

\*St. Petersburg State University of Aerospace Instrumentation

## ABOUT THE NEURAL NETWORK MOVEMENT CONTROL IN UNITY AS A WAY OF DESIGNING ROBOTIC SYSTEMS

The paper considers the way of designing and debugging objects of mobile robotics, capable of finding their way in a maze, through the creation of a three-dimensional virtual prototype containing a labyrinth and micromouse, Able to self-monitor their position and detect obstacles in the form of walls.

**Keywords:** mobile robotics, wide search algorithm, neural network management.

### Введение

Разработка методов и средств создания персонажей, способных решать задачу поиска пути в окружении, является актуальной задачей в области современной мобильной робототехники. Например, решение подобной задачи лежит в основе конкурса микромышинных бегов MicroMouse, популярного сегодня во многих странах мира [1]. Указанный конкурс проводится с 70-х гг. XX. Его суть заключается в создании участниками миниатюрных роботов-мышей, способных находить путь к центру лабиринта заданного размера и соревнующихся между собой в скорости его прохождения.

Микромыши – это полностью автономные роботы, которые должны без посторонней помощи максимально быстро добраться из начальной точки в центральную часть лабиринта. Мышь должна отслеживать свое местоположение, обнаруживать препятствия во время исследования, составлять карту лабиринта, принимать решение по выбору пути и обнаруживать факт достижения цели. Однако с 1980-х гг. в правила было внесено существенное изменение – микромышь должна понять, что она достигла центра лабиринта [2; 3].

Цель настоящей работы – создание в Unity трехмерного прототипа, содержащего лабиринт и микромышь, способную самостоятельно находить в нем путь, отслеживая свое положение и обнаруживая препятствия в виде стен. Иными словами, в статье рассматривается одна из наиболее важных областей робототехники – «интеллект роботов» [4; 5].

### Проведение исследований

Для создания виртуальных микромышь и ее окружения был использован игровой движок Unity, редактор которого предоставляет среду для разработки двух- и трехмерных приложений, а также обширный набор стандартных примитивов, компонентов и модулей и доступ к магазину ассетов [6]. Для построения пути используется алгоритм поиска пути в ширину, а перемещение между точками пути производится за счет управления вращением колес мыши при помощи обученной нейросети.

Игровые объекты в Unity состояются из наборов компонентов, отвечающих за их различные свойства, такие как положение в пространстве, отображаемая модель, физические характеристики, скрипт с классом, описывающим его логику, а также иерархии дочерних объектов. На рис. 1 изображен объект «микромышь», созданный в процессе работы.

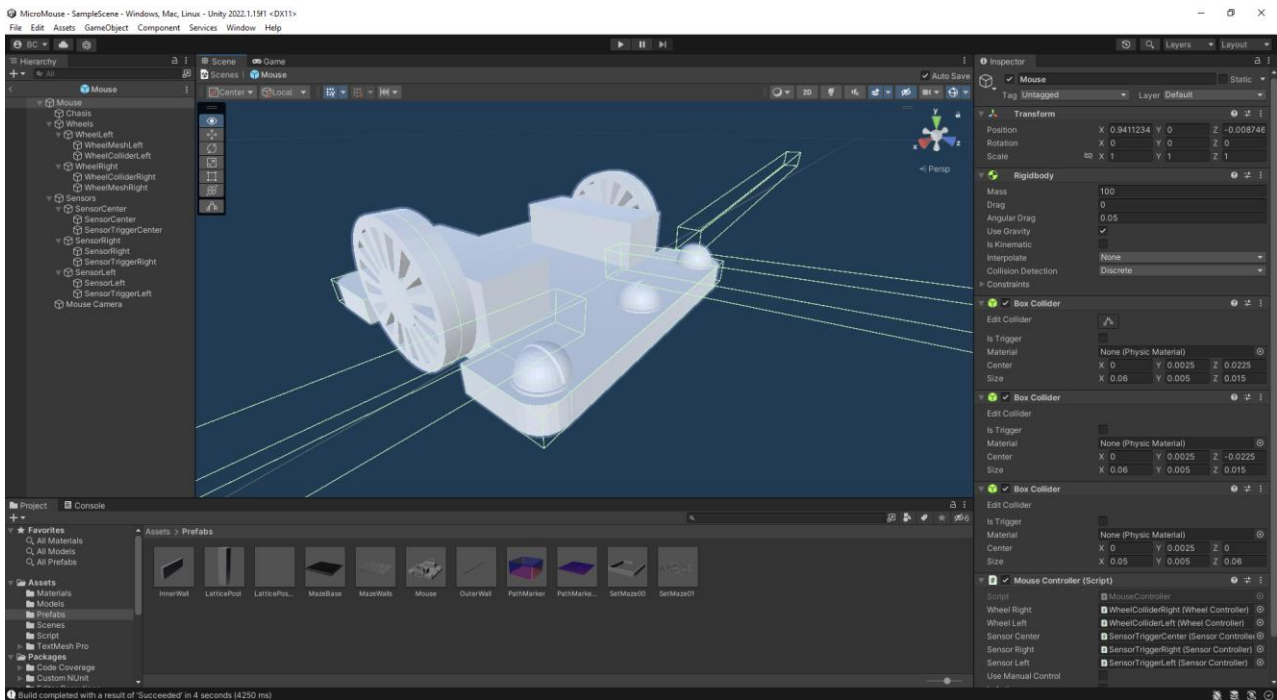


Рис. 1. Объект микромышь в окне редактора Unity

Для поиска пути мышь использует вариацию алгоритма поиска в ширину [7; 8]. Идея данного алгоритма заключается в посещении кратчайшим путем из указанной точки всех точек карты с учетом обнаруженных стен и записью прошлой посещенной точки. Схема алгоритма приведена на рис. 2. Логика поведения самой микромышь заключается в перемещении по квадратам лабиринта по построенному пути с обнаружением стен при помощи датчиков и при необходимости перестроением пути.

Для работы с нейросетью был создан класс, содержащий нейроны входного, скрытых и выходного слоя, матрицы весов, нейроны смещения и оценку пригодности. Метод расчета значений слоев принимает на вход значения входного слоя, после чего производит расчет значений последующих слоев путем матричного умножения значений прошлого слоя на соответствующую матрицу весов и сложения со значением соответствующего нейрона смещения.

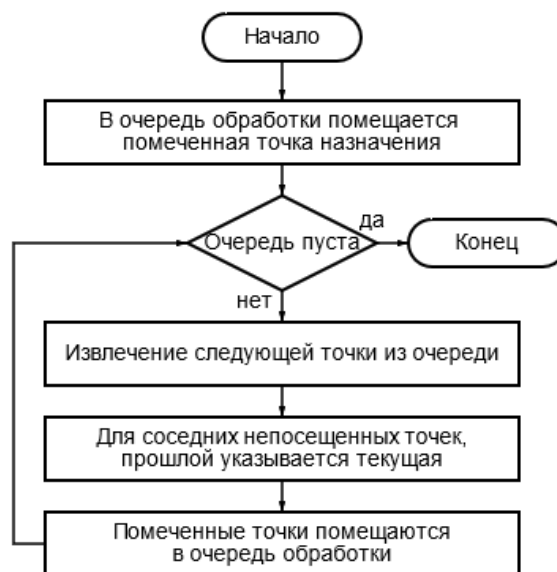


Рис. 2. Схема алгоритма поиска пути

К значениям входного и выходного слоя применяется функция гиперболического тангенса:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}},$$

что необходимо для нормализации значений.

Метод перемещения при помощи сети передает экземпляру нейросети три значения:

- расстояние до центра следующего квадрата пути;
- угол между поворотом мыши и центром квадрата назначения, принимающий значения  $[-180, 0]$  при необходимости поворота по часовой стрелке и  $[0, 180]$  при необходимости поворота против часовой;
- текущую скорость мыши.

На выходе нейросети получаются два значения, используемые как множители скорости вращения правого и левого колес.

На рис. 3 изображена схема нейросети, подходящей для применения мышью и обладающая двумя скрытыми слоями по девять нейронов.

Для обучения сети был применен метод нейрорезволюции [9]. Используемый вариант метода заключается в создании популяции нейросетей со случайными значениями весов и нейронов смещения, после чего производятся оценка пригодности каждой из сетей по каким-либо критериям и отбор наиболее пригодных сетей. Составляется следующее поколение сетей из отобранных, их потомков, мутаций и набора сетей со случайными значениями, после чего действия повторяются для новых поколений, пока не будет получена сеть удовлетворяющей пригодности.




Рис. 3. Схема нейросети управления мышью

При скрещивании используется только указанное число наиболее пригодных сетей и при формировании указанного числа потомков производится обмен полными матрицами весов и отдельными нейронами смещения. Мутации происходят с указанным шансом мутации и либо с нейроном смещения, либо с частью значений какой-либо матрицы весов, присваивая им новые случайные значения. Размер популяций остается постоянным.

Оценка пригодности производится при каждом обращении к сети и рассчитывается по формуле

$$F = F + \begin{cases} 5, & |\alpha| < 5 \\ 0, & |\alpha| \geq 5 \end{cases} + \begin{cases} 0, & \Delta d < 0 \\ 5, & \Delta d \geq 0 \\ 0, & |\alpha| \geq 5 \end{cases}, \quad |\alpha| < 5 + T \cdot \begin{cases} 0, & T \leq 1 \\ 10, & T > 1 \end{cases}$$

поощряющей нахождение направления мыши в пределах пяти градусов от направления цели, уменьшение расстояния до цели при нахождении направления в пределах и количество достигнутых целей. Здесь  $F$  – пригодность, изначально равная нулю;  $a$  – направление цели;  $\Delta d$  – изменение расстояния до цели с последнего обращения;  $T$  – количество достигнутых целей.

В результате проб обучения нейросети была составлена формула, используемая при обучении. При обучении с шансом мутации 5,5% и структурой слоев, изображенной на рис. 3, была получена сеть тринадцатого поколения, обладающая пригодностью 454 280 и способная успешно управлять мышью.

Скриншот виртуальной системы «микромшь – лабиринт» представлен на рис. 4, где отображена часть маршрута, проделанного мышью, управляемой обученной нейросетью.




Рис. 4. Маршрут, проделанный микромышью

### Заключение

Итогом проделанной работы стал виртуальный прототип с лабиринтом и микромышью, управление которой производится при помощи алгоритма построения пути и нейросети, успешно обученной для управления ее передвижением. Очевидно, что результаты обучения нейросети могут быть улучшены путем составления другой функции оценки пригодности, изменением структуры скрытых слоев сети, изменением правил формирования популяций новых поколений, формирования потомков и мутаций.

Прототипирование систем в виртуальном пространстве позволяет без больших вложений проверить технические решения по созданию интеллектуальных роботов перед их реализацией, что подчеркивает актуальность и перспективность подобных работ.

### Библиографический список

1. MicroMouse Competition Rules. URL: [https://attend.ieee.org/r2sac-2020/wp-content/uploads/sites/175/2020/01/MicroMouse\\_Rules\\_2020.pdf](https://attend.ieee.org/r2sac-2020/wp-content/uploads/sites/175/2020/01/MicroMouse_Rules_2020.pdf) (дата обращения: 07.01.2024).
2. Micromouse – а ваша робомышь пройдет лабиринт? URL: <https://habr.com/ru/companies/cloud4y/articles/738262/> (дата обращения: 07.01.2024).
3. Jabuti project: maze solver micromouse robot / A. L. C. Maciel, M. E. B. Gonçalves, V. Y. M. Basañez, J. V. S. Mendes // Journal of Bioengineering, Technologies and Health. 2023. Vol. 5, № 4. P. 272–278.
4. Swati M., Bande P. Maze Solving Algorithms for Micro Mouse // 2008 IEEE International Conference on Signal Image Technology and Internet Based Systems. 2008. С. 86 – 93.
5. Сергеев А. М. Основы искусственного интеллекта: учеб. пособие. СПб.: ГУАП, 2024. 75 с.
6. UNITY Real-Time Development Platform. URL: [unity.com](https://unity.com) (дата обращения: 07.01.2024).
7. Разработка модуля предобработки изображений методом поиска в ширину для системы распознавания образов на основе мультиагентной нейрокогнитивной архитектуры / А. З. Энес, М. В. Хажметов, К. Ч. Бжихатлов, С. А. Канкулов // Вестник Новосибирского государственного университета. Серия: Информационные технологии. 2023. Т. 21, № 4. С. 46–53.
8. Рафгарден Т. Совершенный алгоритм. Графовые алгоритмы и структуры данных. СПб.: Питер, 2023. 256 с.
9. Березина В. А., Мезенцева О. С., Ганьшин К. Ю. Гибридная нейроэволюция как способ обучения нейронных сетей на примере решения задачи поиска пути в лабиринте // Моделирование, оптимизация и информационные технологии. 2021. Т. 9, № 3(34).

*Т. М. Татарникова\**

доктор технических наук, профессор

*А. С. Раскопина\**

инженер

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## СОВРЕМЕННЫЕ ПОДХОДЫ К РАЗРАБОТКЕ ЛЕКАРСТВ С ПРИМЕНЕНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Современная фармацевтическая индустрия сталкивается с множеством вызовов, связанных с разработкой новых лекарственных препаратов. Основными проблемами являются высокий уровень затрат, значительные временные рамки исследований и клинических испытаний, а также сложности в предсказании эффективности и безопасности препаратов. Рассматриваются современные подходы к разработке лекарственных препаратов с использованием искусственного интеллекта (ИИ). Также изучается использование ИИ в доклинических и клинических исследованиях, что способствует более эффективному и безопасному созданию новых терапий.

**Ключевые слова:** искусственный интеллект, разработка лекарств, машинное обучение, фармацевтическая индустрия, клинические исследования, персонализированная медицина.

*T. M. Tatarnikova\**

Dr. Sc., Tech., Professor

*A. S. Raskopina\**

Engineer

\*St. Petersburg State University of Aerospace Instrumentation

## MODERN APPROACHES TO DRUG DEVELOPMENT USING ARTIFICIAL INTELLIGENCE

The modern pharmaceutical industry faces many challenges associated with the development of new drugs. The main problems are high costs, significant time frames for research and clinical trials, as well as difficulties in predicting the effectiveness and safety of drugs. The article discusses modern approaches to drug development using artificial intelligence (AI). It also discusses the use of AI in preclinical and clinical studies, which contributes to a more efficient and safe creation of new therapies. The introduction of AI in the pharmaceutical industry opens up new opportunities, although it requires overcoming certain challenges.

**Keywords:** artificial intelligence, drug development, machine learning, pharmaceutical industry, clinical trials, personalized medicine.

### Введение

Фармацевтическая отрасль сегодня сталкивается с множеством вызовов в процессе разработки новых лекарственных препаратов. Среди них выделяются высокие финансовые затраты, значительные временные рамки, необходимые для проведения исследований и клинических испытаний, а также сложности, связанные с предсказанием эффективности и безопасности новых препаратов. В этой ситуации искусственный интеллект (ИИ) становится важным инструментом, который может значительно сократить время и стоимость разработки лекарств, а также повысить точность прогнозов относительно их терапевтической эффективности. В данной статье рассмотрены современные подходы к разработке лекарств с использованием ИИ, а также представлены основные направления и примеры успешного применения ИИ в данной сфере.

### Машинное обучение в поиске новых лекарственных соединений

Одно из перспективных направлений в разработке лекарственных средств – применение методов машинного обучения (ML) для поиска и выявления новых молекул, которые могут обладать терапевтическим потенциалом. Например, глубокое обучение, использующее нейронные сети, позволяет анализировать огромные объемы данных, включающие химические свойства молекул и их биологическую активность. Это позволяет моделям ИИ предсказывать, какие соединения могут стать потенциальными кандидатами для дальнейшего изучения в качестве лекарственных средств. Такой подход ускоряет процесс поиска и снижает вероятность включения в разработку неподходящих кандидатов на ранних этапах [1].

Примером успешного применения таких методов является проект по созданию новых антибиотиков, где с помощью ИИ были выявлены молекулы с уникальными механизмами действия, ранее не изученными учеными. Этот подход значительно ускорил процесс разработки и расширил возможности в борьбе с устойчивыми к антибиотикам инфекциями [2].

## Виртуальный скрининг и улучшение характеристик соединений

Виртуальный скрининг представляет собой процесс, при котором ИИ анализирует базы данных химических соединений и предсказывает их возможное взаимодействие с целевыми белками. Это позволяет сузить круг кандидатов для дальнейших лабораторных исследований, что экономит время и ресурсы. Совмещение виртуального скрининга с методами молекулярного моделирования позволяет не только прогнозировать взаимодействие молекул, но и оптимизировать их структуру с целью повышения биологической активности и снижения побочных эффектов. Например, ИИ был успешно применен для поиска ингибиторов протеина BACE-1, который является ключевым в развитии болезни Альцгеймера [3].

Кроме того, ИИ используется для анализа и оптимизации фармакокинетических и фармакодинамических характеристик соединений, что способствует созданию более эффективных и безопасных препаратов. Использование ИИ на этих этапах позволяет предсказать поведение молекул в организме человека, тем самым уменьшая риск неудачи на поздних стадиях разработки [4].

### ИИ в доклинических и клинических исследованиях

ИИ активно используется не только на стадии поиска и оптимизации молекул, но и на следующих этапах разработки лекарственных препаратов, таких как доклинические и клинические исследования. Например, алгоритмы ИИ анализируют геномные данные пациентов, что позволяет выявить биомаркеры для персонализированного лечения и предсказать, как пациенты будут реагировать на определенные препараты. Это особенно важно в онкологии, где персонализированная медицина набирает популярность. Внедрение ИИ на этих этапах позволяет сократить расходы на клинические испытания и повысить их результативность за счет более точного отбора участников и прогнозирования исходов лечения [5].

Также ИИ помогает автоматизировать обработку данных клинических исследований, что ускоряет процессы и снижает вероятность ошибок. К примеру, системы ИИ могут анализировать данные о побочных эффектах и эффективности препаратов в реальном времени, что позволяет быстрее принимать решения о продолжении или прекращении исследований [6].

### Примеры успешного использования ИИ в разработке лекарств

Одним из ярких примеров применения ИИ является разработка компанией Insilico Medicine нового соединения для лечения фиброза, которое было найдено и синтезировано всего за несколько месяцев, что значительно быстрее по сравнению с традиционными методами, где процесс может занимать годы. Применение ИИ позволило сократить не только время, но и затраты на разработку [7].

Еще один важный пример – сотрудничество компании Pfizer с IBM Watson, в рамках которого ИИ используется для ускорения разработки онкологических препаратов. ИИ анализирует огромные объемы данных о генетических и молекулярных особенностях опухолей, что позволяет подбирать более точные методы лечения для конкретных пациентов [8].

Крупные фармацевтические компании, такие как GlaxoSmithKline и Novartis, также активно инвестируют в ИИ-технологии, чтобы повысить эффективность своих исследовательских программ. Например, GlaxoSmithKline использует ИИ для поиска новых биологических мишеней, а Novartis – для оптимизации химических соединений. Эти компании добиваются значительных результатов, интегрируя ИИ с другими передовыми технологиями, такими как анализ больших данных и облачные вычисления [9; 10].

## Заключение

Применение искусственного интеллекта в разработке лекарственных препаратов открывает новые перспективы для фармацевтической индустрии. Современные подходы, включающие машинное обучение, виртуальный скрининг, молекулярное моделирование и анализ геномных данных, позволяют значительно ускорить процесс создания новых лекарств, снизить затраты и повысить точность прогнозов их эффективности. Примеры успешного применения ИИ демонстрируют его большой потенциал в ускорении разработки препаратов, повышении их эффективности и безопасности. Хотя существуют определенные вызовы и ограничения в использовании ИИ, его внедрение в фармацевтику набирает обороты и оказывает значительное влияние на развитие отрасли.

### Библиографический список

1. Ekins S. Exploring the Artificial Intelligence-driven Drug Discovery World // *Chemical Research in Toxicology*. 2019. Vol. 32, № 4. P. 846–858.
2. Zhavoronkov A. Deep Learning for Drug Discovery and Biomarker Development // *Trends in Pharmacological Sciences*. 2019. Vol. 40, № 2. P. 110–124.
3. Macalino S. J. Y. Role of Computer-Aided Drug Design in Modern Drug Discovery // *Archives of Pharmacal Research*. 2019. Vol. 42, № 1. P. 1–12.

4. *Tang Y.* The Role of Artificial Intelligence in Drug Discovery // *Chemical Biology & Drug Design*. 2020. Vol. 95, № 5. P. 583–591.
5. *Stokes J. M.* A Deep Learning Approach to Antibiotic Discovery // *Cell*. 2020. Vol. 180, № 4. P. 688–702.
6. *Shah P.* Artificial Intelligence and Machine Learning in Drug Discovery: A Comprehensive Review // *Molecular Informatics*. 2019. Vol. 38, № 1–2. P. 1800111.
7. *Zhavoronkov A.* Artificial Intelligence in Drug Discovery: A New Era in the Field // *Nature Biotechnology*. 2020. Vol. 38. P. 665–668.
8. *Gupta A.* Machine Learning Approaches in Drug Discovery: Methods and Applications // *Drug Discovery Today*. 2020. Vol. 25, № 4. P. 745–753.
9. *Baskin I. I.* AI in Medicinal Chemistry and Drug Design // *Drug Discovery Today*. 2019. Vol. 24, № 4. P. 1018–1026.
10. *Wu Z.* AI-driven Drug Discovery: Trends, Possibilities, and Challenges // *Journal of Chemical Information and Modeling*. 2020. Vol. 60, № 6. P. 2708–2724.

*А. А. Тафеева\**

студент

*М. Д. Поляк\**

старший преподаватель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ОПРЕДЕЛЕНИЕ ПОЛА ЧЕЛОВЕКА ПО ФОТОГРАФИИ ЧАСТИЧНО ЗАКРЫТОГО ЛИЦА

Исследуется влияние наличия очков на качество решения задачи определения пола человека по фотографии лица. При построении классификатора используется модель FaceNet, и производится ее дообучение методом transfer learning.

**Ключевые слова:** нейронная сеть, определение пола, очки, FaceNet, transfer learning.

*A. A. Tafeeva\**

Student

*M. D. Polyak\**

Senior Lecturer

\*St. Petersburg State University of Aerospace Instrumentation

## DETERMINING A PERSON'S GENDER FROM A PARTIALLY OBSCURED FACIAL PHOTOGRAPH

In this work the quality of the task of determining a person's gender from a facial photograph is analyzed based on the presence or absence of glasses on a person's face. FaceNet model is used in order to construct a classifier, and it is further trained using the transfer learning method.

**Keywords:** neural network, gender detection, glasses, FaceNet, transfer learning.

### Введение

Классификация фотографий лиц людей по различным признакам – актуальная задача, особенно в таких сферах, как социальные сети и бизнес. Она решается при помощи глубоких нейронных сетей [1–3].

В данной работе рассматривается частный случай задачи определения пола человека – определение пола по фотографии лица в очках. Существующие модели позволяют определить пол человека по фотографии лица без очков с высокой точностью, в частности модель VGGFace [4] достигает значения метрики assigasy в 97,4% [5]. Однако определение пола человека по фотографии лица в очках менее точно: использование указанной модели на наборе данных Faces dataset [6] показывает assigasy 86,6%. Нами предпринята попытка улучшить распознавание пола по фотографии лица в очках.

### Наборы данных

Для обучения был использован набор данных Male and female faces dataset [7], содержащий 2698 фотографий женщин и 2720 фотографий мужчин, в основном без очков. Набор был разделен на две части – обучающую и валидационную – в отношении 4 к 1. Для тестирования был использован набор Faces dataset (упомянутый ранее), содержащий 212 фотографий женщин и 100 фотографий мужчин, по большей части в очках.

Предварительно на фотографиях при помощи детектора MTCNN [8] определялось лицо, изображение обрезалось по полученной ограничительной рамке и приводилось к размеру 224×224 пикселя.

### Модель для классификации лиц

В качестве основы была взята модель FaceNet [9], предварительно обученная на наборе данных VGGFace2 [10]. Эта модель получает на вход изображение лица размером 224×224 пикселя, которое после прохождения сверточных слоев преобразуется в вектор из 512 чисел (эмбединг), содержащих информативные признаки изображения. FaceNet построена на архитектуре Inception-ResNet-v1 [11] и состоит из модулей – групп слоев свертки (convolutional), пулинга (pooling) и конкатенации (concat) – нескольких типов:

- Stem – оптимизирует входные данные;
- Inception-resnet A, B и C – применяет несколько операций свертки разной размерности и сливает их результаты; каждый модуль используется несколько раз;
- Reduction A и B – уменьшает размерность данных;
- модуль создания эмбедингов.

Эта модель была дообучена для распознавания пола при помощи transfer learning.



## Обучение классификатора

На первом этапе (feature extraction) к модели были добавлены два слоя: слой исключения (dropout) для предотвращения переобучения и слой классификации с одним нейроном с сигмоидой в качестве функции активации (рис. 1). Исходные слои модели были исключены из обучения («заморожены»), и сеть обучалась в течение 150 эпох. На втором этапе (fine tuning) последний блок слоев исходной модели был включен в обучение («разморожен»), и сеть обучалась еще 50 эпох. В качестве функции потерь на обоих этапах использовалась Binary Cross Entropy Loss [12], поскольку классификация бинарная («мужчина» и «женщина»).




Рис. 1. Схема классификатора

После обучения были получены следующие результаты на тестовой выборке: accuracy 0,987, precision 0,962, recall 1,000. На рис. 2 приведен график изменения значения ассигасу на обучающей выборке, на рис. 3 – график изменения значения функции потерь в процессе обучения.




Рис. 2. График изменения значения ассигасу на обучающей и валидационной выборках в процессе обучения сети




Рис. 3. График изменения значения функции потерь на обучающей и валидационной выборках в процессе обучения сети

Таблица содержит матрицу ошибок сети на тестовой выборке, а на рис. 3 показана нормализованная матрица ошибок.

### Матрица ошибок для тестовой выборки изображений

Истинный класс	Предсказанный класс	
	Мужчина	Женщина
Мужчина	100	0
Женщина	4	208




Рис. 3. Нормализованная матрица ошибок для тестовой выборки изображений

## Заключение

В ходе выполнения работы был построен классификатор, позволяющий с точностью 99% определить пол человека по фотографии лица в очках. Поскольку обучение проводилось на фотографиях лиц преимущественно без очков, а хорошие результаты распознавания пола достигнуты на фотографиях лиц в очках, можно сделать вывод, что наличие очков не оказывает существенного влияния на получаемые в результате работы сверточных слоев модели эмбединги.

## Библиографический список

1. *Levi G., Hassner T.* 2015. Age and gender classification using convolutional neural networks // Proceedings of the IEEE conference on computer vision and pattern recognition workshops. 2015. P. 34–42.
2. *Wu C. C., Zeng Y. C., Shih M. J.* Enhancing retailer marketing with an facial recognition integrated recommender system // IEEE ICCE-TW. 2015. P. 25–26.
3. *Zulkashev R., Polyak M.* Automatic analysis of face images for college degree verification // IEEE proceedings of ITNT 2023: The IXth International Conference on information technology and nanotechnology, Samara. 2023. P. 10139216.
4. *Parkhi O. M., Vedaldi A., Zisserman A.* Deep Face Recognition. URL: <https://www.robots.ox.ac.uk/~vgg/publications/2015/Parkhi15/parkhi15.pdf> (дата обращения: 02.08.2024).
5. *Serengil S. I.* Apparent Age and Gender Prediction in Keras. URL: <https://sefiks.com/2019/02/13/apparent-age-and-gender-prediction-in-keras/> (дата обращения: 02.08.2024).
6. *Поляк М. Д.* faces-dataset. URL: <https://github.com/markpolyak/faces-dataset> (дата обращения: 02.08.2024).
7. *Gupta A.* Male and female faces dataset. URL: <https://www.kaggle.com/datasets/ashwingupta3012/male-and-female-faces-dataset/code> (дата обращения: 02.08.2024).
8. Joint face detection and alignment using multitask cascaded convolutional networks / K. Zhang, Z. Zhang, Z. Li, Y. Qiao // IEEE Signal Processing Letters. 2016. 23(10). P. 1499–1503.
9. *Schroff F., Kalenichenko D., Philbin J.* FaceNet: A Unified Embedding for Face Recognition and Clustering. URL: <https://arxiv.org/pdf/1503.03832> (дата обращения: 02.08.2024).
10. *Sandberg D.* Face Recognition using Tensorflow. URL: <https://github.com/davidsandberg/facenet> (дата обращения: 02.08.2024).
11. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning / C. Szegedy, S. Ioffe, V. Vanhoucke, A. Alemi. URL: <https://arxiv.org/pdf/1602.07261> (дата обращения: 20.08.2024).
12. *Chollet F.* Deep Learning with Python. Manning, 2021. 504 p.

*Д. А. Токарев\**

магистрант

*А. В. Никитин\**

кандидат технических наук, доцент

*Н. Н. Решетникова\**

кандидат технических наук, доцент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ИНТЕЛЛЕКТУАЛИЗАЦИЯ НЕИГРОВЫХ ПЕРСОНАЖЕЙ В МЕТАВСЕЛЕННОЙ ГУАП

Рассмотрена задача перемещения неигрового персонажа в 3D-среде на основе машинного обучения с подкреплением.

**Ключевые слова:** метавселенная, неигровые персонажи, машинное обучение с подкреплением.

*D. A. Tokarev\**

Postgraduate Student

*A. V. Nikitin\**

PhD, Tech., Associate Professor

*N. N. Reshetnikova\**

PhD, Tech., Associate Professor

\*St. Petersburg State University of Aerospace Instrumentation

## INTELLIGENT NON-PLAYER CHARACTERS IN THE SUAI METAVERSE

The problem of moving a non-player character in a 3D environment is considered based on machine learning with reinforcement.

**Key words:** metaverse, non-player character, reinforcement learning

Для решения учебных и научно-исследовательских задач в ГУАП разработана метавселенная, представляющая собой интерактивную 3D-цифровую среду, в которой географически распределенные пользователи могут взаимодействовать в реальном времени друг с другом и с цифровыми объектами через своих аватаров (персонажей) [1]. Аватары представляют пользователей, а также могут быть неигровыми (NPC – Non-Player Character), которые не контролируются игроками напрямую.

Перемещение NPC в метавселенной является важной задачей и характеризуется последовательным принятием решений аватаром (на каждом шаге своего пути), динамической средой (аватар должен адаптироваться к постоянным изменениям среды), наличием награды (цель аватара – безопасно добраться до цели, что легко формализовать в виде награды). Как правило, традиционные NPC с предопределенным поведением статичны и не могут адаптироваться к изменяющимся условиям среды. Решение данной задачи возможно за счет интеллектуализация NPC на основе обучения с подкреплением, что позволит создавать более реалистичных (внешний вид, вербальное и невербальное поведение) и адаптивных (навигация, поведение) персонажей, способных принимать решения, основанные на текущем состоянии среды и полученных наградах [2–4].

Основой метавселенной ГУАП является интерактивная 3D-модель зданий ГУАП и прилегающей территории, одной из задач которой является обучение NPC поведению в городской среде. Метавселенная ГУАП реализована на движке Unity, который облегчает разработчикам исследование возможностей машинного обучения в играх с помощью своего инструментария Unity ML-Agent, представляющего различные алгоритмы машинного обучения вместе с примерами и удобную для пользователя среду разработки [2; 3; 5].

Цель исследования – оценить, насколько успешно агент может научиться перемещаться в городской среде, избегая столкновений с препятствиями и правильно взаимодействуя с элементами инфраструктуры (например, пешеходными переходами), с помощью существующих инструментов, таких как Unity ML-Agents и алгоритмов обучения с подкреплением, без дополнительной оптимизации или разработки новых методов.

Для решения задачи используется алгоритм обучения с подкреплением Soft Actor-Critic (SAC) из библиотеки python PyTorch [6]. Этот метод основан на стохастической политике агента, что позволяет исследовать различные стратегии и находить наиболее эффективные решения. В алгоритме SAC и актер, и критик представлены нейронными сетями. Актер, исходя из текущего состояния, среды оптимизирует политику  $\pi(a | s)$ , учитывая энтропию для сохранения разнообразия действий. В это время нейронная сеть критика используется для оценки действия  $Q(s, a)$ . Обновление параметров осуществляется с помощью градиентного спуска.

Для реализации задачи используются следующие компоненты: Unity ML-Agents – фреймворк для обучения агентов с использованием обучения с подкреплением; Ray Perception Sensor 3D – сенсор для восприятия окружающей среды; скрипты на C# – для управления поведением агента и взаимодействия с окружающей средой;

Python – для запуска процесса обучения с помощью ML-Agents; TensorBoard – для визуализации процесса обучения агента.

Этапы обучения.

1. Подготовка среды: установка объектов и сенсоров в Unity.
2. Настройка агента: определение поведения агента через скрипты.
3. Запуск эпизодов: агент начинает каждый эпизод с новой позиции и обучается взаимодействовать со средой.
4. Сбор наблюдений: агент фиксирует объекты и их расстояние с помощью Ray Perception Sensor 3D.
5. Выбор действий: модель принимает решения на основе текущих наблюдений.
6. Получение вознаграждения: агент получает награды или штрафы в зависимости от своих действий.
7. Обновление политики: модель обучается на основе полученных вознаграждений и обновляет свою политику.

Обучение агента разбито на несколько итераций, каждая из которых представляет собой отдельную сцену (рис. 1). Первая сцена обучает агента избегать столкновений, вторая – перемещаться по тротуару, не выходя на проезжую часть, третья – правильно переходить через пешеходные переходы.




Рис. 1. Среда обучения агента

Процесс обучения агента можно разбить на следующие составляющие.

Состояние агента определяется наблюдениями, полученными с помощью Ray Perception Sensor 3D. В любой момент времени состояние описывается набором переменных: текущая позиция агента в трехмерном пространстве ( $p = (x, y, z)$ ), скорость ( $v = (vx, vy, vz)$ ), направление движения ( $d = (dx, dy, dz)$ ) и состояние ожидания на пешеходном переходе ( $w$ ) ( $w$ ). Состояние представляется в виде вектора ( $S_t = (p_t, v_t, d_t, w_t)$ ).

Агент выбирает действия, которые описываются вектором скорости вдоль осей X и Z:  $A_t = (a_x, a_z)$ , где  $a_x$  и  $a_z$  задают направление и величину перемещения.

Функция вознаграждения зависит от взаимодействия агента со средой:

- $R_t = 1$  при успешном переходе через пешеходный переход;
- $R_t = -1$  при столкновении с препятствием;
- $R_t = -0,01$  за каждую единицу времени ожидания на пешеходном переходе.

Переходы состояния описываются уравнением ( $S_{t+1} = f(S_t, A_t)$ ), где  $f(S_t, A_t)$  учитывает физику движения агента и воздействие окружающей среды. Например, новое положение агента рассчитывается как  $p_{t+1} = p_t + d_t \Delta t$ , а направление движения обновляется на основе выбранного действия:  $d_{t+1} = \text{Normalize}(A_t)$ . Эпизод завершается, если агент сталкивается с препятствием или успешно завершает переход через пешеходный переход.

Для визуализации работы агентов был использован инструмент Tensor Board. Анализ полученных графиков приведен далее.

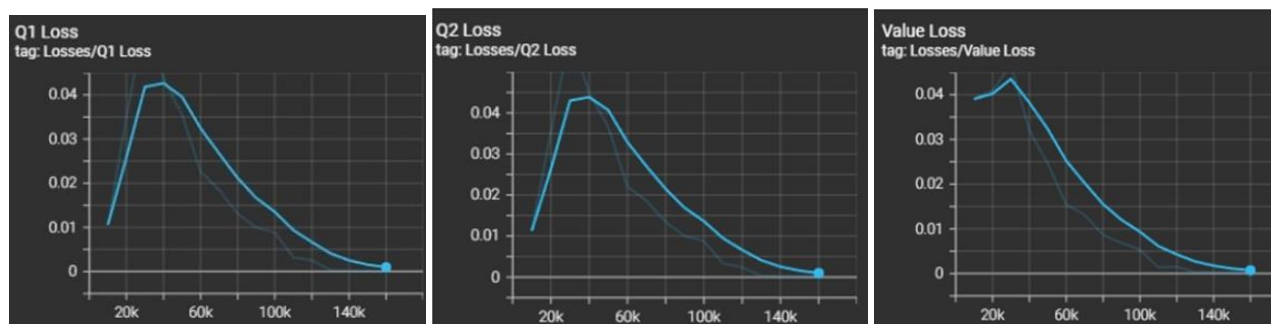


Рис. 2. Визуализация полученных графиков в Tensor Board: а – график потери критиков Q1, б – график потери критиков Q2, в – график потери функции ценности

На рис. 2, а, б показаны графики потери критиков Q1 и Q2 (Q1 Loss и Q2 Loss). Обе метрики Q1 Loss и Q2 Loss демонстрируют схожий тренд: начальное увеличение потерь, за которым следует устойчивое снижение. Это поведение характерно для функции потерь критика в алгоритмах обучения с подкреплением, когда модель сначала испытывает сложности с оценкой состояния, но со временем учится это делать более точно. Поскольку Q-значения напрямую связаны с оценкой качества действий в конкретных состояниях, уменьшение этих потерь свидетельствует о том, что модель улучшает свою способность оценивать действия.

Потери функции ценности (Value Loss) (рис. 2, в) аналогично Q-метрикам сначала увеличиваются, а затем начинают снижаться, достигая минимальных значений. Это говорит о том, что модель постепенно обучается точно оценивать будущие вознаграждения.

На данном этапе исследования агент успешно освоил базовое перемещение в статичной городской среде, избегая столкновений с препятствиями. Это подтверждает возможность создания работоспособного поведения NPC с использованием существующих инструментов, таких как Unity ML-Agents и алгоритм Soft Actor-Critic (SAC), даже без дополнительной оптимизации или разработки новых методов.

Однако важно отметить, что на текущем этапе агент еще не обучен взаимодействовать с динамическими элементами, такими как пешеходные переходы. Это ограничивает его функциональность в более сложных сценариях, требующих учета переменных условий и правил городской инфраструктуры.

В следующей фазе исследования планируется добавить в обучение агента задачи, связанные с переходом через пешеходные переходы и другими динамическими элементами городской среды. Это позволит проверить, насколько успешно существующие инструменты могут быть применены для создания более сложного и адаптивного поведения NPC в условиях, приближенных к реальным. Дальнейшее развитие проекта может включать расширение функциональности агента, что откроет новые возможности для создания универсальных и гибких решений в игровой индустрии.

### Библиографический список

1. Метавселенная ГУАП. URL: <https://guap.ru/n/labvr> (дата обращения: 31.08.2024).
2. How Machine Learning is Powering Intelligent NPCs. URL: <https://www.nftparis.xyz/blog/how-machine-learning-is-powering-intelligent-npcs> (дата обращения: 31.08.2024).
3. *Ransom Duncan*. Using Reinforcement Learning to Train In-game Non-Player Characters. URL: [https://loop.cs.mtu.edu/wp-content/uploads/2024/04/Infinite\\_Loop\\_v1\\_Duncan\\_2024\\_Using\\_ReinforcementLearning\\_to\\_Train\\_In\\_game\\_Non\\_Player\\_Characters.pdf](https://loop.cs.mtu.edu/wp-content/uploads/2024/04/Infinite_Loop_v1_Duncan_2024_Using_ReinforcementLearning_to_Train_In_game_Non_Player_Characters.pdf) (дата обращения: 31.08.2024).
4. *Dyon Kreffer*. Reinforcement learning for non-player characters in the video game industry. URL: [https://www.researchgate.net/publication/361452041\\_Reinforcement\\_learning\\_for\\_non-player\\_characters\\_in\\_the\\_video\\_game\\_industry](https://www.researchgate.net/publication/361452041_Reinforcement_learning_for_non-player_characters_in_the_video_game_industry) (дата обращения: 31.08.2024).
5. *Abhilash Majumder*. Deep Reinforcement Learning in Unity: With Unity ML Toolkit. Apress, 2021. 564 p.
6. Soft Actor-Critic (SAC). URL: <https://tensoraerospace.readthedocs.io/en/latest/agent/sac.html> (дата обращения: 31.08.2024).

**В. А. Ушаков**

кандидат технических наук

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ПОСТРОЕНИЕ ОБЛАСТЕЙ ДОСТИЖИМОСТИ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Рассмотрены существующие решения (программное обеспечение) для построения и аппроксимации областей достижимости, в том числе с использованием методов машинного обучения.

**Ключевые слова:** область достижимости; построение областей достижимости; аппроксимация областей достижимости; машинное обучение.

**V. A. Ushakov**

PhD, Tech.

St. Petersburg State University of Aerospace Instrumentation

## BUILDING AREAS OF REACHABILITY USING MACHINE LEARNING METHODS

The existing solutions (software) for building and approximating areas of reachability, including using machine learning methods, are considered.

**Keywords:** reachability area; building reachability areas; approximation of reachability areas; machine learning.

### Введение

На практике при решении задач оптимального управления сложными техническими объектами (СТО) [1], имеющими иерархически-сетевую структуру, возникают существенные трудности, вызванные большой размерностью указанных задач, сложным характером ограничений на процесс управления, существенной нелинейностью математических моделей, описывающих функционирование реальных динамических систем. В этих условиях особую актуальность приобретает задача повышения оперативности и обоснованности принятия управленческих решений, связанных с конфигурированием (реконфигурированием) структур автоматизированных систем управления (АСУ) подвижными объектами (ПДО), основанных на построении и аппроксимации множеств достижимости логико-динамических моделей указанных автоматизированных систем, описывающих данную предметную область в динамически изменяющихся условиях. Но для решения данной задачи в первую очередь необходимо выполнить построение области достижимости (ОД) АСУ ПДО.

Знание ОД дает максимальную информацию о возможностях рассматриваемой автоматизированной системы. Например, на основе ОД можно оценить, с одной стороны, пропускные способности АСУ ПДО (интегральную, дифференциальную пропускную способность), с другой – маневренные возможности ПДО, выбрать оптимальную программу управления, формировать оптимальное управление при наведении ПДО и т. д.

В современной теории управления существует множество задач, в ходе решения которых возникает потребность в построении и анализе ОД управляемой системы [2]. По существу, методы построения ОД можно разделить на два подхода. Первый заключается в построении точных ОД, охватывающих только те состояния динамической системы, в которые она может быть переведена за конечный промежуток времени. Второй подход подразумевает построение некоторой аппроксимации ОД [3], например, с помощью эллипсоидов [2]. Аппроксимационным методам в настоящее время уделяется большое внимание [2; 3], поскольку они позволяют значительно сократить вычислительные затраты. Однако аппроксимационные методы дают лишь приближенное представление о ОД, которое в некоторых случаях является весьма грубым.

### Обзор «классических» решений (программного обеспечения) для построения и аппроксимации областей достижимости

В 2018 г. [4] был проведен обзор существующих решений (программного обеспечения) для построения ОД [5–10]. В [5] предложен численный алгоритм для построения ОД нелинейной системы с импульсным управлением. В [6] рассматриваются задача приближенного построения ОД динамической системы и численные методы решения этой задачи на кластерных вычислительных системах, графических процессорных устройствах и нейросетевых ускорителях. В указанной работе приведен пример построения ОД ПДО в графическом процессорном устройстве NVIDIA GeForce 9600 GT. В качестве среды разработки была выбрана Microsoft Visual Studio 2008 и технология OpenCL. В [7; 8] рассматривается построение ОД линейных дискретных динамических систем на основе модифицированного общего рекуррентного алгебраического метода. В указанных работах приведены примеры моделирования ОД системы в программном пакете Matlab 8.4 (R2014b). В [9] рассматривается задача сравнения ОД непрерывной нелинейной и линеаризованной дискретной управляемых динамических систем. В качестве объекта управления используется модель ПДО, движение которого описывается системой нелинейных

динамических уравнений. В указанной работе приведен пример моделирования алгоритма аппроксимации ОД нелинейной модели ПДО в программной среде Matlab R2014a. В [10] рассматривается линейная стационарная система третьего порядка с одним управляющим (возмущающим) воздействием, ограниченным по абсолютной величине. В качестве объекта управления используется модель ПДО, движение которого описывается системой нелинейных динамических уравнений.

Однако с тех пор многое изменилось: появились новые решения, а самое главное – появились и вошли в широкое применение новые технологии, в частности искусственный интеллект.

### **Обзор возможных путей применения методов искусственного интеллекта в задачах построения и аппроксимации областей достижимости**

Значительный рост количества действительных и доступных наборов данных зданий вызывает большой интерес к использованию методов искусственного интеллекта (ИИ), особенно машинного обучения в различных предметных областях. Более того, для проведения успешных проектов необходимо изучать и внедрять новые технологии в области управления подвижными объектами [11]. Наиболее применяемыми методами машинного обучения (Machine learning, ML) для построения и аппроксимации областей достижимости являются искусственная нейронная сеть (ИНС), машина опорных векторов (SVM), гауссовское распределение регрессия и кластеризация.

Машинное обучение обычно используется для описания компьютерного алгоритма, который обучается на существующих данных. Эти алгоритмы чаще всего используют значительный объем данных и относительно небольшое количество входных характеристик для процесса обучения. В последние годы было предложено множество методов ML. Модели машинного обучения работают как «черный ящик» и не нуждаются в информации о конкретной системе. Они обнаруживают связь между различными входными характеристиками и выходными целевыми показателями (например, АСУ ПДО) с использованием заданных данных. Когда модели машинного обучения обучаются с достаточным объемом данных, их можно использовать для прогнозирования целей для невидимых образцов, хотя соотношение между характеристиками и целями не определено. Эта процедура также известна как контролируемое обучение в области ML.

Второй метод машинного обучения, а именно неконтролируемое обучение, получил значительное внимание в анализе показателей качества АСУ ПДО. Неконтролируемое обучение, также известное как неконтролируемая классификация, в основном применяется к немаркированным данным для их кластеризации на основе скрытых шаблонов и сходств, лежащих в основе признаков. Следовательно, алгоритмы кластеризации предоставляют более точные инструменты для группировки различных показателей по сравнению с традиционным методом.

Три основных метода, которые широко используются в строительном секторе для контролируемого обучения, – это модели ANN, SVM и регрессии гауссовского распределения. Методы К-средних и иерархической кластеризации также используются для целей неконтролируемого обучения.

### **Заключение**

Рассмотрены существующие подходы к решению задач построения и аппроксимации ОД СТО [12–15] (в том числе и АСУ ПДО), а также применение технологий искусственного интеллекта для решения указанных задач.

### **Библиографический список**

1. *Охтилев М. Ю., Соколов Б. В., Юсупов Р. М.* Интеллектуальные технологии мониторинга и управления структурной динамикой сложных технических объектов. М.: Наука, 2006. 410 с.
2. *Черноусько Ф. Л.* Оценивание фазового состояния динамических систем. Метод эллипсоидов. М.: Наука, 1988. 320 с.
3. *Потрясаев С. А.* Динамическая модель и алгоритмы комплексного планирования операций и распределения ресурсов в корпоративной информационной системе: дисс. ... канд. техн. наук. СПб., 2009. 159 с.
4. *Ушаков В. А.* Построение и аппроксимация областей достижимости: обзор существующих решений и выбор программного обеспечения // Региональная информатика и информационная безопасность. СПОИСУ. Вып. 6. 2018. С. 253–257.
5. *Вдовина О. И., Сесекин А. Н.* Численное построение областей достижимости для систем с импульсным управлением // Труды Института математики и механики УрО РАН. 2005. Т 11, №. 1, С. 65–73.
6. Система поддержки принятия решений при выборе параллельного аппаратно-программного комплекса для построения областей достижимости летательного аппарата / А. В. Быстров, А. П. Карпенко, О. Г. Козлова, В. А. Федин // Параллельные вычислительные технологии (ПАВТ'2011). М.: Издат. центр ЮУрГУ, 2011. С. 60–68.
7. *Булаев В. В., Осипов И. О.* Модифицированный алгоритм построения областей достижимости линейных дискретных динамических систем // Вестник ЮУрГУ. Серия: Компьютерные технологии, управление, радиоэлектроника. 2018. Т 18, № 1. С. 56–62.



8. Булаев В. В., Осипов И. О. Об одном модифицированном рекуррентном алгебраическом методе построения областей достижимости линейных дискретных динамических систем // Ракетно-космическая техника. 2017. Т 1, № 2(10). С. 4–15.
9. Горанов А. Ю., Шориков А. Ф. Анализ точности общего алгебраического метода построения областей достижимости линеаризованных динамических систем // Труды второй научно-технической конференции молодых ученых уральского энергетического института. Екатеринбург: УрФУ, 2017. С. 407–410.
10. Бугров Д. И., Формальский А. М. Зависимость от времени областей достижимости систем третьего порядка // Прикладная математика и механика. 2017. Т 81, № 2. С. 154–164.
11. Бугров Д. И. Предельная область достижимости линейной колебательной системы третьего порядка специального вида // Вестник Московского университета. Серия 1: Математика. Механика. 2023. № 5. С. 65–69.
12. Бугров Д. И. О траекториях на границе предельной области достижимости линейной управляемой системы третьего порядка // XIII Всероссийский Съезд по теоретической и прикладной механике: сб. тез. Докл. (СПб, 21–25 авг. 2023 г.). СПб: СПбПУ, 2023. С. 158–160.
13. Пацко В. С., Федотов А. А. Трехмерное множество достижимости для машины дубинса: сведение общего случая ограничений на повороты к каноническому // Известия Российской академии наук. Теория и системы управления. 2023. №4. С. 25–49.
14. Асеев А. С., Самсонов С. П. Построение множеств достижимости для одного класса негладких управляемых систем на плоскости // Вестник Московского университета. Серия 15: Вычислительная математика и кибернетика. 2024. № 2. С. 6–17.
15. Pour Rahimian F., Arciszewski T., Goulding J. S. Successful education for AEC professionals: case study of applying immersive gamelike virtual reality interfaces. Visualization in Engineering. 2014. Vol. 2(1), № 4. P. 1–12.

*А. П. Шабунин\**

аспирант

*В. В. Фомин\**

доктор технических наук, профессор

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ТЕМАТИЧЕСКАЯ КЛАССИФИКАЦИЯ НОВОСТНЫХ СТАТЕЙ ИЗ ИНТЕРНЕТА МЕТОДАМИ NLP

Представлены исследования по применению цифровых моделей на базе технологии обработки естественных языков BERT для тематической классификации новостных текстов на русском языке. Актуальность работы обусловлена необходимостью точного и эффективного анализа новостного контента в условиях растущих объемов данных. Цель исследования – оценка возможности применения модели BERT для улучшения тематического анализа текстов, что может расширить возможности SEO-анализа. Экспериментальные результаты продемонстрировали высокую эффективность модели в задачах классификации, особенно в областях с четкими тематическими границами. Обсуждаются особенности работы модели и предлагаются направления для дальнейших исследований, направленных на улучшение классификации и расширение ее применения.

**Ключевые слова:** анализ текста, машинное обучение, тематическая классификация, обработка естественного языка, SEO анализ, большие языковые модели, классификация новостных статей.

*A. P. Shabunin\**

Postgraduate Student

*V. V. Fomin\**

Dr. Sc. Tech., Professor

\*St. Petersburg State University of Aerospace Instrumentation

## TOPICAL CLASSIFICATION OF NEWS ARTICLES FROM THE INTERNET USING NLP METHODS

The article presents research on the application of digital models based on the BERT natural language processing technology for thematic classification of news texts in Russian. The relevance of the work is due to the need for accurate and effective analysis of news content in the context of growing data volumes. The purpose of the study is to assess the possibility of using the BERT model to improve thematic analysis of texts, which can expand the capabilities of SEO analysis. Experimental results have demonstrated the high efficiency of the model in classification tasks, especially in areas with clear thematic boundaries. Features of the model are discussed and directions for further research aimed at improving classification and expanding its application are proposed.

**Keywords:** text analysis, machine learning, topic classification, natural language processing, SEO analysis, large language models, news article classification

В последние годы объем данных в Интернете, особенно в новостных источниках, значительно возрос, что требует эффективных методов их анализа. Традиционно SEO-оптимизация фокусировалась на технических аспектах, таких как скорость загрузки сайта, для улучшения видимости контента. С развитием методов NLP [1] появились возможности решения задач анализа сайтов не только с точки зрения технического анализа, но и информационно-содержательной оценки контента, его тематики, структуры, смыслового влияния в когнитивном, эргономическом, психоэмоциональном аспектах [2]. Современные подходы на базе больших языковых моделей LLM (GPT, BERT, LaMDA, BigARTM и др.) демонстрируют значительный потенциал в области тестового анализа, тематической классификации, эмоционального окраса и т. д. [3].

Цель работы заключается в исследовании возможностей модели BERT для тематического анализа текстов с целью расширения традиционного подхода к SEO-оптимизации. Исследование сосредоточено на оценке текстового содержания не только с технической, но и с содержательной стороны, включая тематику, что закладывает основу для дальнейшего изучения эмоциональных и психологических аспектов контента.

Для достижения данной цели были поставлены следующие задачи:

- разработать и протестировать методику классификации новостных статей, использующую модель BERT для контекстуального анализа и BigARTM для тематического моделирования текстов;
- исследовать возможность расширения SEO-анализа с применением BERT, включая оценку текстовых характеристик, таких как ключевые слова и другие признаки, способствующие более точному определению тем;
- оценить эффективность предложенной методики на реальных новостных данных с акцентом на точность и качество тематической классификации.

Тематическая классификация новостных статей представляет собой сложную задачу из-за высокой динамичности и разнообразия контента. Новостные статьи охватывают широкий спектр тем и могут сочетать не-

сколько тем в рамках одного текста, что затрудняет автоматизацию классификации. Кроме того, статьи варьируются по стилю и структуре, от аналитических материалов до кратких заметок, что требует адаптации моделей под разные жанры.

Шум в данных, например нерелевантные ссылки или рекламные вставки, также усложняет обработку. Полисемия и специализированный жаргон добавляют сложности, так как одни и те же слова могут иметь разные значения в зависимости от контекста. Традиционные методы тематического моделирования, такие как Latent Dirichlet Allocation (LDA), могут не справляться с этими вызовами, особенно при работе с большими и разнообразными текстовыми корпусами [4].

Интеграция модели BERT с BigARTM предлагает значительное улучшение, благодаря способности BERT к глубокому контекстуальному анализу и гибкости BigARTM в построении тематических моделей [5]. Такой подход позволяет более точно выделять контекстуальные признаки и учитывать динамичные темы, что способствует более качественной тематической классификации [1].

В работе применен метод тематической классификации новостных статей на русском языке с использованием модели BERT (Bidirectional Encoder Representations from Transformers), что позволяет учитывать контекстные зависимости и повышает точность анализа текста. Модель BERT помогает извлекать высокоуровневые признаки из текстов, улучшая качество анализа за счет учета сложных семантических и синтаксических связей. Для решения задач классификации был разработан инструмент на базе библиотеки transformers.

Эксперимент. Для экспериментов использован датасет News Category Dataset (Kaggle), содержащий 1000 новостных статей, распределенных по 10 категориям (кластерам): спорт, политика, бизнес, космос, технологии, развлечения, медицина, еда, история, графика. Для каждой категории выбрано по 100 текстов (всего выборка 1000 тестов).

В ходе эксперимента была проведена тематическая классификация новостных статей на русском языке с использованием модели BERT (Bidirectional Encoder Representations from Transformers).

Процедура эксперимента.

1. Разделение данных. Выборка разделена на тренировочный и тестовый наборы: 80% данных (800 статей) использовались для обучения модели, 20% (200 статей) – для тестирования.

2. Обучение модели. Модель BERT была обучена на тренировочном наборе данных. Использовался класс Trainer из библиотеки transformers, который автоматизирует процесс настройки и обучения модели, включая оптимизацию гиперпараметров. Модель обучалась для задачи классификации, где каждый текстуальный пример должен был быть отнесен к одной из 10 категорий.

3. Оценка результатов. Оценка проводилась с использованием трех ключевых метрик: точность (Precision), полнота (Recall), F1-мера.

Полученные результаты (таблица), показали, что модель BERT достигла высоких значений точности, полноты и F1-меры по всем категориям. Средние значения этих метрик составили 0.98, что свидетельствует о высоком качестве классификации.

Точность (precision) модели для всех категорий, кроме одной, составила 1.0, что указывает на очень низкий уровень ложных срабатываний. Это означает, что модель крайне редко ошибается, присваивая текст неверной категории. Наиболее высокие значения точности были достигнуты в категориях «политика», «бизнес», «технологии» и «история». Эти результаты могут свидетельствовать о четкой определенности этих тем в новостных статьях, а также о том, что модель успешно улавливает специфические характеристики текстов в данных категориях.

### Результаты эксперимента

Category	Precision	Recall	F1-Score	Support
Sport	0.96	0.96	0.96	27
Politics	1.00	1.00	1.00	22
Business	1.00	1.00	1.00	13
Space	1.00	0.95	0.98	21
Technologie	1.00	1.00	1.00	23
Entertainment	1.00	1.00	0.98	25
Medical	1.00	0.92	0.96	13
Food	0.95	0.95	0.95	21
Historical	1.00	1.00	1.00	20
Graphics	0.94	1.00	0.97	15
Accuracy	?	?	0.98	200
Macro avg	0.98	0.98	0.98	200
Weighted avg	0.98	0.98	0.98	200

Полнота (recall) также продемонстрировала высокие результаты, однако в некоторых категориях, таких как «медицина» (0.92) и «космос» (0.95), наблюдались небольшие отклонения. Это может указывать на то, что часть текстов в этих категориях могла быть сложной для классификации, возможно из-за перекрытия тем с другими категориями или использования специфической лексики, менее представленной в тренировочном наборе.

F1-мера сочетает точность и полноту, и для всех категорий ее значения варьируются от 0.95 до 1.0. Это подтверждает, что модель BERT в целом хорошо справляется с задачей классификации, успешно уравнивая точность и полноту.

В категории «графика» точность модели составила 0.94 при полноте 1.0, что может говорить о наличии в текстах этой категории элементов, перекрывающихся с другими тематиками, либо о недостаточной репрезентативности данной темы в тренировочном наборе.

Выводы. Эксперимент продемонстрировал высокую эффективность модели BERT для тематической классификации новостных текстов на русском языке. Модель показала отличные результаты по ключевым метрикам, включая точность, полноту и F1-меру, подтверждая ее способность эффективно различать тематики статей. Наилучшие результаты были достигнуты в категориях с четкими темами, что связано с наличием четко определенной лексики и достаточным количеством данных.

Заключение. Эффективность подхода BERT подтверждается способностью модели минимизировать ошибки классификации, что важно для задач, требующих высокой точности, таких как автоматическая категоризация и фильтрация контента.

Определим несколько направлений, которые могут улучшить модель и расширить ее применение.

1. Увеличение объема данных. Добавление большего количества текстов в тренировочный набор может помочь модели лучше справляться с менее репрезентативными темами, такими как «медицина» и «еда», где наблюдались незначительные отклонения в метриках.

2. Использование специализированных подмоделей. Включение дополнительных моделей, обученных на более узких тематиках, может повысить точность классификации в сложных или специализированных категориях.

3. Улучшение предобработки данных. Применение методов глубокой семантической предобработки и анализа текстов может помочь лучше улавливать тонкие различия между тематиками, что в свою очередь улучшит общую производительность модели.

4. Исследование других архитектур трансформеров. Изучение других моделей, таких как GPT или T5, и их сравнение с BERT может предоставить дополнительные инсайты и помочь выбрать наиболее подходящий подход для конкретных задач классификации.

### Библиографический список

1. *Фомин В. В., Фомина И. К., Осочкин А. А.* Информационная технология организации системы классификации текстов // Информатизация образования и науки. 2022. № 2(54). С. 27–44.
2. *Камалова И. В., Борисов С. А.* Методики обработки естественного языка: современные подходы и технологии // Вестник Томского государственного университета. 2019. Т. 47, № 1. С. 74–85.
3. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding / J. Devlin, M. W. Chang, K. Lee, K. Toutanova // Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics (NAACL '19). Association for Computational Linguistics. 2019. С. 4171–4186. URL: <https://www.aclweb.org/anthology/N19-1423/> (дата обращения: 15.08.2024).
4. *Лебедев А. Н., Сидоров М. В.* Современные подходы к тематическому моделированию и их реализация на основе BigARTM // Вестник Института прикладной математики и информатики. 2021. № 3(15). С. 45–58.
5. *Гаврилов Н. И.* Модели тематического моделирования и их применение в задачах обработки текстов // Вестник Московского университета. Серия 25: Компьютерные науки. 2018. № 4(1). С. 53–69.

*А. А. Шукин\**

студент

*М. Д. Поляк\**

старший преподаватель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ПРОГНОЗИРОВАНИЕ КОНЦЕНТРАЦИИ ХЛОРОФИЛЛА А С ПОМОЩЬЮ МЕТОДОВ МАТЕМАТИЧЕСКОЙ СТАТИСТИКИ И НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ

Рассматривается задача прогнозирования цветения фитопланктона за счет анализа концентрации хлорофилла *a* в водоеме. Используются методы регрессионного анализа и нейросетевой подход.

**Ключевые слова:** фитопланктон, хлорофилл *a*, прогнозирование, перцептрон.

*A. A. Shchukin\**

Student

*M. D. Polyak\**

Senior Lecturer

\*St. Petersburg State University of Aerospace Instrumentation

## PREDICTION OF CHLOROPHYLL A CONCENTRATION USING METHODS OF MATHEMATICAL STATISTICS AND NEURAL NETWORK MODELS

The paper addresses the task of forecasting phytoplankton blooms by analyzing the concentration of chlorophyll *a* in a water body. Regression analysis methods and a neural network approach are used.

**Keywords:** phytoplankton, chlorophyll *a*, forecasting, perceptron.

### 1. Описание предметной области

Хлорофилл *a* – ключевой пигмент фотосинтеза у фитопланктона и микроводорослей. Избыточный рост микроводорослей может вызвать «цветение воды», снижая уровень кислорода и приводя к гибели водных организмов. Это влечет за собой экологические и экономические проблемы, такие как упадок рыболовства и туризма. Оценить концентрацию микроводорослей сложно без лабораторных тестов, но измерение концентрации хлорофилла *a* в воде может служить эффективным индикатором их содержания.

### 2. Описание данных

В работе использован временной ряд изменения концентрации хлорофилла *a* в Балтийском море за период с 1997 по 2022 г., предоставленный организацией Copernicus Marine Environment Monitoring Service (CMEMS) [1]. Данные предоставлены Плимутской морской лабораторией и включают ежемесячные региональные средние значения, вычисленные путем усреднения 2D-месячных данных по площади пикселя в пределах Балтийского моря (широта от 53,25° до 65,85°, долгота от 9,25° до 30,25°).

Дополнительно использовалась база данных концентрации хлорофилла *a* Шведского метеорологического и гидрологического института за период с 1982 по 2023 г. [2]. Выбраны данные с одной станции (KOVIKSUDDE) и с одного водного региона (Norra Östersjön). Эти данные содержат множество измерений, что позволяет исследовать корреляцию концентрации хлорофилла *a* с температурой воздуха, номером недели и глубиной взятия измерений.

### 3. Математическое и компьютерное моделирование

Для моделирования биологических процессов могут применяться разные подходы, например исследование динамических систем [3] или статистические методы [4]. Рассмотрим несколько статистических подходов.

#### *Регрессионный анализ*

Для реализации методов регрессионного анализа данных потребовалось удалить пропуски, возникшие из-за отсутствия измерений зимой, так как ввиду природных условий данные считаются некорректными.

Для дальнейшего анализа временной ряд нужно привести к стационарному состоянию, для чего была построена модель скользящего среднего. Поскольку значения данных повторяются ежегодно, с низкими показателями в холодные месяцы и высокими в теплые, размер окна сезонности был установлен на 9 значений. Обобщенная формула для вычисления значения для текущего момента времени:

$$y_t = \frac{1}{n} \sum_{i=t-n}^t y_i,$$

где  $y_t$  – новое значение временного ряда с индексом  $t$ ;  $n$  – размер окна.

Чтобы отследить тенденцию хлорофилла  $a$ , необходимо построить линию тренда. Линии тренда бывают разных видов, но, чтобы наглядно сказать увеличивается или уменьшается концентрация хлорофилла, необходимо построить линейный полином. Пример полиномиальной функции в общем виде:

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \dots + \beta_n x^n,$$

где  $y$  – вектор наблюдаемых значений;  $x$  – независимая переменная;  $\beta_0, \beta_1, \beta_2, \dots, \beta_n$  – коэффициенты, которые необходимо найти;  $n$  – степень полинома, для линии тренда  $n = 1$ .

Чтобы найти параметры прямой, рассмотрим метод наименьших квадратов. Для начала необходимо сформировать матрицу значений независимой переменной, она выглядит следующим образом:

$$X = \begin{pmatrix} 1 & x_1 & x_1^2 & \dots & x_1^n \\ 1 & x_2 & x_2^2 & \dots & x_2^n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_n & x_n^2 & \dots & x_n^n \end{pmatrix}.$$

Вектор  $\beta$  находится через следующую формулу:

$$\beta = (X^T X)^{-1} X^T y,$$

где  $\beta$  – вектор коэффициентов;  $X$  – матрица значений независимой переменной;  $y$  – вектор зависимой переменной;  $X^T$  – транспонированная матрица  $X$ .

### ARIMA-модель

Модель ARIMA (Auto Regressive Integrated Moving Average) используется для прогнозирования временных рядов и состоит из трех компонентов: AR (авторегрессия) – описывает зависимость текущего значения ряда от предыдущих; I (интегрирование) – применяется для приведения ряда к стационарному виду путем взятия разностей между значениями, что устраняет тренды и сезонные эффекты; MA (скользящее среднее) – описывает зависимость текущего значения от предыдущих ошибок прогноза [5].

Модель ARIMA обозначается как ARIMA(p, d, q), где  $d$  – количество дифференцирований, необходимых для стационарности ряда, проверяется с помощью ADF-теста;  $p$  – количество лагов для авторегрессии, определяется по графику частичной авторегрессии (PACF-тест) или методом перебора, если визуально подобрать константу не получается;  $q$  – количество лагов для скользящего среднего, определяется по графику автокорреляции (ACF-тест) или подбором.

Чтобы оценить, насколько модель правдоподобно предсказывает результаты, необходимо посчитать специальные количественные меры (метрики). Рекомендуется использовать сочетание метрик для более корректных результатов.

**MSE (Mean Squared Error)** – среднеквадратичная ошибка, оценивающая среднее значение квадратов ошибок между предсказанными и истинными значениями. Формула для MSE:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2,$$

где  $n$  – количество наблюдений;  $y_i$  – истинное значение;  $\hat{y}_i$  – предсказанное значение.

На практике чаще используют квадратный корень из MSE (**Root Mean Squared Error, RMSE**), выражающий ошибку в тех же единицах, что и целевая переменная. RMSE менее чувствителен к выбросам и легче интерпретируется. Чем ниже RMSE, тем точнее модель.

**AIC (Akaike Information Criterion)** – критерий, учитывающий также сложность модели. Низкие значения AIC указывают на лучшее соотношение точности и сложности модели. Формула для вычисления AIC:

$$AIC = 2k - 2\ln(L),$$

где  $k$  – количество параметров модели;  $L$  – максимальное значение функции правдоподобия.

После построения модели важно проверить ее остаточные значения, которые представляют собой разницу между фактическими значениями и предсказаниями модели. Модель считается достоверной, если остатки случайны, т. е. имеют нормальное распределение и не демонстрируют явных паттернов. Для визуальной оценки можно построить графики остатков, гистограмму распределения и QQplot. Для более глубокой проверки рекомендуется провести тесты на нормальность распределения остатков и на наличие автокорреляции.

### Многослойный перцептрон

Многослойный перцептрон (MLP) – это модель нейронной сети, состоящая из нескольких слоев (рис. 1), где каждый слой включает несколько нейронов, принимающих входные сигналы с определенными весами [6]. Отдельный нейрон описывается формулой

$$z = \sum_{i=1}^n w_i x_i + b,$$
$$a = f(z),$$

где  $x_i$  – входной сигнал;  $w_i$  – вес нейрона;  $b$  – смещение;  $f$  – активационная функция;  $a$  – выходной сигнал.

MLP используется для прогнозирования на основе признаков (предыдущих значений временного ряда). В данном случае сеть состоит из девяти нейронов во входном слое, шестнадцати в скрытом и одного на выходе.

Модель обучается в течение 100 эпох, каждая из которых включает 150 случайных выборок из тренировочной выборки (всего 180 элементов). В качестве оптимизатора используется Adam (Adaptive Moment Estimation), а функция потерь – MSE. На каждом шаге 9 признаков проходят через сеть, вычисляется предсказанное значение  $y(i)$ , которое сравнивается с реальным  $y$  и корректируется на основе `learning_rate`, регулирующего скорость обучения.




Рис. 1. Схема многослойного перцептрона

В ходе обучения сеть постепенно уменьшает функцию потерь, оптимизируя веса. По завершении обучения строится предсказание, позволяющее оценить переобучение и точность модели.

### Практические результаты

На рис. 2 показаны данные концентрации хлорофилла  $a$ , предоставленные СМЕМС. График очищен от пропусков зимних месяцев, добавлены модель скользящего среднего и линия тренда. Наблюдается незначительный рост концентрации хлорофилла  $a$ .

На рис. 3 представлены обучение и тестирование ARIMA-модели. В данной работе используется модель ARIMA(8, 1, 10). Она имеет минимальные значения метрик (RMSE  $\approx$  0.104 63, AIC  $\approx$  -241.220 17) и не демонстрирует переобучение.

На рис. 4 проведены тесты на нормальность распределения остатков, подтверждающие адекватность модели.

Рисунок 5 показывает тестирование MLP, а рис. 6 – график функции потерь за 100 эпох. Подбор гиперпараметров позволил создать и обучить модель MLP с метрикой RMSE  $\approx$  0.027.




Рис. 2. Данные концентрации хлорофилла а, скользящее среднее и тренд




Рис. 3. Модель ARIMA




Рис. 4. Остаточные значения ARIMA-модели






Рис. 5. Многослойный перцептрон




Рис. 6. График функции потерь в процессе обучения многослойного перцептрона




Рис. 7. Концентрация хлорофилла а и температуры воздуха на станции KOVIKSUDDE

Анализ временных рядов концентрации хлорофилла  $a$  и температуры воздуха (рис. 7) показал следующее.

– Коэффициенты корреляции Пирсона: между хлорофиллом  $a$  и температурой воздуха  $\approx 0.1917$ , что указывает на слабую положительную линейную зависимость; между хлорофиллом  $a$  и номером недели в году  $\approx -0.0748$ , что указывает на очень слабую, практически отсутствующую, отрицательную линейную зависимость.

– Коэффициенты корреляции Спирмана: между хлорофиллом  $a$  и температурой воздуха  $\approx 0.2819$ , что указывает на слабую монотонную зависимость; между хлорофиллом  $a$  и номером недели в году  $\approx -0.0837$ , что указывает на очень слабую, практически отсутствующую, отрицательную монотонную зависимость.

Также было построено уравнение множественной регрессии:

$$y = 0.2411x_1 - 0.0798x_2 + 9.7451,$$

где  $y$  – зависимая переменная (концентрация хлорофилла  $a$ );  $x_1$  – значение температуры воздуха;  $x_2$  – значение номера недели в году.

Уравнение показывает, насколько влиятельна единица характеристики на зависимую переменную. Коэффициент детерминации  $R^2 = 0.0502$ , что свидетельствует о том, что только примерно 5% значений зависят от температуры и номера недели. Коэффициенты корреляции между концентрацией хлорофилла  $a$  и глубиной отбора проб воды: коэффициент корреляции Пирсона  $\approx -0.12973$ , что указывает на слабую отрицательную линейную связь; коэффициент корреляции Спирмена  $\approx -0.1391$ , что указывает на слабую отрицательную монотонную связь; коэффициент правдоподобия  $\approx 2.15568e-23$ , что указывает на сильную статистическую значимость.

### Выводы

Установлено, что концентрация хлорофилла  $a$  за последние 30 лет немного возросла, влияние температуры воздуха на изменения концентрации минимально, а время года (номер недели в году) практически не оказывает влияния на измерения.

Для прогнозирования концентрации хлорофилла  $a$  были реализованы несколько моделей. Лучшую точность показала модель многослойного персептрона (MLP) с девятью нейронами на входном слое, шестнадцатью на скрытом слое и одним выходным нейроном, использующая оптимизатор Adam с learning rate = 0.001, обучавшаяся 100 эпох и с 150 тестами на эпоху (RMSE  $\approx 0.027$ ). MLP обучалась на стационарном ряде, в то время как модель ARIMA (8, 1, 10) также показала хорошие результаты с RMSE  $\approx 0.10463$ . В качестве эталона служила метрика RMSE линейного полинома (тренда), равная 0.16432; модели с ошибками ниже этого значения считаются успешными.

### Библиографический список

1. Baltic Sea Chlorophyll-a time series and trend from Observations Reprocessing // Copernicus Marine Environment Monitoring Service. URL: <https://marine.copernicus.eu/access-data/ocean-monitoring-indicators/baltic-sea-chlorophyll-time-series-and-trend-observations> (дата обращения: 04.08.2024).
2. Svenskt Havsvetenskap // SHARK web. URL: <https://sharkweb.smhi.se/hamta-data/> (дата обращения: 04.08.2024).
3. Щеголева А. А., Поляк М. Д. Модель «хищник-жертва с питанием // Обработка, передача и защита информации в компьютерных системах: Междунар. науч. конф.: сб. докл., СПб., 14–22 апр. 2021 г. СПб.: ГУАП, 2021. С. 86–91.
4. Грешилов А. А., Стакун В. А., Стакун А. А. Математические методы построения прогнозов. М.: Радио и связь, 1997. 112 с.
5. Айвазян С. А. Прикладная статистика: учеб. для вузов: в 2 т. Т. 2. Основы эконометрики. 2-е изд. М.: ЮНИТИ-ДАНА, 2001. 432 с.
6. Хайкин С. Нейронные сети. Полный курс. 2-е изд. М.: Ун-т McMaster Гамильтон, Онтарио, Канада, 2006. 1101 с.

*И. А. Юдин\**

аспирант

*Д. С. Решетников\**

студент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## СОЗДАНИЕ ETL-ДВИЖКА ДЛЯ РЕПЛИКАЦИИ ДАННЫХ ИЗ APACHE HIVE В CLICKHOUSE

Представлено создание ETL-движка, который помогает автоматически извлекать, преобразовывать и загружать данные из разных источников. Мы сосредоточились на разработке быстрого инструмента, который использует параллельную обработку и оптимизированные алгоритмы. Результаты тестирования показывают, что движок эффективно справляется с большими объемами данных, что помогает лучше анализировать информацию и принимать обоснованные бизнес-решения.

**Ключевые слова:** Apache Hive, репликация данных, Clickhouse, Apache Airflow, Python.

*I. A. Yudin\**

PhD Student

*D. S. Reshetnikov\**

Student

\*St. Petersburg State University of Aerospace Instrumentation

## CREATING AN ETL ENGINE FOR DATA REPLICATION FROM APACHE HIVE TO CLICKHOUSE

The paper presents the creation of an ETL engine that helps to automatically extract, transform and load data from various sources. We focused on developing a fast tool that uses parallel processing and optimized algorithms. The test results show that the engine effectively handles large amounts of data, which helps to better analyze information and make informed business decisions.

**Keywords:** Apache Hive, data replication, Clickhouse, Apache Airflow, Python.

В статье мы представим процесс создания ETL, который включает извлечение данных из источников, их преобразование для соответствия требованиям целевой системы и загрузку в конечное хранилище.

Apache Hive – это система управления данными, построенная на Hadoop, которая позволяет выполнять SQL-подобные запросы к большим объемам данных, хранящимся в распределенных файловых системах. ClickHouse, в свою очередь, является колоночной системой управления базами данных (СУБД), оптимизированной для обработки аналитических запросов в реальном времени [1].

Создание ETL-движка [1; 2] между этими двумя системами позволяет обеспечить эффективный перенос и обработку данных, что открывает новые возможности для анализа и бизнес-аналитики. В статье мы подробно рассмотрим этапы разработки такого движка, включая извлечение данных из Hive, их трансформацию и загрузку в ClickHouse, а также поделимся практическими примерами реализации.

Актуальность работы заключается в том, что Clickhouse является улучшенным инструментом для работы с BI-инструментами, следовательно, его целесообразно использовать при создании дашбордов и витрин данных. Также Clickhouse более удобен для обработки больших данных, масштабирования и распределенных вычислений [3].

Процесс обработки данных реализован при помощи технологий: Apache Hive, Clickhouse, Apache Airflow (необходим для того, чтобы создать в нем даг, который будет работать по расписанию с определенными требованиями, которые укажет пользователь), Jupiterlab (технология, в которой требуется произвести реализацию алгоритма), Apache Spark (распределенная вычислительная платформа, предназначенная для обработки больших данных, она поддерживает различные языки программирования, включая Python).

Язык реализации алгоритма Python. Python становится популярным выбором для реализации ETL-движков благодаря простоте и читаемости кода. Кроме того, поддержка параллельной обработки и интеграция с облачными сервисами делают Python универсальным инструментом для обработки больших объемов информации. Наконец, активное сообщество и доступная документация способствуют быстрому обучению и решению возникающих проблем. Библиотеки, которые понадобятся в Python: PySpark (для взаимодействия со Apache Spark), argparse (для того, чтобы передавать данные из дага в скрипт в Jupiterlab), airflow (для того, чтобы создать даг в Apache Airflow с необходимыми параметрами), pendulum (для того, чтобы конкретно указать timezone для работы движка и дага), ipywidgets (для реализации дружественного интерфейса в приложении, чтобы пользователи могли пользоваться данным движком).

Цель работы заключается в создании ETL-движка для репликации данных из Apache Hive в Clickhouse. Данный движок должен транспортировать данные из Apache Airflow в Clickhouse. Требуется определить основные подцели:

- создать шаблоны для создания дага. Требуется создать два шаблона дага, один включает все библиотеки, необходимые для создания дага, а другой содержит непосредственно скрипт создания дага;
- создать несколько классов. Необходимы классы для работы с таблицей в Clickhouse, для создания таблицы в Clickhouse, для работы с таблицей в Apache Hive, для работы с файлами hdfs и для создания основного класса, в котором будет произведена реализация работы всех классов и в который будут передаваться аргументы из дага;
- создать приложение с интерфейсом, встроенное в Jupiterlab, с помощью которого пользователь сможет сам создавать свой даг и ставить в расписание в Apache Airflow.

### Реализация алгоритма по созданию движка

1. Требуется создать два шаблона и положить их в папку templates. Первый шаблон необходимо назвать libraries.py. В него поместим все библиотеки, необходимые для создания дага и выполнения определенных модификаций при этом. Второй шаблон необходимо назвать template\_create\_dag.py, в нем выполним скрипт непосредственно по созданию дага. Шаблоны должны объединяться в один питоновский файл, принять параметры из приложения, откуда пользователь передает параметры по созданию дага [4]. После этого в Apache Airflow должен появиться даг, включающий скрипт из объединенных шаблонов.

2. В Jupiterlab следует создать пять классов, которые будут реализовывать необходимый нам алгоритм. Изначально определяются необходимые параметры, которые передаются из дага, такие как названия таблиц и баз данных, а также учетные данные для подключения к ним. После этого программа считывает введенные аргументы и сохраняет их для дальнейшего использования. Это позволяет пользователю гибко настраивать поведение программы в зависимости от его потребностей. Класс ManagerHelper представляет собой мощный инструмент для управления данными между системами Impala и ClickHouse, используя возможности Apache Spark. Он инкапсулирует логику создания и обработки таблиц, обеспечивая удобный интерфейс для взаимодействия с базами данных. Конструктор класса принимает необходимые параметры, такие как имя таблицы и базы данных в ClickHouse, а также учетные данные для подключения. Это позволяет легко настраивать объект ManagerHelper для работы с различными источниками данных.

Внутри класса создаются экземпляры вспомогательных классов, таких как ImpalaHelper, HDFSHelper и ClickHouseHelper, которые обеспечивают доступ к специфическим функциям работы с данными. Эти классы помогают разделить ответственность и упрощают поддержку кода. Например, ClickHouseHelper отвечает за взаимодействие с ClickHouse, в то время как ImpalaHelper предоставляет методы для работы с Impala. Такой подход способствует лучшей модульности и переиспользованию кода.

Класс также включает методы для генерации SQL-запросов, необходимых для создания таблиц в ClickHouse на основе структуры таблиц в Impala. Метод generate\_create\_table\_sql определяет логику обработки как партиционных, так и непартиционных таблиц. В зависимости от наличия партиций вызываются соответствующие методы для обработки данных. Это позволяет эффективно управлять различными типами таблиц и обеспечивает гибкость при работе с изменениями в структуре данных.

3. Далее требуется создать интерфейс, с помощью которого пользователи будут создавать для себя даги, с определенными параметрами. Необходимо создать интерактивный интерфейс для работы с Apache Spark и базами данных, используя библиотеку ipywidgets. Он включает чекбокс для выбора полной перезагрузки данных, текстовые поля для ввода расписания и названий таблиц, а также поля для выбора даты. Пользователь может инициировать действия через кнопки, такие как создание DAG или получение информации о таблице. Основная цель – упростить взаимодействие с данными и автоматизировать процессы для пользователя.

Внедрение ETL-движка для переноса данных из Hive в ClickHouse позволяет значительно улучшить процессы обработки и анализа больших объемов информации. Это решение обеспечивает интеграцию разрозненных данных, повышает их качество за счет трансформации и очистки, а также автоматизирует загрузку, что сокращает время на получение актуальной информации. Использование ClickHouse, известного высокой производительностью и возможностями работы с аналитическими запросами в реальном времени, в сочетании с мощными инструментами ETL позволяет компаниям эффективно реагировать на изменения в бизнес-среде и принимать обоснованные решения на основе качественных данных [5].

### Библиографический список

1. Тихонов А. В., Смирнов И. Н. Архитектура ETL-процессов для интеграции данных из различных источников // Журнал информационных технологий. 2020. № 12. С. 45–50.
2. Баранов Д. Е., Петрова А. С. Эффективные подходы к трансформации данных в ETL-процессах // Вестник информационных систем. 2019. № 3(27). С. 15–22.
3. Кузнецов С. В., Лебедев М. А. Оптимизация загрузки данных в ClickHouse с использованием ETL-решений // Научные труды вузов. 2021. № 5(32). С. 30–35.
4. Открытый курс по ETL и Data Warehousing // Coursera. 2022. URL: <https://www.coursera.org/learn/etl-data-warehousing> (дата обращения: 15.03.2023).
5. Сидоров И. П., Федоров А. Н. Применение ETL-процессов в аналитике больших данных // Современные проблемы науки и образования. 2021. № 4(56). С. 10–14.

# ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТИ

УДК 004.56

*А. В. Афанасьева\**

старший преподаватель

*С. В. Беззатеев\**

доктор технических наук, доцент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ОСОБЕННОСТИ ПРИМЕНЕНИЯ ДОВЕРЕННЫХ ВЫЧИСЛИТЕЛЬНЫХ СРЕД ДЛЯ ЗАЩИТЫ СИСТЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Рассматриваются особенности применения доверенных вычислительных сред для защиты систем искусственного интеллекта и машинного обучения. Обсуждаются уязвимости, связанные с процессом обучения и эксплуатацией нейронных сетей, а также методы защиты данных и моделей ИИ с использованием доверенных вычислительных сред. В результате анализа выявлены проблемы обеспечения безопасности и целостности при работе с обучающими выборками и алгоритмами.

**Ключевые слова:** доверенные среды выполнения, искусственный интеллект, нейронные сети, уязвимости, безопасность, модели машинного обучения.

*A. V. Afanasyeva\**

Senior Lecturer

*S. V. Bezzateev\**

Dr. Sc., Tech., Associate Professor

\*St. Petersburg State University of Aerospace Instrumentation

## FEATURES OF USING TRUSTED EXECUTION ENVIRONMENTS TO PROTECT ARTIFICIAL INTELLIGENCE SYSTEMS

The paper considers the features of application of trusted execution environments for protection of artificial intelligence and machine learning systems. The vulnerabilities related to learning and exploitation of neural networks, as well as data protection methods and AI models using trusted execution environments are discussed. The analysis revealed problems of security and integrity in working with training samples and algorithms.

**Keywords:** trusted execution environments, artificial intelligence, neural networks, vulnerability, security, machine learning models.

### Введение

Применение искусственного интеллекта и машинного обучения помогает решить разнообразные проблемы в самых разных прикладных областях, таких как медицина, машиностроение, оборонная промышленность. В медицине приложения и системы с использованием ИИ используются для распознавания медицинских изображений, разработки лекарств, удаленной помощи пациенту и т. д. В сельском хозяйстве при помощи ИИ беспилотные летательные позволяют проводить мониторинг состояния посевов, выявлять болезни растений и т. д.

Один из мощных инструментов искусственного интеллекта – нейронные сети. Алгоритмы нейронных сетей часто позволяют решить более сложные задачи, чем традиционные алгоритмы ИИ. Они обладают способностью к обучению на наборах данных с большим объемом, что помогает нейронным сетям найти широкое применение во многих областях. В нейронных сетях существуют многие модели, включая сверточные нейронные сети (СНС), рекуррентные нейронные сети и т. д. [1]. Сверточные нейронные сети – одна из моделей нейронных сетей, специально созданных для эффективной работы с неструктурированными данными. Алгоритмы СНС используют операцию свертки для извлечения признаков из набора данных, независимо от их местоположения. Эффективность СНС была доказана во многих научных исследованиях [1].

Процесс обучения нейронных сетей наиболее ресурсоемкий и часто требует привлечения дополнительных ресурсов, при этом он одновременно наиболее уязвимый с точки зрения безопасности: атакам подвержены

как обучающие выборки, так и формируемая в процессе обучения модель. Один из очевидных способов защиты нейронных сетей – применение доверенных вычислительных сред для их обучения и эксплуатации.

### Классификация УБИ ФСТЭК по технологиям ИИ

УБИ ФСТЭК представляется собой реестр угроз безопасности информации по ФСТЭК Российской Федерации [2]. В данном реестре представлена подробная информация об угрозах безопасности, возникающих в информационных системах. По своей структуре представленная информация включает описание угрозы, ее источники, объект воздействия и последствия реализации угрозы. Наличие УБИ может приводить к нарушению любого из обязательных требований триады безопасности: конфиденциальности, целостности и доступности. На рисунке показан список УБИ ФСТЭК на ИИ (последнее обновление 2020 г.) [2].

УБИ. 218	Угроза раскрытия информации о модели машинного обучения
УБИ. 219	Угроза хищения обучающих данных
УБИ. 220	Угроза нарушения функционирования («обхода») средств, реализующих технологии искусственного интеллекта
УБИ. 221	Угроза модификации модели машинного обучения путем искажения («отравления») обучающих данных
УБИ. 222	Угроза подмены модели машинного обучения

*УБИ ФСТЭК по технологиям ИИ в 2020 г.*

Согласно перечню УБИ ФСТЭК, УБИ по технологиям ИИ являются угрозами УБИ.218 - 222 [2]. УБИ по технологиям ИИ могут быть разделены на три группы по объекту воздействия:

- угрозы, связанные с моделью МО (УБИ.218, УБИ.221, УБИ.222);
- угрозы, связанные с обучающими данными МО (УБИ.219, УБИ.221.);
- угрозы, связанные со средствами, которые реализуют технологии ИИ (УБИ.220).

Угрозы, связанные с моделью ИИ, возникают из-за недостатков в реализации процесса обучения, в разработке алгоритмов обучения и слабостей в управлении доступом в системах, использующих модели МО. В результате реализации данных угроз возможны раскрытие информации о модели МО, модификация модели МО или подмена модели. В качестве нарушения базовых требований безопасности возможны нарушение конфиденциальности и целостности.

Угрозы, связанные с обучающими данными ИИ, возникают, из-за того, что злоумышленники могут воспользоваться слабыми местами управления доступом к автоматизированным системам, недостатками реализации процесса обучения и устройства алгоритмов МО для кражи обучающих наборов данных [2]. Эти угрозы воздействуют на обучающие данные МО и программы, использующие технологии ИИ. Их источником могут быть внешние и внутренние нарушители. Реализация этих угроз может приводить к нарушению конфиденциальности и целостности.

Угроза, связанная со средствами, реализующими технологии ИИ, обусловлена наличием недостатков моделей МО или отсутствием необходимых данных в обучающей выборке [2].

### Применение доверенных вычислительных сред для защиты систем искусственного интеллекта

Доверенная платформа в самом общем смысле – это совокупность ресурсов, которые могут доказать, что она может предоставлять доверенные услуги и предоставляет доверенные услуги, независимо от того, являются ли эти услуги вычислительными услугами, производственными услугами, услугами проектирования или услугами любого другого типа. Одна доверенная платформа может предоставлять услуги, которые используются другой доверенной платформой.

TCG [3] определяет схемы установления доверия к платформе, основанные на идентификации ее аппаратных и программных компонентов. Модуль доверенной платформы (Trusted Platform Module, TPM) предоставляет методы для сбора этих идентификационных данных и представления отчетов об этом. TPM, используемый в компьютерной системе, сообщает об аппаратном и программном обеспечении таким образом, который позволяет определить ожидаемое поведение и, исходя из этого ожидания, установить доверие.

Услуга, предоставляемая платформой доверенных вычислений, заключается в том, что владельцы платформы и пользователи могут защитить свою информацию от программных атак и ограниченного набора физических атак, контролируя доступ к ключам, контролируя перемещение ключей и доступ к расшифрованной информации. В случае владельца платформы защита означает защиту ОС или гипервизоров, в случае пользователя – защиту данных, которые представляют собой критически важную и/или ценную информацию.

Доверенные среды выполнения (Trusted execution environments, TEE) – это безопасные области центральных процессоров или устройств, которые выполняют код с более высоким уровнем безопасности, чем остальная часть устройства. Безопасность обеспечивается зашифрованными областями памяти, называемыми анклавами (enclaves). Поскольку среда изолирована от остальной части устройства, она, как правило, не подвержена заражению или компрометации устройства. В доверенных средах выполнения есть приложения для различных целей, например мобильные телефоны, облачная обработка данных или криптовалюта.

Использование аппаратных TEE в облачных средах называется «конфиденциальными вычислениями» (confidential computing). В статье [4] представлены систематический обзор и сравнение протоколов безопасных вычислений на основе TEE. Чтобы обеспечить справедливое сравнение рассматриваемых протоколов, в работе предложены комплексные критерии оценки по четырем аспектам: настройка, методология, безопасность и производительность. На базе этих критериев проведено сравнение современных протоколов безопасных вычислений на основе TEE как для вычислительных функций общего назначения, так и для функций специального назначения, таких как машинное обучение с сохранением конфиденциальности и зашифрованные запросы к базе данных. Аппаратные TEE предоставляются различными поставщиками, включая AMD, Intel и ARM, а также на различных платформах, включая Microsoft Azure или приложения интернета вещей [5–7]. Исторически TEE хранили небольшие объемы данных, например пароли или ключи шифрования. В настоящее время они доступны в более широком масштабе в облачных средах и поэтому могут предлагаться как часть безопасных служб баз данных, которые позволяют расшифровывать данные только в TEE соответствующих серверов, таким образом, их применение может быть расширено для защиты систем ИИ. Другими словами, данные шифруются как при передаче, так и при хранении. Несмотря на то, что они не шифруются во время использования, они все равно защищены, поскольку их можно использовать только внутри изолированного анклава [8]. Использование TEE в облачных средах позволяет компаниям переносить высококонфиденциальные данные, такие как обучающие выборки и обученные модели, в облако. Согласно предварительному исследованию [9], понимание регулирующего воздействия TEE имеет важное значение для стимулирования внедрения облачных технологий компаниями, особенно в таких отраслях, как здравоохранение, медико-биологические науки и банковское дело, которые более консервативны и медленно адаптируются.

Основной сложностью при применении доверенных сред выполнения для защиты систем ИИ являются большие объемы данных, содержащиеся в обучающих выборках, большие модели и их постоянное изменение в процессе обучения. Следовательно, необходимо рассмотреть существующие уязвимые объекты в системах ИИ и выделить особенности их защиты при помощи TEE. Атаки на системы МО могут вызывать неправильную работу системы, что приводит ко многим серьезным последствиям, таким как несанкционированное вторжение в систему МО и снижение производительности модели МО. Эти последствия могут быть связаны с серьезными проблемами, включая нарушение безопасности информации и воздействие на людей. Уязвимости систем ИИ связаны с важными компонентами системы: набор данных, архитектура и параметры модели МО, процесс обучения и процесс эксплуатации [10].

Системы МО почти полностью зависят от данных, только с их помощью алгоритмы моделей МО могут выполнять процесс обучения. Таким образом, наборы данных являются самой важной частью построения и развертывания моделей МО. Набор данных представляет собой статичную базу данных большого объема, которую можно защитить только при развертывании в защищенном анклаве с обязательной проверкой этих данных на целостность. В текущих условиях, когда доверенные среды вычисления разворачиваются в облачных системах, выделение достаточных объемов памяти на хранение данных не является неразрешимой проблемой.

Модель МО часто имеет довольно сложную архитектуру с множеством слоев и параметров, предназначенную для прогнозирования, распознавания объектов и принятия решений. Как и наборы данных, модель МО сталкивается со многими проблемами безопасности в процессе жизненного цикла. Она может быть уязвимым компонентом. Злоумышленники часто пользуются ошибками и уязвимостями структуры модели МО для реализации атак. Их целью являются кража информации о модели, ее модификация и подмена. Модель МО, как правило, включает два компонента, с которыми могут быть связаны уязвимости: архитектура модели и параметры модели. И если архитектура модели МО статична на всех этапах жизненного цикла после фиксирования на этапе проектирования, то параметры непрерывно меняются в процессе обучения, а иногда и эксплуатации, если модель поддерживает самообучение. Таким образом, основная сложность состоит в контроле целостности изменяющейся модели. Единственным способом поддержания целостности модели МО – помещение ее в изолированную доверенную среду вычислений, что существенно замедляет все связанные с моделью процессы, как обучения, так и эксплуатации.

На этапе обучения, являющемся самым важным процессом для любой модели МО, уязвимым объектом становится сам процесс обучения, включая алгоритмы оптимизации и алгоритмы регуляризации. И для защиты этого процесса нужны изолированные, авторизованные доверенные вычислительные платформы, обеспечивающие для владельца модели непрерывный контроль корректности работы алгоритмов обучения и целостности используемых для обучения выборок. Основной проблемой в данном подходе будет нахождение баланса между сложностью задачи контроля и доверием к получаемым результатам. На данном этапе не предлагается подобных систем.

На этапе эксплуатации систем ИИ можно столкнуться со многими потенциальными угрозами. Потенциальные угрозы связаны с безопасностью среды разработки, производительностью и доступностью модели. При этом средствами TEE может поддерживаться конфиденциальность данных запроса, но не может быть полностью

защищена модель МО и обучающая выборка, так как утечки возможны через ответы на запросы к системе ИИ. При этом средства TEE могут также контролировать целостность модели МО и запроса к системе.

### Заключение

В ходе выполнения анализа существующих уязвимостей систем ИИ и подходов к их защите на основе применения доверенных сред выполнения были выявлены объекты угроз и проведен анализ возникающих проблем при их защите. При помощи процедур безопасных вычислений на основе TEE в облачных средах может быть обеспечен контроль целостности обучающих данных и моделей МО, но при условии потерь в производительности, что не позволяет на данный момент предоставлять подобные услуги на рынке цифровых технологий. Кроме того, невозможно защитить систему от нарушения конфиденциальности (УБИ.218, УБИ.219) при помощи TEE в случае использования атак на основе черного ящика.

### Библиографический список

1. Deep Neural Network: The 3 Popular Types (MLP, CHC and RNN). URL: <https://viso.ai/deep-learning/deep-neuralnetwork-three-popular-types/> (дата обращения: 25.08.2024).
2. Банк данных угроз безопасности информации // Федеральная служба по техническому и экспортному контролю России: офиц. сайт. URL: <https://bdu.fstec.ru/threat> (дата обращения: 01.09.2024).
3. GlobalPlatform Technology TEE System Architecture v1.3 (White Paper: May 2022 – GPD\_SPE\_009). URL: <https://globalplatform.org/specs-library/tee-system-architecture/> (дата обращения: 20.08.2024).
4. (2023). A Survey of Secure Computation Using Trusted Execution Environments / X. Li, B. Zhao, G. Yang, [et al.]. ArXiv, abs/2302.12150.
5. Costan V., Devadas S. Intel SGX Explained. Published: Cryptology. 2016. URL: <https://eprint.iacr.org/2016/086> (дата обращения: 28.08.2024).
6. Priebe C. Protecting applications using trusted execution environments. Imperial College London, 2020.
7. A survey of Intel SGX and its applications / W. Zheng, Y. Wu, X. Wu [et al.] // Front. Comput. Sci. 2021. Vol. 15(3). P. 153808.
8. Kurnikov A. Trusted Execution Environments in Cloud Computing. Aalto University, 2021. 133 p.
9. Overcoming Cloud Concerns with Trusted Execution Environments? Exploring the Organizational Perception of a Novel Security Technology in Regulated Swiss Companies / T. Geppert, J. Anderegg, L. Frei [et al.] // Proceedings of the 55th Hawaii International Conference on System Sciences. 2022. P. 6822–6829.
10. Oprea A., Vassilev A. Adversarial Machine Learning: A Taxonomy and Terminology of Attacks and Mitigations / National institute of standards and technology. 2024. 75 p.



*Н. А. Балонин\**

доктор технических наук, профессор

*М. Б. Сергеев\**

доктор технических наук, профессор

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ПРОБЛЕМА СОХРАННОСТИ НАУЧНОГО НАСЛЕДИЯ УЧЕНЫХ

Рассматривается проблема сохранности научного наследия ученых, хранимого в виде их сайтов в сети Интернет. Ставится вопрос о решении проблемы на государственном уровне созданием ресурса, накапливающего научные сайты современных ученых и студентов – ученых будущего.

**Ключевые слова:** научное наследие, архивы, хостинг, домен.

*N. A. Balonin\**

Dr. Sc., Tech., Professor

*M. B. Sergeev\**

Dr. Sc., Tech., Professor

\*St. Petersburg State University of Aerospace Instrumentation

## THE PROBLEM OF PRESERVING THE SCIENTIFIC HERITAGE OF SCIENTISTS

The paper addresses the problem of preserving the scientific heritage of scientists, stored in the form of their sites on the Internet. The question is posed of solving the problem at the state level by creating a resource that accumulates scientific sites of modern scientists and students - future scientists.

**Keywords:** scientific heritage, archives, hosting, domain.

### Введение

Проблема сохранности научно-технической информации не нова, первый научный архив возник еще на базе петровской Академии наук и сохраняет в основном напечатанные книги и рукописи, причем практика насчитывает несколько столетий. Появление Интернета отразилось на форме сохранения научных трудов: прежде хранимое в печатном виде научное наследие стали оцифровывать. База метаинформации, например научной электронной библиотеки, дает очевидный пример современного обеспечения сохранности и простого доступа к статьям, книгам, тезисам, отчетам о НИР и др. [1].

Сегодня электронные библиотеки, сайты и блоги помаленьку вытесняют прежние книги как средство сохранения и донесения информации [2]. Но все ли можно сохранить в цифровом виде, в формате PDF и прочих аналогичных печати на бумажном носителе форматах в течение длительного времени? Конечно же, нет. И дело здесь не столько в технологиях работы с текстами, в переходе к использованию более современных, ранее не доступных средств, сколько в сохранении доступа к ресурсам ученых.

Можно привести примеры сайтов ученых в России и за рубежом, которые пропали и растворились в хаосе Интернета «темных веков», как смогут назвать наше время потомки. Вот существовали доходчивые обзоры, интересные страницы, включая блоги писателей. Где они, Артур Кларк и Станислав Лемм? Еще вчера они писали «в сеть». Где же их мысли? Ведь это были не только известные фантасты, но и инженеры.

Конечно, есть большое количество примеров бережного отношения к наследию выдающихся ученых и целых коллективов [3–5]. И не только в наше время. Дети Ивана Янковского (1800–1912), ученого, инженера и автора книги «Всемирное тяготение», смогли ее переиздать, а деньги использовать для создания фонда содействия изобретательской деятельности [6]. В наше время имеются примеры бережного сохранения научного наследия ученых в сети. Например, научное наследие Миклухо-Маклая в сети Интернет поддерживается его родственниками [7].

Однако нет смысла перечислять имена отечественных ученых, сайты которых, наполняемые долгое время научными работами, в том числе неопубликованными, не попавшими в научную электронную библиотеку, исчезли. Их очень много. Как только поддерживаемые хостинг и домен перестают оплачиваться, их сайты гаснут. Это серьезная проблема, которая пока мало осознается и дискутируется.

Цель настоящей работы – обратить внимание, пока это имеет смысл, на сохранение огромного научного наследия, доставшегося нам от предыдущего поколения и создаваемого сегодня, пока оно еще поддерживается усилиями авторов или их родственниками и учениками в Интернете. Тем более в современных условиях развития теории и технологий искусственного интеллекта – научного и прикладного направления, актуального сегодня и на долгое время.

### Пути решения проблемы

Принадлежность платформ, сохраняющих информацию, подчас темна и непредсказуема. Кто истинный их владелец, в чье владение переходят многочисленные тексты и сайты, часто неизвестно. Порядок в данной сфере,

как известно, может быть организован только государством. Ссылки на сохранение только востребованных сегодня ресурсов здесь неуместны. Фундаментальная наука всегда делается на будущее и имеет длительный эффект последствий в работах учеников и последователей. Но, вообще-то, трудно предсказать, когда это будущее для конкретного научного материала настанет и что будет конкретно востребовано.

**Государственный хостинг и домен** могли бы решить рассматриваемую проблему. Открытие государственной библиотеки сайтов ученых и студентов, в которую могло бы поступать и копиться наследие отечественных ученых и современные работы студентов, разумеется на добровольной основе, будет востребовано.

Что получает государство? Оно перестанет терять информацию.

Осознание возможности долговременного хранения информации в Сети стимулирует авторов на создание энциклопедий и баз данных, поскольку, есть ли смысл затевать создание крупного труда, если он от силы будет храниться частным образом пять или десять лет? А ведь в России большое количество ученых энциклопедического размаха, ими созданы замечательные справочники и даже энциклопедии.

Много шума наделала статья с доказательством теоремы Пуанкаре, опубликованная Григорием Перельманом в электронном архиве. Но мало кто задумывается о том, что этот архив пустился в свободное плавание. Ведь он меняет владельцев.

Другой пример – энциклопедия числовых последовательностей OEIS [8]. С уходом ее создателя, доктора Слоуна, она попала не известно в чьи руки. Польза от нее большая, а вот от ее исчезновения никто не выиграет.

Государственные хостинг и домен исключили бы увод информации в России в частные руки. Может, это и не так плохо – частная собственность на ресурсы Интернета, но кто же согласится с тезисом, что научные архивы и библиотеки, включая архив Академии наук, надо передать в частные руки? Для всех нас это невыгодно. Так почему это может быть выгодно как долговременная стратегия с архивом научных сайтов?

Сегодня в России в приоритете, среди прочих научных направлений, искусственный интеллект. Куда же складировать результаты научных и прикладных работ в этой современной научной области, определяющей будущее? Пока некуда и нет ресурса, на котором можно было бы все наработки (научные и прикладные) выложить на хранение с доступом всех желающих. Между тем, любая область науки нарастает заимствованиями, непрерывным обменом, ростом объема информации.

При наличии общеизвестной и доступной информационной среды ее могли бы развивать студенты сотен технических высших учебных заведений, соревнуясь в эффективности между собой. Где же им хранить результаты своих исследований? Да на той же платформе, на том же хостинге и домене. Сейчас они молодые ученые и специалисты, а завтра? База могла бы сопровождать их труд на протяжении всей их жизни. Так и делается, но с опубликованными трудами. На это и рассчитана eLibrary.ru, но недостаточен ли этот ресурс?

Сегодня уже нет. Он недостаточен. Он не предназначен для сохранения очень обширной научной информации, отличной от опубликованной. Он не становится центром кристаллизации таких работ. С сайтами ученых проблему надо решать, она нарастает.

**Где создавать хранилище и в каком виде?** Первоначально хранилище может быть децентрализованным, его можно создавать фрагментами при университетах, научно-исследовательских институтах, научных школах. Оно выгодно всем и как источник работ, и как общее хранилище. Важен, собственно, доступ по единому ресурсу.

Сайты отличаются от книг, им нужна поддержка программных продуктов и пакетов программ. На первое время даже понятно каких. Наиболее экономной форме хватит поддержки сочетания HTML и javascript. Далее стоит обеспечить РНР и прочие сервисы, например описанные в работах [9; 10] и ориентированные на работу с текстовыми и графическими данными. Все это реально и все это даст серьезный научный задел для его использования будущими поколениями.

## Заключение

Сохранность научных исследований сегодня обеспечивается только для опубликованных (зарегистрированных) работ. Однако не все результаты научных исследований сводятся к информации, для которой характерна названная форма. Современные ученые создают и многие годы поддерживают сайты, содержащие обильную научную, техническую и прочую информацию. Поскольку хостинги и домены ученых оплачиваются ими частным образом, информация с их уходом из науки (из жизни) со временем легко утрачивается. Мы обращаем внимание на то, что проблема может быть решена созданием ресурса, аналогичного eLibrary.ru, но накапливающего принципиально иную информацию – научные сайты современных ученых и студентов – ученых будущего.

## Библиографический список

1. Научная электронная библиотека. URL: eLibrary.ru (дата обращения: 11.08.2024).
2. Научно-методическая поддержка разработки научных электронных библиотек / С. И. Акимов, А. М. Елизаров, Т. В. Ершова [и др.] // Электронные библиотеки. 2005. Т. 8, вып. 1.
3. *Авруцкая Т. Б., Захаров-Гезехус И. А.* К 50-летию комиссии по сохранению и разработке научного наследия академика Н. И. Вавилова // Вестник Российской академии наук. 2016. Т. 86, № 10. С. 947–952.
4. *Бредихин В. Е., Козачек А. В.* Историко-педагогические аспекты деятельности комиссии Академии наук по разработке научного наследия В. И. Вернадского (1945–1985 гг.) // Вопросы современной науки и практики. Университет им. В. И. Вернадского. 2023. № 4(90). С. 157–169.

5. Мурзинцева А. Е., Кушнарцева Л. Л., Эрдынеева С. Э. Научное наследие в академических учреждениях Бурятии: формы сохранения и актуализации // Исторический курьер. 2021. № 2(16). С. 36–47. URL: [istkurier.ru/data/2021/ISTKURIER-2021-2-03.pdf](http://istkurier.ru/data/2021/ISTKURIER-2021-2-03.pdf) (дата обращения: 11.08.2024).
6. Горст И. В., Мещеряков В., Дунаевский Г. Е. Сохранение научного и инженерного наследия Яркковского в ТГУ // Актуальные проблемы радиофизики АПР-2023: сб. тр. X Междунар. науч.-практ. конф. Томск. 2023. С. 355–357.
7. Миклухо-Маклай Н. Н. Цифровизация и ее методы для сохранения и обеспечения преемственности научных традиций // Юго-Восточная Азия: актуальные проблемы развития. 2022. Т. 2, № 2(55). С. 255–267.
8. The On-Line Encyclopedia of Integer Sequences® (OEIS®). URL: [oeis.org](http://oeis.org) (дата обращения: 11.08.2024).
9. Балонин Н. А., Сергеев М. Б. Техническая «живая книга»: приглашение к дискуссии // Высшее образование в России. 2013. № 7. С. 141–144.
10. Балонин Н. А., Сергеев М. Б., Марлей В. Е. Новые возможности математической сети для коллективных исследований и моделирования в Интернет // Информационно-управляющие системы. 2014. № 3(70). С. 40–46.

*С. В. Беззатеев\**

доктор технических наук, доцент

*Т. Н. Елина\**

кандидат экономических наук, доцент

*Н. С. Красников\**

ассистент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## АЛГОРИТМ МИКШИРОВАНИЯ РЕАЛЬНОГО И СИНТЕТИЧЕСКОГО НАБОРОВ ДАННЫХ ДЛЯ ОБУЧЕНИЯ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

Рассматривается алгоритм микширования реального и синтетического наборов данных для обучения сверточных нейронных сетей, применяемых в интеллектуальных информационных системах. Исследуется процесс создания синтетического датасета с компрометирующими изображениями для повышения точности детектирования объектов. Описывается алгоритм микширования с использованием платформы Supervisely, включая шаги создания 3D-объектов, обработки данных и расчетов метрик качества. В результате проделанной работы получены реальные и синтетические датасеты, которые продемонстрировали эффективные результаты при обнаружении объектов в условиях высокой классификационной нагрузки.

**Ключевые слова:** микширование данных, синтетический датасет, сверточные нейронные сети.

*S. V. Bezzateev\**

Dr. Sc., Tech., Associate Professor

*T. N. Elina\**

PhD, Economic, Associate Professor

*N. S. Krasnikov\**

Assistant

\*St. Petersburg State University of Aerospace Instrumentation

## REAL AND SYNTHETIC DATA MIXING ALGORITHM FOR LEARNING NEURAL NETWORKS

The paper considers an algorithm for mixing real and synthetic data sets to learn about computational neural networks used in intelligent information systems. The process of creating a synthetic dataset with compromising images is investigated to improve the accuracy of detecting objects. The article considers an algorithm for mixing real and synthetic data sets to learn about computational neural networks used in intelligent information systems. The process of creating a synthetic dataset with compromising images is investigated to improve the accuracy of detecting objects.

**Keywords:** data mixing, synthetic dataset, retrieval neural networks.

В интеллектуальных информационных системах датасетом принято называть набор данных, который используется для обучения нейросетевых моделей и иных методов машинного обучения [1]. Качество и объем собранного датасета всецело определяют качество функционирования нейросетевой модели как таковой. Процессы формирования датасетов не всегда просты и часто в должной мере не автоматизированы. Кроме того, после сбора необходимого объема «сырых» массивов данных требуется провести множество их преобразований, выполняя так называемый препроцессинг (preprocessing) или подготовку данных (Data Preparation). В частности, к числу таких преобразований относится разметка изображений, которая является неотъемлемой частью разработки систем искусственного интеллекта и одной из основных задач в технологии компьютерного зрения. Кроме того, подготовка данных включает выборку, очистку, генерацию признаков, интеграцию, форматирование, разделение на обучающий, валидационный и тестовый датасеты. Каждый из этих процессов при больших объемах датасетов является нетривиальным и часто выполняется вручную при решении многих интеллектуальных задач, что приводит к существенным временным (до 80% от всего жизненного цикла нейросетевой модели [1]) и финансовым затратам именно при выполнении этапа препроцессинга. Поэтому задачи автоматизации процессов этапа Data Preparation актуальны.

После подготовки и разметки реального датасета возможно возникновение необходимости пополнения его синтетическими данными с целью улучшения точности детектирования объектов. Синтетический датасет в данном контексте требуется, чтобы сформировать достаточную по объему выборку с так называемыми «компрометирующими» изображениями – в них среди экземпляров основного класса весовых продуктов (например, яблок) «прячется» экземпляр иного класса (например, лайм или лимон). Сформировать датасет с компрометирующими изображениями, получив реальные фото от ритейла, весьма проблематично. Поэтому было принято решение автоматизировать процесс создания подобных датасетов. Процесс микширования реального и синтетического датасета выполнялся с использованием механизмов Supervisely [2] по описанному далее алгоритму. Supervisely пред-

ставляет собой веб-платформу, включающую расширенный интерфейс аннотаций, а также охватывающую весь процесс обучения компьютерному зрению, включая библиотеку моделей глубокого обучения, которые можно обучать, тестировать и улучшать непосредственно на платформе (рис. 1).

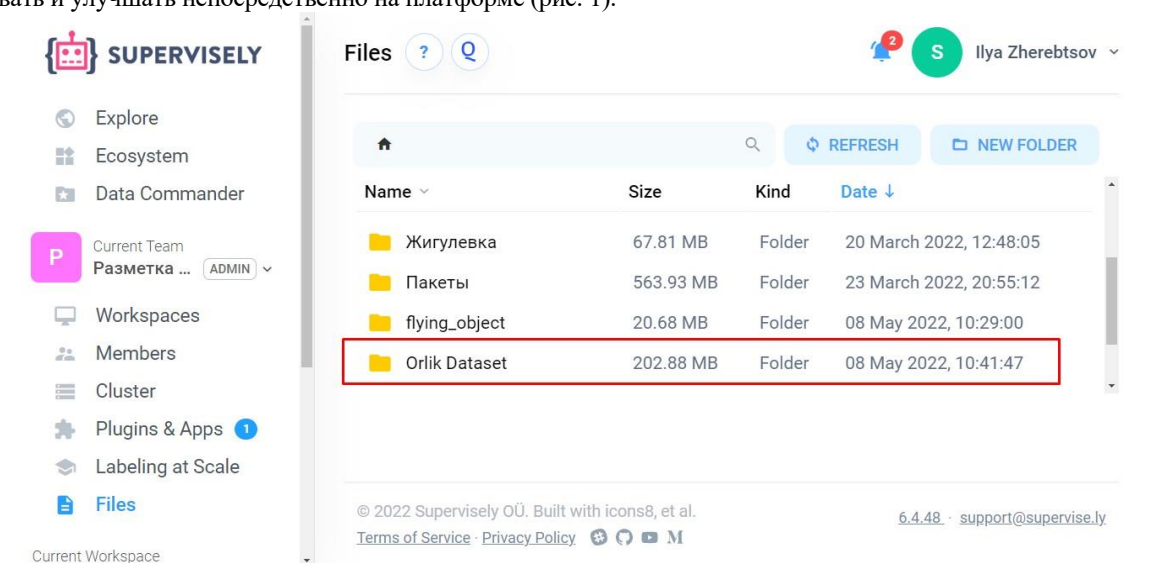


Рис. 1. Облачное хранилище, управляемое Supervisely

Шаг 1. Создание 3D-объектов весовых продуктов.

Шаг 2. Создание 3D-сцен весовых продуктов.

Шаг 3. Разработка нейросетевой модели адаптации целевого (реального) датасета и датасета-источника (синтетического).

Шаг 4. Загрузка синтетического датасета в облачное хранилище, управляемое Supervisely.

Шаг 5. Определение соотношения синтетических и реальных изображений.

Шаг 6. Расчет метрик качества нейросетевых моделей, решающих задачу сегментирования (индекс Жаккара) и задачу детектирования объектов (FAR и FRR).

Шаг 7. Повторение шагов 5 и 6, до тех пор, пока FAR и FRR не станут меньше значения  $10^{-3}$ .

Результаты исследования микширования датасетов приведены на рис. 2.




Рис. 2. Результаты исследования микширования датасетов: а – зависимость FAR от доли синтетических данных; б – зависимость FRR от доли синтетических данных

Разметка датасетов – это совместная масштабная работа: менеджеры, эксперты в предметной области, специалисты по обработке и анализу данных, штатные специалисты по маркировке и выделенные внешние группы по маркировке, системные администраторы и инженеры по информационной безопасности. В нем задействованы сотни людей. Кроме того, этот сложный процесс, который требует многоступенчатой проверки и корректировки для гарантии качества. А организовать весь процесс без специально разработанных инструментов сложно.

В результате работы созданы реальные и синтетические датасеты объектов. Реальный (целевой) датасет содержит 859 фотореалистичных изображений весовых продуктов [3], распределенных по 4 классам (категориям), сохраненных в формате JPEG с разрешением  $3024 \times 3024$ . Выполнена разметка реального датасета с использованием нейросетевой модели Mask R-CNN. Выбор нейросетевой модели Mask R-CNN экспериментально

подтвержден. Синтетический датасет (домен-источник) содержит 37 экземпляров 3D-объектов весовых продуктов и 1260 3D-сцен весовых продуктов с прозрачной упаковкой и без нее.

Проведено исследование по микшированию реального и синтетического датасета. В ходе исследования рассчитывались метрики: индекс Жаккара для предобученной нейросетевой модели при выполнении семантической сегментации и FAR и FRR для модели Faster R-CNN при решении задачи обнаружения объекта. Детектировался объект, имеющий отличающийся класс среди прочих равных (лимон среди яблок). Определено, что предпочтительным соотношением целевой домен / домен-источник является значение 40:60. При этом достигаются минимальные значения метрик FAR и FRR.

#### Библиографический список

1. Machine Learning Operations Maturity Model. URL: <https://www.bigdataschool.ru/blog/mlops-google-maturity-model.html> (дата обращения: 05.05.2024).
2. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. URL: <https://arxiv.org/abs/1506.01497> (дата обращения: 17.06.2024).
3. *Беззатеев С. В., Елина Т. Н., Красников Н. С.* Исследование методов машинного обучения для обеспечения информационной безопасности в розничных торговых операциях // Проблемы информационной безопасности. Компьютерные системы. 2022. № 3. С. 155–166.

*С. В. Беззатеев\**

доктор технических наук, доцент

*Т. Н. Елина\**

кандидат экономических наук, доцент

*Н. С. Красников\**

ассистент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ПРОБЛЕМЫ МОШЕННИЧЕСТВА С ИСПОЛЬЗОВАНИЕМ СИНТЕТИЧЕСКИХ ДАННЫХ В ЗАДАЧАХ КОМПЬЮТЕРНОГО ЗРЕНИЯ

Рассматриваются проблемы мошенничества, возникающие в результате использования синтетических данных в задачах компьютерного зрения, особенно в контексте ритейла. Показано, что генерация синтетических данных может компенсировать нехватку реальных данных, что критично для обучения нейросетевых моделей. В рамках исследования предложены механизмы по сбору, обработке и микшированию реальных и синтетических наборов данных с целью повышения эффективности детектирования мошенничества.

**Ключевые слова:** синтетические данные, компьютерное зрение, сверточные нейронные сети, детектирование объектов, 3D-сцены, микширование датасетов.

*S. V. Bezzateev\**

Dr. Sc., Tech., Associate Professor

*T. N. Elina\**

PhD, Economic, Associate Professor

*N. S. Krasnikov\**

Assistant

\*St. Petersburg State University of Aerospace Instrumentation

## PROBLEMS OF FRAUD WITH SYNTHETIC DATA IN COMPUTER VISION TASKS

The paper examines the problems of fraud arising from the use of synthetic data in computer vision tasks, especially in the context of retail. It is shown that the generation of synthetic data can compensate for the lack of real data, which is critical to learning neural network models. The study proposes mechanisms for collecting, processing and mixing real and synthetic data sets to improve fraud detection.

**Keywords:** synthetic data, computer vision, neural networks, object detection, 3D-scenes, dataset mixing.

Стремление к снижению стоимости бизнес-процессов торговых предприятий, в том числе за счет уменьшения трудозатрат на процессы обслуживания клиентов, приводит компании к использованию смарт-устройств в операционной деятельности. В настоящее время ритейлеры повсеместно используют кассы самообслуживания и смарт-корзины. При всех очевидных преимуществах применение такого интеллектуального оборудования несет и риски, обусловленные высокой вероятностью мошенничества со стороны недобросовестных покупателей. Наиболее частой является ситуация, когда покупатель кладет в корзинку один товар, а на весах вводит цену другого, более дешевого продукта [1]. Самой уязвимой категорией товаров с точки зрения такого рода мошенничества на кассах самообслуживания является весовая продукция – овощи и фрукты. Многочисленные сорта не расфасованных весовых продуктов разной ценовой категории являются потенциальным объектом мошенничества недобросовестных покупателей.

При этом незначительные в денежном выражении потери при подобных нарушениях в условиях большого потока покупателей складываются в значительные финансовые потери, с одной стороны, а с другой – наносят репутационный вред ритейл-бизнесу в целом. Данные риски обуславливают необходимость создания механизмов обнаружения и предотвращения мошенничества, встроенных в используемое интеллектуальное торговое оборудование. Предлагаемые методы, описанные в [2], используют сверточные нейронные сети, для качественного обучения которых необходимы наборы данных большого объема.

При решении различных прикладных задач компьютерного зрения часто исследователи сталкиваются с недостаточным объемом тренировочных данных. Один из подходов увеличения наборов данных в таких случаях – генерация синтетических данных, доступных в дальнейшем в неограниченном количестве, и адаптация обученной на них модели. В рамках рассматриваемой задачи – обнаружения факта мошенничества при покупке весовых продуктов в ритейле – имеется еще одна весома причина в насыщении датасетов синтетическими данными, поскольку объем данных с зафиксированным реальным фактом подмены весовых продуктов по объективным причинам мал. Решения описанной проблемы можно достичь с помощью реализации следующих задач:

1) сбор реальных наборов данных овощей и фруктов для ритейлеров, а также выполнение предварительной обработки и обогащение реальных наборов данных;

2) анализ и разработка эффективных методов формирования синтетических наборов данных овощей и фруктов для ритейлеров;

3) исследование существующих и при необходимости разработка оригинальных методов микширования реальных и синтетических наборов данных для ритейлеров;

4) выбор типа нейросетевой модели для реализации задачи бинарной классификации (наличие/отсутствие факта мошенничества), обоснование ее гиперпараметров, обучение и реализация;

5) выбор типа нейросетевой модели для решения задачи семантической сегментации и обнаружения объектов альтернативного класса (выделение объекта мошенничества), обоснование ее гиперпараметров, ее реализация и обучение.

Формирование синтетических наборов данных для обогащения реальных датасетов производилось путем реализации следующих этапов:

1) анализ технологий для автоматизации создания 3D-объектов синтетических наборов данных;

2) аналитический обзор методов и ML-инструментов обнаружения объектов на сложном изображении;

3) анализ требований для формирования стека технологий интеграции генератора 3D-сцен в ML-проект/платформу.

4) разработка генератора 3D-сцен весовых продуктов для ритейла;

5) проектирование и реализация архитектуры защищенных хранилищ для 3D-объектов;

6) создание микшированного датасета с 3D-сценами весовых продуктов для ритейла;

7) исследование влияния синтетического датасета на точность детектирования объекта мошенничества.

Основу систем компьютерного зрения составляют нейросетевые модели глубокого обучения, для которых большой объем обучающих данных является ключом к построению высокопроизводительных систем. Если нет нужного количества тренировочных данных, модели глубокого обучения сталкиваются с проблемой недообучения. Кроме того, данные, подаваемые на вход нейросетевой модели, должны быть разнообразными, иначе, даже если подается большое количество тренировочных данных, модель сталкивается с проблемой переобучения. В системах компьютерного зрения используются различные методы аугментации для создания более значимых данных, которые можно использовать для построения моделей глубокого обучения. Другими словами, искусственно увеличивается размер набора данных, создавая разные версии существующих данных из реального (но недостаточного по объему или разнообразию) набора данных. Алгоритмы увеличения данных могут повысить точность моделей машинного обучения.

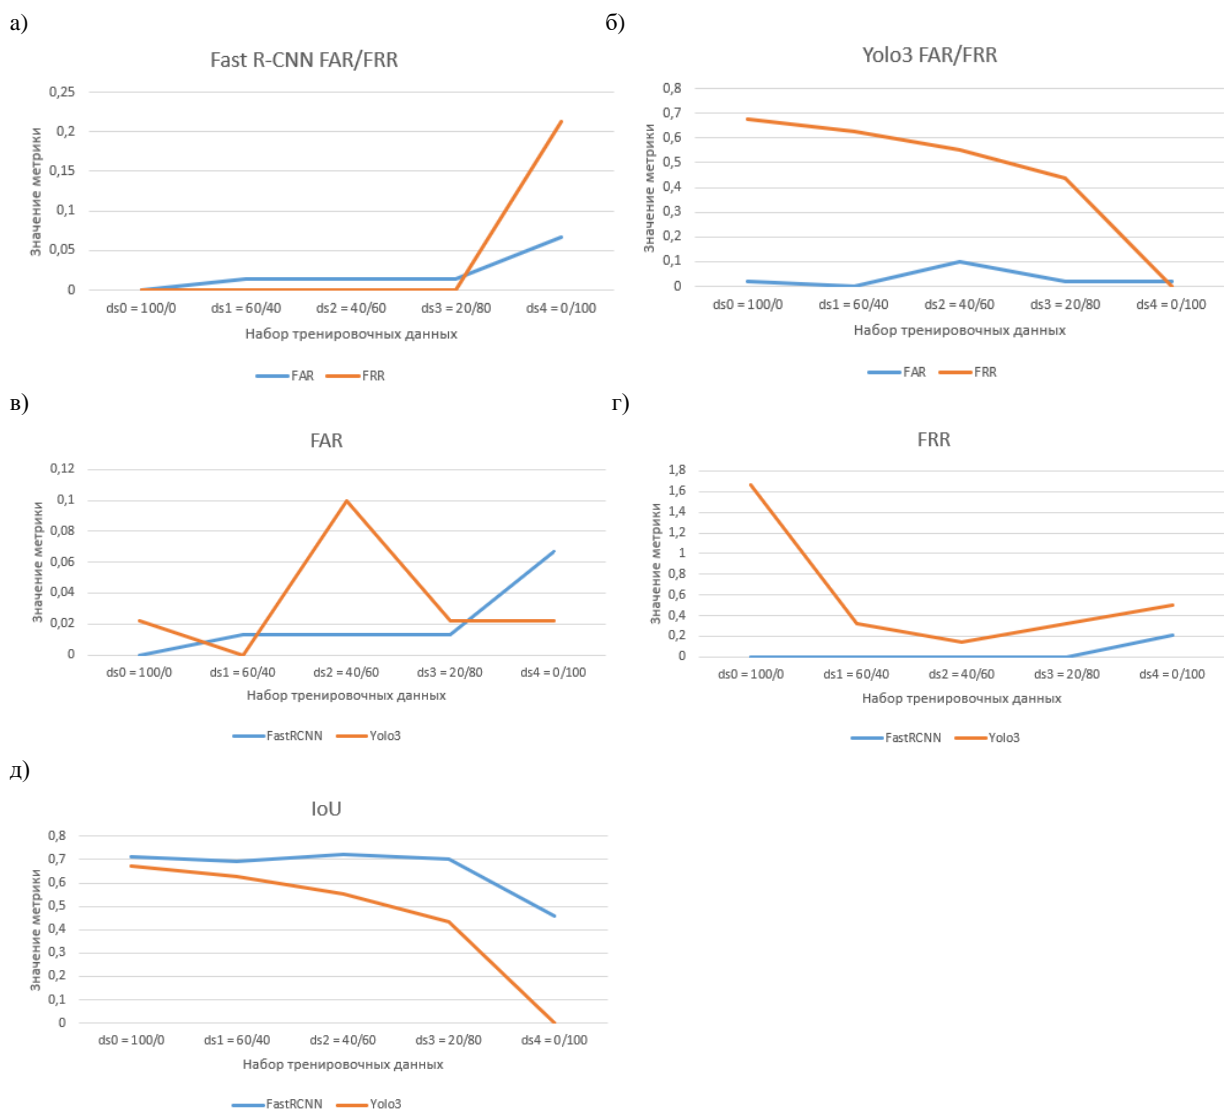
При работе с синтетическими 3D-изображениями чаще всего для аугментации используются аффинные преобразования [3]. Однако в процессе этих преобразований можно получить некоторые формы 3D-объектов, которых не существует в реальности, что может отрицательно повлиять на обучение модели. Поэтому в рамках поставленной задачи следует создавать синтетические данные отдельно, проверять их, а затем использовать для обучения. При этом актуальной является задача исследования влияния автоматически генерируемых 3D-сцен весовых продуктов на метрики качества распознавания объекта мошенничества. Для этого была построена модель глубокого обучения без аугментации и рассчитана точность детектирования объекта мошенничества. Затем строилась аналогичная модель глубокого обучения с выполнением аугментации и рассчитывалась та же точность. Затем сравнивалась производительность обеих моделей.

Результаты проведенной оценки влияния синтетического датасета на точность детектирования объекта мошенничества с использованием моделей Fast R-CNN и YOLOv3 [4] приведены в таблице и на рисунке. Для оценки использовались индекс Жаккара, а также метрики FAR и FRR.

**Значения метрик системы детектирования объекта мошенничества с помощью синтетического датасета на тестовой выборке**

Модель	Класс/соотношение данных целевого домена и домена-источника	100/0	60/40	40/60	20/80	0/100
<i>Индекс Жаккара</i>						
Fast R-CNN	Яблоки «Орлик» и лимон «Майкоп»	0,711 26	0,694 805	0,722 149	0,703 964	0,456 777
Yolov3	Яблоки «Орлик» и лимон «Майкоп»	0,673 95	0,627 95	0,553 55	0,435 83	0,000 24
<i>FAR</i>						
Fast R-CNN	Яблоки «Орлик» и лимон «Майкоп»	0	0,013 33	0,013 33	0,013 33	0,066 66
Yolov3	Яблоки «Орлик» и лимон «Майкоп»	0,021 74	0	0,1	0,021 73	0,021 74
<i>FRR</i>						
Fast R-CNN	Яблоки «Орлик» и лимон «Майкоп»	0	0	0	0	0,213 33
Yolov3	Яблоки «Орлик» и лимон «Майкоп»	1,666 66	0,318 18	0,14286	0,318 18	0,5





Результат оценки микширования датасетов: а – зависимость FAR и FRR от доли синтетических данных Fast R-CNN; б – зависимость FAR и FRR от доли синтетических данных Yolo3; в – сравнение FAR Fast R-CNN и Yolo3; г – сравнение FRR Fast R-CNN и Yolo3; д – сравнение индекса Жаккара Fast R-CNN и Yolo3

Таким образом, разработанный генератор 3D-сцен весовых продуктов позволяет в течение нескольких минут автоматически создавать синтетический 3D-датасет весовых продуктов объемом 1 Гб, имеющий полную разметку и аннотации. Также спроектирован и реализован конвейер нейросетевых моделей (обнаружение объекта мошенничества при покупке весовых товаров), в котором модели семантической сегментации и обнаружения взаимозаменяемо применяются для выявления объекта мошенничества. Экспериментально подтверждено, что для реализации этапа детектирования оптимальным выбором является модель Fast R-CNN. Исследовано влияние синтетического набора данных на точность детектирования объекта мошенничества. При использовании на завершающем этапе конвейера модели Fast R-CNN получено, что только на реальных датасетах RetailDataSet метрики FAR = 0, FRR = 0, ИЖ = 0,711 26. Данные метрики FAR и FRR при микшировании датасетов RetailDataSet с синтетическими имеют значения, представленные в таблице. Результаты оценки позволяют сделать вывод об оптимальном соотношении реальных и синтетических датасетов в пропорции 40/60.

### Библиографический список

1. Беззатеев С. В., Елина Т. Н., Красников Н. С. Исследование методов машинного обучения для обеспечения информационной безопасности в розничных торговых операциях // Проблемы информационной безопасности. Компьютерные системы. 2022. № 3. С. 155–166.
2. Yelina T. N., Bezzateev S. V., Krasnikov N. S. Analysis of the efficiency of neural network teacher learning methods for solving image classification problems // Wave Electronics and Its Application in Information and Telecommunication Systems. 2023. Vol. 6, № 1. P. 454–457
3. Фомичева С. Г. Влияние ранжирования индикаторов атак на качество моделей машинного обучения в агентных системах непрерывной аутентификации / Т-Comm: Телекоммуникации и транспорт. 2023. Т. 17, № 8. С. 45–55.
4. Haykin S. Neural Networks and Learning Machines. 3rd ed. Pearson, 2018.

*В. С. Беззатеева*

старший преподаватель

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## СПОСОБЫ ЗАЩИТЫ НЕСОВЕРШЕННОЛЕТНЕГО В СЕТИ ОТ ДЕСТРУКТИВНОГО КОНТЕНТА ПРИ ПОМОЩИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Применение искусственного интеллекта в целях повышения уровня защиты несовершеннолетних от негативного воздействия аддиктивного контента является актуальной проблемой. Рассмотрены современные способы защиты от деструктивного контента, использующие искусственный интеллект. Представленные методы могут быть использованы для обеспечения цифровой безопасности несовершеннолетнего.

**Ключевые слова:** искусственный интеллект, защита от деструктивного контента.

*V. S. Bezzateeva*

Senior Lecturer

St. Petersburg State University of Aerospace Instrumentation

## WAYS TO JUVENILE PROTECT FROM DESTRUCTIVE CONTENT ON THE INTERNET WITH ARTIFICIAL INTELLIGENCE

The use of artificial intelligence to increase the level of protection of juvenile from the negative impact of addict content is a pressing issue. The article considers modern ways of protection against destructive content using artificial intelligence. The methods discussed can be used to ensure the digital security of a juvenile.

**Keywords:** artificial intelligence, protection from destructive content.

### Введение

В эпоху цифровизации несовершеннолетние все чаще сталкиваются с деструктивным контентом, который оказывает негативное влияние на их психоэмоциональное состояние. Развитие цифровых технологий и сети Интернет, в том числе социальных сетей дало возможность несовершеннолетним получать доступ к информации, которая может быть как полезной и нужной, так и опасной. Деструктивный контент, в том числе пропаганда насилия, экстремизма и материалы для взрослых, является серьезной угрозой для психологического благополучия детей. В свою очередь, традиционные методы, используемые для фильтрации контента и основанные на черных списках и ключевых словах, часто оказываются неэффективными. В таком контексте методы ограничений на базе искусственного интеллекта дают более гибкий и точный результат.

### Современные способы защиты, использующие искусственный интеллект

На данный момент существует несколько российских систем, таких как: семейный режим поиска Яндекс, Kaspersky Safe Kids, облачный сервис SkyDNS, работающих на определенных методах искусственного интеллекта (ИИ), включающих:

- 1) фильтрацию контента – данная система ИИ может анализировать информацию в сети Интернет и осуществлять ее фильтрацию в соответствии с выбранными критериями;
- 2) анализ контента – нейронные сети могут быть обучены для анализа текста, изображений, видео и дальнейшего определения, подходит ли он для просмотра несовершеннолетним;
- 3) мониторинг онлайн-активности и анализ поведения – системы ИИ могут проводить анализ истории браузера для выявления сайтов с деструктивным контентом, а также отслеживать и анализировать поведение несовершеннолетнего в сети. В случае если ребенок пытается получить доступ к сайту с неподходящими материалами или проявляет необычное поведение при нахождении в сети, система может сразу заблокировать сайт или отправить оповещение родителям;
- 4) родительский контроль – ИИ используется для мониторинга и ограничения доступа к деструктивным сайтам и приложениям на устройствах детей, система автоматически предлагает ограничение контента в зависимости от возраста несовершеннолетнего и адаптирует ограничения по мере взросления. Также при помощи родительского контроля можно установить разрешенное время использования гаджета;
- 5) обучение нейронной сети – можно обучить ИИ распознавать не только явный вредоносный контент, но и более скрытые его формы, такие как кибербуллинг, манипуляции, шутерство;
- 6) умные голосовые помощники – данные системы, встроенные в устройство несовершеннолетнего, могут использовать ИИ для блокирования запроса, если он включает аддиктивный контент.

У данных механизмов есть как преимущества, такие как, скорость обработки больших объемов данных и возможность непрерывного обучения нейронной сети для повышения точности фильтрации, и недостатки, к которым можно отнести возможность ложных результатов, в результате чего будет заблокирован безопасный

контент, пропущенная деструктивная информация, которая не была распознана как деструктивная, что требует постоянного мониторинга и улучшений. Кроме того, остро стоит проблема обеспечения конфиденциальности данных в таких системах, и возможная предвзятость, в случае обучения их на несбалансированных данных.

Для развития нейронной сети с целью обеспечения безопасности несовершеннолетнего в Интернете можно предложить несколько новых методов.

1. Управление контентом в динамике, исходя из психоэмоционального состояния, – ИИ может использовать распознавание эмоций по голосовым командам или выражению лица несовершеннолетнего через веб-камеру и, выявив признаки беспокойства, стресса или гнева автоматически, ограничить доступ к определенному контенту, который является триггером в таком состоянии и предложить более спокойную и развивающую информацию [1].

2. Проактивное уведомление о подозрительном контенте – ИИ можно использовать как предупредительную меру для обеспечения кибербезопасности несовершеннолетнего. Можно обучить ИИ анализировать малоизвестные веб-сайты и приложения на предмет определения неподходящего контента (например, нецензурный текст, скрытые функции чатов, реклама взрослых товаров). Такая система может оповестить родителей о возможных угрозах до того, как ребенок начнет пользоваться этими ресурсами.

3. Контекстуальное понимание и анализ контента – вместо стандартного анализа ключевых слов ИИ может использовать естественную обработку языка (Natural Language Processing, NLP) для более четкого понимания контекста сообщений, которыми обмениваются несовершеннолетние [2]. Такой подход позволяет распознавать не только очевидный аддитивный контент, но и более тонкие его формы. Например, ИИ способен идентифицировать изолированный кибербуллинг, скрытые манипуляции и даже сложные стратегии социальной инженерии, которые традиционные методы фильтрации не могут обнаружить.

4. Микротаргетинг образовательного контента – при помощи искусственного интеллекта образовательные программы могут быть настроены на индивидуальные интересы и способности учащихся, обеспечивая персонализацию учебного процесса. Интерактивность и привлекательность обучения повышаются за счет адаптивных интерактивных курсов и развивающих игр, что способствует отвлечению внимания молодежи от нежелательной информации.

5. Геймификация цифровой безопасности – это разработка интерактивных игровых программ, направленных на дидактику детей в сфере определения и предотвращения интернет-рисков. Использование искусственного интеллекта позволяет адаптировать игровые процессы к индивидуальным и возрастным особенностям пользователя и предоставляет ему мгновенные комментарии по ходу обучения, направленные на освоение правильных стратегий поведения в цифровой среде.

6. Создание «зон безопасности» в сети Интернет – создание виртуального пространства, контролируемого искусственным интеллектом, в котором несовершеннолетние могут безопасно взаимодействовать между собой, при помощи ИИ автоматизируются процессы удаления и редактирования нежелательного контента и осуществляется мониторинг коммуникаций в целях предотвращения кибербуллинга и прочих онлайн-угроз.

7. Интеграция с платформами социальных сетей – ИИ может взаимодействовать с платформами социальных сетей, что дает возможность отслеживать и предотвращать появление вредоносного контента в режиме реального времени. До того как нежелательный контент становится доступным для несовершеннолетнего, система способна его устранить, блокируя передачу опасных сообщений, изображений или видео, а также уведомлять родителей о потенциальной опасности.

8. Использование технологий распознавания речи для мониторинга аудиоконтента – технологии распознавания речи могут быть использованы для фильтрации и блокирования аддитивного контента в подкастах и аудиокнигах.

Эти методы могут быть использованы для обеспечения цифровой безопасности несовершеннолетнего. Можно достичь значительного прогресса в достижении этой цели, эскалируя уровень защиты детей во время их пребывания в сети Интернет.

### **Заключение**

Применение искусственного интеллекта в целях повышения уровня защиты несовершеннолетних от негативного воздействия аддитивного контента – актуальная проблема. Современные информационные технологии уже демонстрируют потенциал для улучшения безопасности интернет-пространства. Несмотря на существующие трудности, разработка и внедрение усовершенствованных систем фильтрации предполагают междисциплинарный подход и постоянное совершенствование алгоритмов. Развитие технологий искусственного интеллекта открывает новые возможности обеспечения цифровой безопасности подрастающего поколения.

### **Библиографический список**

1. *Yifei Wang*. Transforming Translation: The Power of Context in NLP. URL: <https://dzone.com/articles/transforming-translation-the-power-of-context-in-n-1> (дата обращения: 02.08.2024).
2. *Reed Albergotti*. How advances in AI can make content moderation harder – and easier. URL: <https://www.semafor.com/article/10/27/2023/how-advances-in-ai-can-make-content-moderation-harder-and-easier> (дата обращения: 03.08.2024).

*Д. А. Булгаков*

старший преподаватель

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ИСПОЛЬЗОВАНИЕ УМНЫХ КОНТРАКТОВ В ЗАДАЧАХ ПО АУТЕНТИФИКАЦИИ ПОЛЬЗОВАТЕЛЕЙ

Умные контракты (или смарт-контракты) нашли широкое применение в таких децентрализованных приложениях (dApps) и службах, где необходимо добиться автоматизации действий без участия посредников. В их числе криптовалюты, различные финансовые и юридические сервисы, системы электронного голосования, а также игровые приложения. Однако свойства блокчейн-сетей позволяют использовать умные контракты для задач идентификации пользователей dApps и посетителей web3-сайтов. В статье описывается принцип работы механизма идентификации пользователей в блокчейн-сети (на примере Ethereum) и рассматривается вариант использования инфраструктуры блокчейна и умных контрактов для регистрации и аутентификации пользователей.

**Ключевые слова:** умный контракт, блокчейн, аутентификация, Ethereum, Solidity, web3.

*D. A. Bulgakov*

Senior Lecturer

St. Petersburg State University of Aerospace Instrumentation

## SMART CONTRACTS USAGE IN AUTHENTICATION TASKS

Smart contracts have found wide application in decentralized applications (dApps) and services where it is necessary to achieve actions automatization without intermediaries. These include cryptocurrencies, various financial and legal services, electronic voting systems, and gaming applications. However, the properties of blockchain networks allow using smart contracts for the tasks of identifying dApps users and web3 site visitors. This article describes the operation principle of a user identification mechanism in a blockchain network (using Ethereum as an example) and considers the option of using the blockchain infrastructure and smart contracts for registering and authenticating users.

**Keywords:** smart contract, blockchain, authentication, Ethereum, Solidity, web3.

### Факторы и проблемы аутентификации

Аутентификация – это процесс проверки подлинности идентификатора, предъявленного пользователем. Идентификатор в зависимости от своей природы относится к одной из четырех категорий, называемых факторами аутентификации [1]:

- 1) кто вы есть – отпечаток пальца, фото, скан сетчатки и другая биометрия;
- 2) где вы находитесь – анализ IP/MAC-адреса, сигнала мобильной сети и т. п.;
- 3) что вы знаете – знание пароля, PIN-кода или кодовой фразы (мнемоники);
- 4) чем вы владеете – наличие физического ключа или токена (USB-накопителя).

Рядовой пользователь в день использует десятки аккаунтов для доступа к различным сервисам. Механизм защиты от несанкционированного доступа к этим аккаунтам в основном базируется на аутентификации с помощью пароля и сравнивает пароль, введенный зарегистрированным пользователем, с записью в базе данных на сервере. Однако пользователям сложно запоминать множество комбинаций из логина/пароля, поэтому они часто используют одну и ту же комбинацию для доступа к различным ресурсам. Отсюда вытекает проблема, что при компрометации даже одного ресурса безопасность многих других аккаунтов пользователя также оказывается под угрозой. Например, по данным информационного портала SecurityLab, специализирующегося на вопросах защиты информации, в июле 2024 г. произошла крупнейшая в истории утечка паролей, от чего в руках злоумышленников оказался список из 10 млрд уникальных записей. Главное же преимущество аутентификации через блокчейн в том, что ресурс, к которому пользователь пытается получить доступ, не хранит никакой критически важной информации, поэтому даже утечка базы данных не даст злоумышленнику возможностей для атаки на пользователей. Рассмотрим подробнее, как работает идентификация в блокчейне.

### Идентификация в блокчейн-сети Ethereum

В блокчейн-сетях идентификация пользователя или узла происходит с помощью электронной подписи. Здесь нет привычных логина и пароля – вместо них для обозначения аккаунтов используются адреса. Если кратко, адрес – это последние 20 байт от хэшированного открытого ключа пользователя [2], к которым слева добавлены символы «0x». Невозможно восстановить открытый ключ пользователя из адреса.

Пример адреса: `0xE61Bcb10c3006E82a83f35a6E0185dAD8bd07746`.

В Ethereum аккаунты бывают двух типов: Externally Owned Account (EOA) – аккаунт пользователя и Contract Account (CA) – аккаунт контракта [3; 4]. Последний имеет связанный код, который выполняется на виртуальной машине Ethereum (EVM) при получении транзакции от EOA (т. е. от пользователя). Для создания аккаунта контракта необходимо опубликовать умный контракт в блокчейне.

Блокчейн Ethereum в силу имманентных свойств, таких как повсеместная доступность, неподменность и верифицируемость, оказывается прекрасно приспособлен для хранения идентификационных данных пользователей. Хэши открытых ключей хранятся в блокчейне, а для прохождения аутентификации (и подтверждения права владения адресом) пользователь подписывает сообщение своим секретным ключом с помощью алгоритма ECDSA. Таким образом, комбинация из открытого ключа и электронной подписи однозначно доказывает, что транзакцию совершил владелец секретного ключа и никто иной. Таким образом, адрес пользователя становится его уникальным идентификатором в публичном блокчейне [5].

Регистрация – это, по сути, запись в блокчейн информации, которая свяжет адрес пользователя с идентификатором и любыми другими данными, например хэшем пароля и никнеймом. Эту функцию выполняет смарт-контракт. Для прохождения авторизации на ресурсе (на сайте или в приложении) пользователь предъявляет свой адрес, а ресурс обращается к смарт-контракту, чтобы узнать, зарегистрирован данный пользователь или нет. Если пользователь зарегистрирован, ему предлагается подписать одноразовое сообщение своим секретным ключом. Ресурс проверяет подпись и выдает JWT-токен.

Популярным средством для подписания сообщений является расширение для браузера MetaMask. Его особенность в том, что секретные ключи хранятся локально в браузере и не передаются на серверы MetaMask или третьим лицам [6].

### Создание умного контракта в сети Ethereum

«Умный контракт» (или смарт-контракт) – это скрипт, скомпилированный EVM в байт-код и опубликованный в блокчейне. Умные контракты следуют логике «если... то» и гарантированно исполняются при достижении некоторого условия. Умные контракты устраняют необходимость в посредниках, а также исключают непредсказуемость и двусмысленность, из-за чего активно используются в финансовых и юридических сервисах, системах электронного голосования, а также в игровых приложениях. Работа умных контрактов в сети Ethereum построена на системе сообщений, которые описывают взаимодействия между контрактами внутри EVM.

Процесс создания и развертывания умного контракта включает несколько этапов.

1. **Установка необходимых инструментов.** Потребуется среда Node.js, редактор кода VS Code с установленным расширением для языка программирования Solidity и набор инструментов Hardhat, предназначенный для создания умных контрактов [7].

2. **Инициализация проекта.** Создать каталог проекта, установить и настроить Hardhat.

3. **Написание кода.** Код контракта начинается с декларирования версии компилятора, например `pragma solidity ^0.8.0;`. Затем объявляется сам контракт: `contract ContractName { }`

4. **Компиляция контракта.** При компиляции генерируется файл ABI (англ. Application Binary Interface «двоичный интерфейс приложения»), определяющий структуру данных, сигнатуры функций и типы аргументов для правильного взаимодействия с пользователем.

5. **Написание миграций.** Миграции нужны для развёртывания контракта в блокчейне.

6. **Тестирование.** Как правило, для тестирования умных контрактов используются библиотека утверждений JavaScript Chai и тестовый фреймворк Mocha.

7. **Развертывание.** Можно проводить как в эмуляторе блокчейна Hardhat Network, так и в реальных сетях EVM. Однако в последнем случае за размещение контракта придется заплатить комиссию основной криптовалютой выбранной сети (ETH для сети Ethereum).

Рассмотрим фрагмент кода умного контракта, позволяющего регистрировать пользователей. Создатель контракта автоматически регистрируется как первый пользователь.

```
struct User { // Структура пользователя
    bool isRegistered;
    uint256 regTime;
    string userName; // Дополнительно – имя пользователя
}
// Мapping адресов к структурам пользователей
mapping (address => User) users;
// Добавление пользователя
function registerUser(string memory _userName) public {
    require(!users[msg.sender].isRegistered, "User is already registered");
    users[msg.sender] = User({
        isRegistered: true,
        regTime: block.timestamp,
        userName: _userName
    });
    emit UserRegistered(msg.sender, _userName);
}
```

Структура User содержит данные, привязанные к адресу пользователя при помощи маппинга (хранилища вида ключ-значение). Для прохождения регистрации пользователь ресурса (например, сайта) вызывает публичную функцию registerUser. При помощи встроенной функции require проверяется, что адрес, вызывающий функцию, еще не зарегистрирован. Создается новая структура User, содержащая информацию о пользователе: статус регистрации, штамп времени блока и имя пользователя, и сохраняется в маппинге users по переменной msg.sender. Функция emit генерирует событие для «внешнего мира», т. е. ресурса вне блокчейна, содержащее адрес и имя пользователя. Сам по себе умный контракт не выполняет проверку подписей – этим занимается блокчейн Ethereum. Также умные контракты могут управлять списками доступа и разрешениями по ролям на уровне блокчейна, для чего похожим образом реализуются соответствующие функции [8; 9].

Процесс авторизации на сайте или в dApp на основе умного контракта выглядит так.

- Пользователь предъявляет адрес своего аккаунта блокчейн-сети.
- Сайт проверяет в блокчейне, зарегистрирован ли там этот адрес.
- Сайт предлагает пользователю подписать одноразовую строку (сообщение).
- Пользователь подписывает сообщение при помощи Metamask или другого провайдера и предоставляет сайту подпись.
- Сайт проверяет подпись и выдает пользователю JWT-токен.

Взаимодействие с умным контрактом происходит через фронтенд (например, со страницы сайта). При этом вызов функций контракта и генерация JWT-токена выполняются функциями JavaScript. Такой способ аутентификации защищен от утечек на стороне сервера и позволяет обойтись без привычной связки логин/пароль.

### Библиографический список

1. *Shah Y., Choyi V., Subramanian L.* Multi-factor Authentication as a Service // 3rd IEEE International Conference on MobileCloud. 2015. P. 144–150.
2. *Buterin V.* A next-generation smart contract and decentralized application platform. URL: <https://scholar.google.co.kr/citations?user=DLP9gTAAAAAJ&hl=en> (дата обращения: 26.07.2024).
3. Документация по разработке Ethereum. Аккаунты Ethereum // Ethereum. URL: <https://ethereum.org/ru/developers/docs/accounts/> (дата обращения: 26.07.2024).
4. База знаний для IT-специалистов. Адреса в Ethereum // Habr. URL: <https://habr.com/ru/articles/739958/> (дата обращения: 26.07.2024).
5. Self-Sovereign Identity + smart-contracts, дешево и сердито // // Habr. URL: <https://habr.com/ru/articles/564856/> (дата обращения: 26.07.2024).
6. *Алматов А. Н.* Аутентификация с использованием блокчейн в децентрализованных приложениях концепции WEB 3.0 // Технологии, модели и алгоритмы модернизации науки в современных геополитических условиях. Ч. 2. Уфа, 2022. С. 27–35.
7. Hardhat's tutorial for beginners // Hardhat. URL: <https://hardhat.org/tutorial#hardhat's-tutorial-for-beginners> (дата обращения: 26.07.2024).
8. *Cruz J. P., Kaji Y., Yanai N.* RBAC-SC: Role-based Access Control using Smart Contract // IEEE Access. 2018. P. 1-1.
9. *Kamboj P., Khare S., Pal S.* User authentication using Blockchain based smart contract in role-based access control // Peer-to-Peer Networking and Applications. 2021.

*Г. Е. Козелов\**

студент

*А. В. Афанасьева\**

старший преподаватель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## СОВРЕМЕННЫЕ МЕТОДЫ ЗАЩИТЫ НЕЙРОСЕТЕЙ ОТ СОСТЯЗАТЕЛЬНЫХ АТАК: ОБЗОР И СРАВНЕНИЕ

Нейронные сети и глубокое обучение революционизировали многие области, включая компьютерное зрение, обработку естественного языка, робототехнику и др. Однако с увеличением числа приложений машинного обучения выросли и угрозы, направленные против этих систем. Одна из наиболее опасных угроз – состязательные атаки, в которых злоумышленники намеренно изменяют входные данные, чтобы обмануть модель и вызвать неправильные прогнозы. Такие атаки могут привести к серьезным последствиям, особенно в критически важных системах, таких как медицинская диагностика, автономные транспортные средства и системы безопасности. Рассматриваются современные методы защиты нейросетей от состязательных атак, анализируются их преимущества и недостатки, а также обсуждаются направления будущих исследований.

**Ключевые слова:** нейронные сети, глубокое обучение, защита информации, компьютерное зрение, состязательные атаки.

*G. E. Kozelov\**

Student

*A. V. Afanasyeva\**

Senior Lecturer

\*St. Petersburg State University of Aerospace Instrumentation

## MODERN METHODS OF PROTECTING NEURAL NETWORKS FROM COMPETITIVE ATTACKS: REVIEW AND COMPARISON

Neural networks and deep learning have revolutionized many fields, including computer vision, natural language processing, robotics, and others. However, as the number of machine learning applications has increased, so have the threats to these systems. One of the most dangerous threats is competitive attacks, in which intruders intentionally alter input data to fool the model and cause incorrect predictions. Such attacks can have serious consequences, especially in critical systems such as medical diagnostics, autonomous vehicles and security systems. In this article, modern methods of protecting neural networks from competitive attacks are considered, their advantages and disadvantages are analyzed, as well as future research directions are discussed.

**Keywords:** neural networks, deep learning, information protection, computer vision, competitive attacks.

### Современные методы защиты

За последние годы исследователи предложили множество методов для защиты нейросетей от состязательных атак. Приведем некоторые из наиболее популярных и эффективных подходов.

#### 1. Состязательное обучение (Adversarial Training [1]).

*Описание.* Заключается в обучении модели с использованием состязательных примеров, чтобы повысить ее устойчивость к атакам. В этом методе модели представлены как обычные, так и специально измененные входные данные, чтобы она научилась различать их.

##### *Преимущества.*

- Повышает устойчивость к атакам, для которых были сгенерированы состязательные примеры.
- Эффективен против широкого спектра известных атак.

##### *Недостатки.*

– Требуется значительных вычислительных ресурсов, так как необходимо генерировать и обучаться на больших объемах состязательных примеров.

- Ограниченная эффективность против неизвестных или новых видов атак.

#### 2. Защитные ансамбли (Defensive Ensembles [2]).

*Описание.* Используется несколько моделей, которые объединяются в ансамбль. Идея заключается в том, что, если одна модель может быть скомпрометирована, другие помогут компенсировать это, предоставляя более точный результат.

##### *Преимущества.*

- Обеспечивает дополнительный уровень защиты благодаря разнообразию моделей.

– Снижает вероятность успеха атаки, так как злоумышленнику необходимо обмануть все модели в ансамбле.

*Недостатки.*

- Увеличивает вычислительные затраты и сложность системы.
- Может не защитить от атак, которые эффективны против всех моделей в ансамбле.

3. Предобучение и регуляризация (Pretraining and Regularization [3]).

*Описание.* Могут быть использованы для повышения устойчивости моделей к состязательным атакам. Регуляризация помогает предотвратить переобучение и делает модель более устойчивой к изменениям данных, в то время как предобучение позволяет модели учиться на более обширных и разнообразных данных.

*Преимущества.*

- Уменьшает вероятность переобучения и повышает обобщающую способность модели.
- Может быть эффективно использовано в сочетании с другими методами защиты.

*Недостатки.*

- Не обеспечивает полноценную защиту от целенаправленных атак.
- Требуется значительных ресурсов для обучения на больших наборах данных.

4. Защитная дистилляция (Defensive Distillation [4]).

*Описание.* Заключается в обучении модели так, чтобы она выдавала «мягкие» ответы (т. е. не категоричные, а распределенные вероятности), которые затем используются для обучения другой модели. Это делает модель менее подверженной малым изменениям во входных данных.

*Преимущества.*

- Уменьшает вероятность успеха некоторых видов атак, особенно в условиях белого ящика.
- Обученная модель становится более устойчива к небольшим изменениям во входных данных.

*Недостатки.*

- Ограниченная эффективность против мощных атак в условиях белого ящика.
- Может усложнить процесс обучения и снизить точность модели на обычных данных.

5. Прямое обнаружение и фильтрация атак (Adversarial Detection and Filtering [5]).

*Описание.* Фокусируется на обнаружении потенциально вредоносных входных данных перед тем, как они будут поданы на модель. Различные методы, такие как аномальное обнаружение и методы машинного обучения, используются для идентификации состязательных примеров.

*Преимущества.*

- Позволяет блокировать атаки до того, как они повлияют на модель.
- Может быть использован в сочетании с другими методами для улучшения защиты.

*Недостатки.*

- Высокий риск ложных срабатываний, что может привести к отказу в обслуживании для легитимных пользователей.
- Не всегда эффективен против сложных атак, которые имитируют легитимные данные.

*Сравнение методов защиты.* Каждый из рассмотренных методов имеет сильные и слабые стороны. Например, состязательное обучение эффективно для защиты от определенных типов атак, но требует значительных ресурсов и может быть неэффективным против неизвестных атак. Защитные ансамбли и предобучение могут обеспечить более широкую защиту, но также имеют ограничения в вычислительных ресурсах и сложности настройки. В таблице показано сравнение основных методов по ключевым характеристикам.

**Сравнение основных методов защиты по ключевым характеристикам**

Метод	Устойчивость к атакам	Вычислительная сложность	Применимость к различным атакам	Риск ложных срабатываний
Состязательное обучение	Высокая	Высокая	Узкая	Низкий
Защитные ансамбли	Средняя	Высокая	Широкая	Низкий
Предобучение и регуляризация	Средняя	Средняя	Узкая	Низкий
Дефенсивное шумоподавление	Средняя	Средняя	Узкая	Низкий
Обнаружение и фильтрация	Средняя	Средняя	Широкая	Высокий

### Заключение

Современные методы защиты нейросетей от состязательных атак разнообразны и предлагают различные подходы к решению этой важной проблемы. Однако не существует универсального метода, который обеспечивал бы полную защиту от всех возможных атак. Эффективная защита часто требует комбинации нескольких методов и их адаптации к конкретным случаям использования. В будущем потребуются дальнейшее развитие методов защиты и их интеграция с новыми технологиями для обеспечения надежной и устойчивой работы моделей машинного обучения в реальных приложениях.



### Библиографический список

1. Adversarial Training for Free! / A. Shafahi, M. Najibi, A. Ghiasi [et al.]. URL: <https://arxiv.org/pdf/1904.12843> (дата обращения: 20.06.2024).
2. Adversarial Example Defenses: Ensembles of Weak Defenses are not Strong / W. He, J. Wei, X. Chen [et al.]. URL: [https://nicholas.carlini.com/papers/2017\\_woot\\_ensembles.pdf](https://nicholas.carlini.com/papers/2017_woot_ensembles.pdf) (дата обращения: 20.06.2024).
3. Ross A. S., Doshi-Velez F. Improving the Adversarial Robustness and Interpretability of Deep Neural Networks by Regularizing their Input Gradients. URL: <https://arxiv.org/pdf/1711.09404> (дата обращения: 20.06.2024).
4. Papernot N., McDaniel P. On the Effectiveness of Defensive Distillation. URL: <https://arxiv.org/pdf/1607.05113> (дата обращения: 20.06.2024).
5. Adversarial Detection: Attacking Object Detection in Real Time / H. Wu, S. Yunas, S. Rowlands [et al.]. URL: <https://arxiv.org/pdf/2209.01962> (дата обращения: 20.06.2024).

*Г. Е. Козелов\**

студент

*С. В. Беззатеев\**

доктор технических наук, доцент – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ОСНОВНЫЕ АРХИТЕКТУРНЫЕ ПРИНЦИПЫ, ЗАЛОЖЕННЫЕ В ТЕЕ, ОРИЕНТИРОВАННЫЕ НА ИСПОЛЬЗОВАНИЕ В ИНТЕЛЛЕКТУАЛЬНЫХ ИНФОРМАЦИОННЫХ СИСТЕМАХ

Рассматриваются основные архитектурные принципы, заложенные в доверенные среды выполнения (ТЕЕ), и их значимость для интеллектуальных информационных систем (ИИС). Особое внимание уделено таким аспектам, как изоляция окружений, минимизация доверенной вычислительной базы (ТСВ), аппаратная поддержка безопасности, обеспечение конфиденциальности и целостности данных, управление криптографическими ключами, а также верификация и аттестация. Применение ТЕЕ в архитектуре ИИС существенно повышает их безопасность, обеспечивая защиту от внешних и внутренних угроз, что особенно актуально в условиях роста киберугроз.

**Ключевые слова:** доверенные среды выполнения, интеллектуальные информационные системы.

*G. E. Kozelov\**

Student

*S. V. Bezzateev\**

Dr. Sc., Tech., Associate Professor – Scientific Adviser

\*St. Petersburg State University of Aerospace Instrumentation

## BASIC ARCHITECTURAL PRINCIPLES OF TEE, ORIENTED TO USE IN INTELLIGENT INFORMATION SYSTEMS

The paper considers the main architectural principles embedded in trusted execution environments (TEE) and their relevance for intelligent information systems. Special attention is given to aspects such as isolation of the environment, minimization of the trusted database, hardware security support, ensuring confidentiality and integrity of data, cryptographic key management, and verification and certification. It is emphasized that the application of TEE in the architecture of IIS significantly increases their security, providing protection from external and internal threats, which is especially relevant in the context of growing cyber threats.

**Keywords:** trusted execution environments, intelligent information systems.

### Введение

Современные интеллектуальные информационные системы (ИИС) требуют высокой степени безопасности и защиты данных, особенно при обработке конфиденциальной информации. Одним из ключевых решений для обеспечения такой безопасности является использование технологии Trusted Execution Environment (ТЕЕ) – доверенной среды выполнения. ТЕЕ представляет собой изолированное вычислительное окружение, которое защищает код и данные от внешних угроз, таких как вредоносное ПО и несанкционированный доступ. Далее рассматриваются основные архитектурные принципы, заложенные в ТЕЕ, и их значение для ИИС.

### 1. Изоляция и доверенные окружения

Один из главных архитектурных принципов ТЕЕ – изоляция [1]. ТЕЕ обеспечивает защищенное выполнение приложений и хранения данных в изолированном окружении, которое отделено от основной операционной системы и других приложений. Эта изоляция достигается за счет аппаратных и программных механизмов, которые предотвращают утечки данных и атаки с использованием вредоносного программного обеспечения.

Изоляция также важна для предотвращения атак со стороны злонамеренных внутренних участников. Внутренние сотрудники или другие пользователи системы могут обладать значительными привилегиями, но не имеют доступа к защищенным данным, находящимся в ТЕЕ. Это гарантирует, что конфиденциальная информация будет защищена даже в случае компрометации основной системы.

### 2. Минимизация доверенной базы (ТСВ)

Другой важный принцип – минимизация доверенной вычислительной базы (Trusted Computing Base, ТСВ). ТСВ включает все компоненты системы, которым необходимо доверять для обеспечения безопасности. Чем меньше размер ТСВ, тем легче контролировать и обеспечивать его безопасность.

В контексте ТЕЕ минимизация ТСВ означает, что только критически важные компоненты и код выполняются в защищенной среде. Это снижает риск уязвимостей и упрощает аудит безопасности системы в целом [2].

В интеллектуальных информационных системах, где обрабатываются большие объемы данных и выполняются сложные вычисления, минимизация TCB помогает сократить число потенциальных точек возможных атак.

### 3. Аппаратная поддержка безопасности

TEE использует аппаратные механизмы для обеспечения безопасности, такие как защищенные процессоры, криптографические модули и изолированные области памяти. Эти аппаратные компоненты играют ключевую роль в защите данных и программного кода от внешних угроз.

Защищенные процессоры, такие как ARM TrustZone или Intel SGX, позволяют выполнять критически важные операции в изолированных окружениях, обеспечивая защиту от атак, направленных на основную операционную систему или другие приложения [1]. Кроме того, использование аппаратных криптографических модулей обеспечивает надежное шифрование данных и предотвращает их компрометацию.

### 4. Обеспечение конфиденциальности и целостности данных

TEE гарантирует конфиденциальность и целостность данных на протяжении всего их жизненного цикла – от обработки до хранения. Это особенно важно для ИИС, которые работают с чувствительными данными, такими как медицинская информация, финансовые данные или персональные данные пользователей.

Конфиденциальность достигается за счет изоляции данных внутри TEE и их шифрования. Даже если злоумышленник получает физический доступ к устройству, шифрованию данных и использованию аппаратных защитных механизмов, TEE предотвращает несанкционированный доступ [3]. Целостность данных обеспечивается за счет механизмов контроля и проверки целостности на уровне TEE, что предотвращает изменения данных без санкции системы.

### 5. Управление ключами и криптография

Также важная роль TEE заключается в управлении криптографическими ключами и выполнении криптографических операций. TEE обеспечивает надежное хранение ключей и защищенное выполнение криптографических алгоритмов, что необходимо для защиты данных в ИИС.

Ключи, используемые для шифрования данных, никогда не покидают пределы TEE, что предотвращает их компрометацию даже в случае взлома основной системы. Криптографические операции выполняются внутри TEE, что исключает возможность перехвата данных и реализацию атак на шифрование.

### 6. Верификация и аттестация

Для обеспечения доверия к системе TEE поддерживает механизмы верификации и аттестации [4]. Аттестация позволяет внешним субъектам проверять целостность и подлинность TEE перед началом взаимодействия. Этот процесс необходим для того, чтобы убедиться, что система не была скомпрометирована и может безопасно выполнять критически важные операции.

Верификация компонентов TEE, включая загрузочный программный код и операционную систему TEE, гарантирует, что они не были изменены злоумышленником. Это особенно важно для интеллектуальных информационных систем, где доверие к системе является ключевым фактором безопасности.

### Заключение

Архитектурные принципы, заложенные в TEE, играют важную роль в обеспечении безопасности интеллектуальных информационных систем. Изоляция, минимизация доверенной базы, использование аппаратных механизмов защиты, обеспечение конфиденциальности и целостности данных, управление ключами и криптография, а также механизмы верификации и аттестации – все эти принципы обеспечивают надежную защиту данных и кода от внешних и внутренних угроз. Внедрение TEE в архитектуру ИИС позволяет значительно повысить уровень безопасности и доверия к таким системам, что особенно важно в условиях постоянно растущих угроз кибербезопасности.

### Библиографический список

1. *Sommerhalder M.* Trusted Execution Environment. URL: [https://www.researchgate.net/publication/372793364\\_Trusted\\_Execution\\_Environment](https://www.researchgate.net/publication/372793364_Trusted_Execution_Environment) (дата обращения: 20.06.2024).
2. *Gallagher S.* Trusted Compute Base. URL: <https://learn.microsoft.com/en-us/azure/confidential-computing/trusted-compute-base> (дата обращения: 20.06.2024).
3. Trusted Execution Environments: Applications and Organizational Challenges / T. Geppert, S. Deml, D. Sturzenegger, N. Ebert. URL: <https://www.frontiersin.org/journals/computer-science/articles/10.3389/fcomp.2022.930741/full> (дата обращения: 20.06.2024).
4. TrustZone: доверенная ОС и ее приложения. URL: <https://habr.com/ru/companies/aladdinrd/articles/428311/> (дата обращения: 20.06.2024).

*Г. Е. Козелов\**

студент

*Д. И. Пекин\**

студент

*С. В. Беззатеев\**

доктор технических наук, доцент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ОПИСАНИЕ МЕТРИК КЛАССИФИКАЦИИ СОСТЯЗАТЕЛЬНЫХ АТАК НА МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ

Рассматриваются основные метрики, используемые для классификации состязательных атак на модели машинного обучения (МО). В условиях возрастающей важности безопасности МО-моделей состязательные атаки, при которых злоумышленники вводят незначительные искажения в данные, могут существенно снизить точность предсказаний моделей. Для анализа и классификации таких атак применяются специфические метрики, которые позволяют оценить их эффективность и влияние на модели. Подробно описаны метрики сходства, атакующей способности, цели атаки, используемых алгоритмов, а также область их применения. Представленные данные имеют существенное значение для глубокого понимания и разработки эффективных методов защиты МО-моделей.

**Ключевые слова:** машинное обучение, состязательные атаки, метрики, классификация.

*G. E. Kozelov\**

Student

*D. E. Pekin\**

Student

*S. V. Bezzateev\**

Dr. Sc., Tech., Associate Professor

\*St. Petersburg State University of Aerospace Instrumentation

## DESCRIPTION OF THE METRICS FOR CLASSIFICATION OF COMPETITIVE ATTACKS ON MACHINE LEARNING MODELS

The paper considers the main metrics used for classification of competitive attacks on machine learning (ML) models. With the increasing importance of ML security, adversarial attacks in which intruders introduce minor distortions to data can significantly reduce the accuracy of model predictions. Specific metrics are used to analyze and classify such attacks, which allow evaluating their effectiveness and impact on the model. The article describes in detail the metrics of similarity, attack power, attack targets, algorithms used and their field of application. The data presented are essential for a thorough understanding and development of effective methods of protection of ML-models.

**Keywords:** machine learning, competitive attacks, metrics, classification.

### Введение

В эпоху стремительного развития машинного обучения (МО) и искусственного интеллекта (ИИ) безопасность моделей становится одной из ключевых задач. Одним из серьезных вызовов являются состязательные атаки, когда злоумышленники, добавляя к данным незначительные на первый взгляд искажения, могут существенно снизить точность предсказаний моделей. Для классификации таких атак используются специфические метрики классификации. В этой статье рассмотрены основные метрики, применяемые для анализа результатов состязательных атак на модели машинного обучения, и предложена оценка их значения и особенности использования в различных контекстах.

### Метрики

Из-за широкого спектра состязательных атак не так просто выделить определенные метрики для классификации. В работе [1] приведен список атак, представленных в обобщенном виде в таблице. Соответственно, классификация атаки основана на нескольких метриках: метрика сходства, атакующая способность, цель, алгоритм, область применения.

### Метрика сходства

Метрика сходства (Similarity [2]) используется для измерения «близости» или «сходства» между оригинальным и объектом (например, изображением, текстом и т. д.), измененным после атаки. Эта метрика различается в зависимости от типа данных и типа атаки и часто используется для ограничения величины изменений, внесенных в исходные данные. В метрике сходства используются следующие параметры:

- $l_2$  – евклидова норма (или норма  $l_2$ ), используется для измерения расстояния между двумя векторами в пространстве, например двумя изображениями. Чем меньше  $l_2$ , тем ближе или более похожи два объекта;
- $l_\infty$  – максимальная норма (или норма  $l_\infty$ ) определяет наибольшую разницу между компонентами двух векторов. Часто используется в атаках, где важно ограничить максимальное изменение какого-либо пикселя;
- $l_0$  – количество ненулевых элементов, указывает на количество изменений (например, количество измененных пикселей или букв) в атакуемом объекте;
- общая вариативность (Total Variation) – параметр, который определяет суммарное изменение в пиксельных значениях изображения, что помогает в оценке того, насколько гладким или «натуральным» выглядит изображение после атаки;
- отдельные символы (letters) – параметр, определяющий изменение на уровне отдельных символов (например, в тексте);
- $l_p$  – обобщенная метрика  $l_p$ , которая может включать  $l_1$ ,  $l_2$ ,  $l_\infty$  или другие нормы в зависимости от задачи и атаки.

Рассмотрим более подробно параметры «распределение степеней» и «совместное возникновение».

### Метрика распределения степеней (Degree Distribution)

**Определение.** Распределение степеней описывает распределение степеней вершин в графе. Степень вершины – это количество ребер, соединяющих данную вершину с другими вершинами.

Значение метрики распределения степеней в состязательной атаке: в контексте атаки Zugner's, метрика помогает анализировать, как изменение расположения ребер в графе (например, их добавление или удаление) влияет на распределение степеней вершин. Эти изменения могут использоваться для создания уязвимостей в графе или для воздействия на обучение модели. Атака может целенаправленно изменять граф так, чтобы изменить распределение степеней для достижения желаемого влияния на модель.

### Классификация состязательных атак

Атака	Публикация	Метрика сходства	Атакующая способность	Цель	Алгоритм	Область применения
L-BFGS	(Szegedy et al., 2013)	$l_2$	Белый ящик	Целевая	Итеративный метод	Классификация изображений
FGSM	(Goodfellow et al., 2014b)	$l_\infty, l_2$	Белый ящик	Нецелевая	Одношаговый метод	Классификация изображений
Deepfool	(Moosavi-Dezfooli et al., 2016)	$l_2$	Белый ящик	Целевая	Итеративный метод	Классификация изображений
JSMA	(Papernot et al., 2016a)	$l_2$	Белый ящик	Целевая	Итеративный метод	Классификация изображений
BIM	(Kurakin et al., 2016a)	$l_\infty$	Белый ящик	Нецелевая	Итеративный метод	Классификация изображений
C & W	(Carlini & Wagner, 2017b)	$l_2$	Белый ящик	Целевая	Итеративный метод	Классификация изображений
Ground Truth	(Carlini et al., 2017)	$l_0$	Белый ящик	Целевая	SMT-решатель	Классификация изображений
Spatial	(Xiao et al., 2018b)	Общая вариативность	Белый ящик	Целевая	Итеративный метод	Классификация изображений
Universal	(Metzen et al., 2017b)	$l_\infty, l_2$	Белый ящик	Нецелевая	Итеративный метод	Классификация изображений
One-Pixel	(Su et al., 2019)	$l_0$	Белый ящик	Целевая	Итеративный метод	Классификация изображений
EAD	(Chen et al., 2018)	$l_1+l_2, l_2$	Белый ящик	Целевая	Итеративный метод	Классификация изображений
Substitute	(Papernot et al., 2017)	$l_p$	Черный ящик	Целевая	Итеративный метод	Классификация изображений
ZOO	(Chen et al., 2017)	$l_p$	Черный ящик	Нецелевая	Итеративный метод	Классификация изображений
Biggio	(Biggio et al., 2012)	$l_2$	Отравление данных	Нецелевая	Итеративный метод	Классификация изображений
Explanation	(Koh & Liang, 2017)	$l_p$	Отравление данных	Нецелевая	Итеративный метод	Классификация изображений

Атака	Публикация	Метрика сходства	Атакующая способность	Цель	Алгоритм	Область применения
Zugner'S	(Zugner et al., 2018)	Распределение степеней, совместное появление	Отравление данных	Целевая	Жадный алгоритм	Классификация узлов
Dai 's	(Dai et al., 2018)	Рёбра	Черный ящик	Целевая	Обучение с подкреплением	Классификация графов и узлов
Meta	(Ziigner & Ginnemann, 2019)	Рёбра	Черный ящик	Целевая	Обучение с подкреплением	Классификация узлов
C & W	(Carlini & Wagner, 2018)	Максимум dB	Белый ящик	Целевая	Итеративный метод	Распознавание речи
Word Embedding	(Miyato et al., 2016)	$l_p$	Белый ящик	Целевая	Одноступенчатый метод	Классификация текста
HotFlip	(Ebrahimi et al., 2017)	Отдельные символы	Белый ящик	Целевая	Жадный алгоритм	Классификация текста
Jia & Liang	(Jia & Liang, 2017)	Отдельные символы	Черный ящик		Жадный алгоритм	Понимание прочитанного
Face Recognition	(Sharif al., 2016)	Физический	Белый ящик	Целевая	Итеративный метод	Распознавание лиц
RL attack.	(Huang et al., 2017)	$l_p$	Белый ящик	Целевая	Обучение с подкреплением	Классификация текста

### Метрика совместного появления (Co-occurrence)

*Определение.* Метрика совместного появления определяет, как часто пары вершин (или ребра) встречаются вместе в графе. В контексте графов это может относиться к частоте совместного появления ребер или вершин в определенных частях графа.

Значение метрики совместного появления в состязательной атаке: в атаке Zugner's эта метрика может использоваться для анализа связей между вершинами и их частого или редкого совместного появления. Путем изменения структуры графа (например, добавления или удаления ребер) атака может целенаправленно воздействовать на частоту совпадения, чтобы ввести модель в заблуждение или ослабить ее производительность.

### Атакующая способность

Для параметра «атакующая способность» существуют три метрики:

- 1) белый ящик (White-box) – нападающий имеет полное знание о модели, включая ее архитектуру и параметры;
- 2) черный ящик (Black-box) – нападающий не имеет информации о модели;
- 3) отравление, отравление данных (Poisoning) – отравление обучающей выборки с целью неверного обучения модели либо для невозможности обучения модели, что вызовет отказ доступности.

*Цель.* Цель, или цель атаки, может быть разной даже для одного и того же алгоритма. Первоначально предполагается, что если атака «целевая», т. е. в результате атаки модель должна классифицировать объект как конкретный другой объект, то также эта атака способна и на «нецелевую» атаку, т. е. в результате атаки модель должна классифицировать объект как любой другой, отличающийся от истинного. Однако более четкая классификация атак по этому параметру позволяет яснее определить классификацию существующих состязательных атак.

### Алгоритм

1. Итеративный метод (Iterative) строит состязательные примеры с помощью последовательного применения небольших изменений к входным данным. В каждой итерации вносятся небольшие изменения, направленные на максимизацию ошибки модели.

**Пример:** Projected Gradient Descent (PGD [3]). Итеративно вносит изменения в входные данные в направлении градиента потерь модели, ограничивая шаги проекцией на допустимую область изменений.

### Преимущества.

- Обычно более эффективен при создании мощных атак по сравнению с одношаговыми методами.
- Может находить сложные уязвимости модели.

*Недостатки.* Могут потребоваться значительные вычислительные ресурсы.

2. Одношаговый метод (Single-Step) создает состязательные примеры путем однократного внесения изменений во входные данные. Эти изменения направлены на максимизацию ошибки модели на одном шаге.

**Пример:** Fast Gradient Sign Method (FGSM [4]). Добавляет к входным данным шум в направлении градиента потерь, умноженный на малый коэффициент.

Преимущества.

- Быстрый и вычислительно эффективный.
- Легко реализуется.

Недостатки.

- Может быть менее эффективен по сравнению с итеративными методами.
- Легче защититься с помощью методов повышения устойчивости модели.

3. SMT-решатель (SMT solver, Satisfiability Modulo Theories) используется для поиска состязательных примеров путем формулирования задачи в виде логической проблемы, которую нужно решить. Решатель ищет такой пример, который удовлетворяет определенным условиям и одновременно вызывает ошибку модели МО.

**Пример:** S3: SMT-based Satisfiability Solver for Security. Использует SMT-решатели для поиска уязвимостей в моделях.

Преимущества.

- Способен находить сложные и малозаметные уязвимости.
- Может гарантировать нахождение решения, если оно существует.

Недостатки.

- Может быть медленным и требовать значительных вычислительных ресурсов.
- Зависит от формулировки задачи.

4. Жадный алгоритм (Greedy) строит состязательные примеры с помощью последовательного внесения изменений в данные, стремясь максимизировать краткосрочную выгоду (ошибку модели МО) на каждом шаге.

**Пример:** Greedy Search. Вносит изменения в отдельные пиксели изображения, которые максимально увеличивают ошибку модели, на каждом шаге.

Преимущества.

- Простой и интуитивно понятный подход.
- Может быть эффективен в некоторых случаях.

Недостатки.

- Может застревать в локальных максимумах и не находить глобально оптимальные решения.
- Может быть медленным для высокоразмерных данных.

5. Обучение с подкреплением (RL, Reinforcement Learning) использует агента, который учится вносить изменения во входные данные через взаимодействие с моделью и получение обратной связи (награды) за создание состязательных примеров.

**Пример:** Adversarial Training with RL. Агент обучается вносить изменения во входные данные таким образом, чтобы максимизировать ошибку модели.

Преимущества.

- Способен обучаться сложным стратегиям атак.
- Может адаптироваться к различным моделям и задачам.

Недостатки.

- Обучение может быть медленным и требовать значительных вычислительных ресурсов.
- Сложность реализации и настройки.

## Область применения

Содержание этой метрики довольно очевидно, но есть пара значений, которые требуют дополнительных пояснений.

Классификация узлов (Node Classification) – это задача классификации, где каждый узел графа присваивается определенной метке или категории. Эта задача актуальна для различных типов графов, таких как социальные сети, сети знаний и молекулярные графы.

Примеры применения:

- социальные сети – определение типа пользователя (например, спамер или обычный пользователь) на основе его связей и активности;
- биологические сети – классификация белков по функциям на основе их взаимодействий с другими белками;
- рекомендательные системы – классификация элементов (например, товаров или пользователей) для персонализации рекомендаций.

Классификация графов (Graph Classification [5]) – это задача классификации, где целый граф присваивается определенной метке или категории. В отличие от классификации узлов, здесь классифицируются целые графы, что особенно важно в таких областях, как химия, биология и анализ социальных сетей.

Примеры применения:

- химия – классификация молекул по их токсичности или фармакологическим свойствам;
- биология – классификация биологических сетей (например, метаболических путей) по их функциям;
- анализ социальных сетей – классификация сообществ по их типам или активности.

Понимание текста (Reading Comprehension) – это задача обработки естественного языка (NLP), в которой модель должна понимать и интерпретировать текст для ответов на вопросы, извлечения информации или выполнения других заданий на основе текста.

Примеры применения:

- образование – автоматическая оценка ответов на вопросы по текстам учебников;
- виртуальные ассистенты – понимание и ответ на вопросы пользователей, основанные на тексте;
- медицинская информатика – извлечение и обобщение информации из медицинских документов.

### Заключение

Рассмотрены критически важные аспекты классификации состязательных атак на модели машинного обучения, при этом основное внимание акцентировано на значениях различных метрик для анализа и оценки таких атак. Выполненный обзор представленных метрик позволяет сказать, что, несмотря на разнообразие атак и методов их проведения, существует необходимость в тщательном анализе и выборе соответствующих метрик для эффективного противодействия возможным атакам на модели МО. Понимание и правильное применение данных метрик способствует повышению устойчивости моделей машинного обучения и улучшению их безопасности, что особенно актуально в свете растущей сложности и изощренности состязательных атак.

### Библиографический список

1. Adversarial Attacks and Defenses in Images, Graphs and Text: A Review / Han Xu, Yao Ma, Haochen Liu [et al.]. URL: [https://www.researchgate.net/publication/340235164\\_Adversarial\\_Attacks\\_and\\_Defenses\\_in\\_Images\\_Graphs\\_and\\_Text\\_A\\_Review](https://www.researchgate.net/publication/340235164_Adversarial_Attacks_and_Defenses_in_Images_Graphs_and_Text_A_Review) (дата обращения: 20.06.2024).
2. *Goodfellow I., Bengio Y., Courville A.* Deep Learning. URL: [https://vk.com/doc483377913\\_672501980?hash=1b9j47WIKa8pSI4LWICIZji-Kutc7U9wEpb0ULN3fkwo&dl=HWUTCsthgjkNyo1ehTeP1fzCQuFS0yegoTBb3xjYSwL](https://vk.com/doc483377913_672501980?hash=1b9j47WIKa8pSI4LWICIZji-Kutc7U9wEpb0ULN3fkwo&dl=HWUTCsthgjkNyo1ehTeP1fzCQuFS0yegoTBb3xjYSwL) (дата обращения: 20.06.2024).
3. Adversarial Attack for Evaluating and Enhancing Adversarial Defenses / G. Sriramanan, S. Addepalli, A. Baburaj [et al.]. URL: <https://proceedings.neurips.cc/paper/2020/file/ea3ed20b6b101a09085ef09c97da1597-Paper.pdf> (дата обращения: 20.06.2024).
4. *Sen J., Dasgupta S.* Adversarial Attacks on Image Classification Models – FGSM and Patch Attacks and their Impact. URL: <https://arxiv.org/pdf/2307.02055> (дата обращения: 20.06.2024).
5. Exploring graph classification techniques under low data constraints: a comprehensive study / K. Kothari, B. Mehta, R. Nambiar, S. Shrawne. URL: <https://arxiv.org/pdf/2311.12737> (дата обращения: 20.06.2024).



УДК 004.89

*Р. С. Кругляков\**

студент

*И. М. Семенов\**

студент

*Э. Э. Сохбатов\**

студент

*С. Г. Фомичева\**

кандидат технических наук, профессор – научный руководитель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ИССЛЕДОВАНИЕ РОБАСТНОСТИ ДЕТЕКТОРОВ ОБЪЕКТОВ СЕМЕЙСТВА YOLO НА УСТОЙЧИВОСТЬ К ШУМОВОЙ МОДИФИКАЦИИ ПАРАМЕТРОВ

Исследуется робастность детекторов объектов семейства YOLO к шумовым модификациям параметров. Рассматривается влияние изменений битов весовых коэффициентов на метрики качества моделей YOLOv8. Проведены эксперименты с методами изменения информации, позволяющие выявить критические биты для стабильной работы моделей.

**Ключевые слова:** робастность, YOLO, шумовые модификации, детекторы объектов, стабильность моделей.

*R. S. Kruglyakov\**

Student

*I. M. Semenov\**

Student

*E. E. Sokhbatov\**

Student

*S. G. Fomicheva\**

PhD, Tech., Professor – Scientific Adviser

\*St. Petersburg State University of Aerospace Instrumentation

## INVESTIGATION OF THE ROBOTS OF YOLO FAMILY OBJECTS FOR RESISTANCE TO NOISE MODIFICATION OF PARAMETERS

The paper investigates the robotics of detectors of YOLO family objects to noise modifications of parameters. The influence of the change in bit weight coefficients on YOLOv8 quality metrics is examined. Experiments were carried out with information modification methods, allowing to identify critical bits for stable models.

**Keywords:** robustness, YOLO, noise modifications, object detectors, model stability.

### Введение

Современные системы компьютерного зрения играют ключевую роль в широком спектре приложений – от автономного вождения до систем видеонаблюдения. Одним из наиболее успешных и широко используемых подходов к задаче детектирования объектов является семейство моделей YOLO (You Only Look Once). Эти модели демонстрируют высокую точность и скорость работы, что делает их привлекательными для реального применения.

Однако в условиях реального мира детекторы объектов сталкиваются с различными помехами и шумами, которые могут существенно влиять на их производительность, включая состязательные атаки [1; 2]. В частности, устойчивость моделей YOLO к шумовым модификациям параметров является важным аспектом для обеспечения надежности и безопасности таких систем. Изучение робастности (устойчивости) этих детекторов позволяет не только понять их слабые места, но и разработать методы для улучшения их устойчивости к шумам.

В данной статье приводятся результаты исследования робастности детекторов объектов семейства YOLO к шумовой модификации параметров. Для анализа робастности моделей YOLOv8 [3] был проведен ряд экспериментов.

1. Выявление значащих и критических битов в весах моделей.
2. Изменение нескольких бит информации в значащие битовые позиции весовых коэффициентов для установления зависимости влияния на метрики модели различными методами:
  - LSB;
  - Коха – Жао (дискретное косинусное преобразование);
  - Коха – Жао (вейвлет-преобразование).

## 1. Выявление значащих и критических битов в весах моделей YOLOv8

Для обнаружения значащих битов в весах моделей YOLOv8 был проведен эксперимент изменения одного конкретного бита информации каждого параметра YOLO-модели, являющегося весовыми коэффициентами нейрона полносвязного слоя детектора объектов. При использовании весовых коэффициентов в Python используется тип данных float, который представлен в 64-битном формате «двойной точности» в соответствии со стандартом IEEE 754. В данной статье принята обратная нумерация битовых позиций, в соответствии с которой 64-й бит является старшим, а 0-й – минимально значащий бит.

В результате данного эксперимента было установлено, что значащими битами весовых коэффициентов модели являются биты, начинающиеся с 29-й позиции. При этом метрики качества YOLO-модели, такие как Precision и Recall, резко деградируют, начиная с 48-го бита (рис. 1, 2).




Рис. 1. Деградация метрик Precision (слева) и Recall (справа) при изменении одного бита веса полносвязного слоя в YOLO-моделях

Как показано на рис. 1, все модели демонстрируют высокую устойчивость к изменению информации до 48-го бита, при этом изменение 49- и 50-го битов (для YOLOv8n, YOLOv8s, YOLOv8l) и 48- и 51-го (для YOLOv8m) вызывает заметное снижение их характеристик. Изменение в старшие биты или 50-й бит (для YOLOv8x) приводит к полному обнулению модели, что подчеркивает критическую важность этих позиций для сохранения функциональности.

## 2. Изменение нескольких бит информации методом LSB

После определения значимых битов было проведено экспериментальное исследование, в рамках которого изменялись несколько бит информации в весовых коэффициентах моделей YOLOv8 с целью выявления их воздействия на метрики качества детекторов объектов. Поскольку изменения в битах весовых коэффициентов с 29-го по 48-й не оказывают влияния на устойчивость моделей, эксперимент начат с 29-й битовой позиции. В ходе эксперимента количественно проведено изменение 20 бит информации методом LSB [4] с последующим увеличением до 23 бит в каждом весовом коэффициенте, чтобы оценить их воздействие на метрики эффективности моделей. Изменения битов информации (их инверсия) затронули все весовые коэффициенты моделей.

Обобщенные результаты изменения 20–23-го битов информации в веса YOLO-моделей приведены в табл. 1, графики метрик представлены на рис. 2. В табл. 1 приведено оптимальное количество бит для изменения в каждый вес моделей, при котором значительных изменений в характеристиках моделей не произошло.




Рис. 2. Динамика метрик Precision (слева) и Recall (справа) при изменении нескольких бит информации

Результаты изменения от 20 до 23 битов в весовых коэффициентах моделей

Модель	Битовые позиции для изменения	Максимальное количество битов на вес	Максимальный объем изменения, МБ	Объем изменения при обнулении характеристик качества
YOLOv8n	29–50	21	7,54	22 бита и более
YOLOv8s	29–50	21	27,9	22 бита и более
YOLOv8m	29–50	21	64,7	22 бита и более
YOLOv8l	29–50	21	109,2	22 бита и более
YOLOv8x	29–50	21	170,6	22 бита и более

### 3. Изменение нескольких бит информации методом Коха – Жао с дискретным косинусным преобразованием

Для внедрения информации методом Коха – Жао [5], который относится к методам частотной модификации, с использованием дискретного косинусного преобразования (ДКП) весовые коэффициенты были разделены на блоки по 16 весов, где в каждый блок был внедрен 1 бит информации. Внедрение происходило по 16 бит информации до момента обнуления метрик моделей. Обобщенные результаты внедрения битов информации в весовые коэффициенты моделей приведены в табл. 2, динамика метрик представлена на рис. 3. В данной таблице приведено оптимальное количество бит для внедрения в модели, при котором значительных изменений в характеристиках моделей не произошло. Внедрение происходило с шагом в 16 бит.




Рис. 3. Динамика метрик Precision (слева) и Recall (справа) при внедрении методом Коха – Жао с ДКП

Таблица 2

Результаты использования метода Коха – Жао с ДКП

Модель	Оптимальное объем внедрения в модель (бит)	Максимальный объем внедрения (бит)	Объем внедрения при обнулении характеристик качества
YOLOv8n	80	112	128 бит и более
YOLOv8s	752	768	784 бит и более
YOLOv8m	1024	1024	1040 бит и более
YOLOv8l	1120	1280	1840 бит и более
YOLOv8x	4000	4160	4320 бит и более

### 4. Изменение нескольких бит информации методом Коха – Жао с вейвлет-преобразованием

Алгоритм внедрения данных аналогичен алгоритму, используемому в методе Коха – Жао, с тем отличием, что вместо дискретного косинусного преобразования применяется вейвлет-преобразование [6]. Обобщенные результаты данного эксперимента приведены в табл. 4, а динамика метрик качества представлена на рис. 4. В табл. 2 приведено оптимальное количество бит для внедрения в YOLO-модели, при котором значительных изменений в характеристиках моделей не произошло. Внедрение происходило с шагом в 16 бит.

Результаты использования метода Коха – Жао с вейвлет-преобразованием Хаара

Модель	Оптимальное объем внедрения в модель (бит)	Максимальный объем внедрения (бит)	Объем внедрения при обнулении характеристик
YOLOv8n	128	144	160
YOLOv8s	528	528	544
YOLOv8m	1312	1584	1600
YOLOv8l	1104	1104	1120
YOLOv8x	2736	2736	3664




Рис. 4. Динамика метрик Precision (слева) и Recall (справа) при внедрении методом Коха – Жао с вейвлет-преобразованием

### 5. Предельные объемы возможных модификаций

По результатам сравнения методов модификации информации в модели YOLOv8, представленным в табл. 5, можно сделать следующие заключения. Метод LSB (Least Significant Bit) демонстрирует значительно большую емкость модификации по сравнению с методом Коха – Жао, достигая объемов до 7,54 МБ для модели YOLOv8n. Однако этот метод сопряжен с риском ухудшения характеристик модели при чрезмерном внесении изменений. Метод Коха – Жао и его вариация с использованием вейвлет-преобразования Хаара обеспечивают меньший объем модификации, но характеризуются более стабильным сохранением точности и устойчивости моделей. Это делает их предпочтительными для задач, где критична сохранность характеристик модели при внесении небольших изменений в данные.

Таблица 5

Сравнение методов изменения

Модель	Метод LSB, максимальный объем изменения, МБ	Метод Коха – Жао с ДКП, максимальный объем изменения, бит	Метод Коха – Жао (вейвлет-преобразование Хаара), максимальный объем изменения
YOLOv8n	7,54	112	144
YOLOv8s	27,9	768	528
YOLOv8m	64,7	1024	1584
YOLOv8l	109,2	1280	1104
YOLOv8x	170,6	4160	2736

Выбор метода должен основываться на конкретных требованиях задачи. Для задач, требующих высокой точности и устойчивости при внесении небольших изменений, рекомендуется использовать метод Коха – Жао. Для задач, где необходимо внести значительные изменения в информацию, метод LSB может быть более подходящим, но с учетом потенциального риска ухудшения характеристик модели.

## Заключение

В ходе проведенного исследования была изучена робастность моделей семейства YOLOv8 к шумовой модификации параметров. Результаты экспериментов показали, что модели демонстрируют высокую устойчивость к изменениям битовой информации до 48-го бита. Однако при изменении 49- и 50-го битов, а также старших битов наблюдается значительное снижение характеристик моделей, вплоть до полного их обнуления. Это подчеркивает важность данных битов для сохранения функциональности моделей.

Сравнение методов модификации информации показало, что метод LSB обладает большей емкостью для изменений, но сопряжен с риском ухудшения характеристик. Методы Коха – Жао с использованием дискретного косинусного преобразования и вейвлет-преобразования Хаара обеспечивают более стабильное сохранение характеристик при меньшем объеме изменений. Таким образом, выбор метода модификации должен основываться на конкретных задачах. Для обеспечения высокой точности и устойчивости моделей предпочтительно использовать методы Коха – Жао, в то время как для задач, требующих значительных изменений, может быть использован метод LSB с осторожностью.

## Библиографический список

1. Фомичева С. Г., Беззатеев С. В. Механизмы защиты моделей машинного обучения от состязательных атак // Т-Comm: Телекоммуникации и транспорт. 2023. Т. 17. № 10. С. 28–42.
2. Фомичева С. Г. Влияние ранжирования индикаторов атак на качество моделей машинного обучения в агентных системах непрерывной аутентификации // Т-Comm: Телекоммуникации и транспорт. 2023. Т. 17, № 8. С. 45–55
3. YOLOv8 – Ultralytics YOLO Docs. URL: <https://docs.ultralytics.com/ru/models/yolov8/> (дата обращения: 05.06.2024).
4. Image Steganography Using LSB and Hybrid Encryption Algorithms / M. Alanzy, R. Alomrani, B. Alqarni, S. Almutairi. 2023. URL: <https://www.mdpi.com/2076-3417/13/21/11771> (дата обращения: 10.06.2024).
5. Белим С. В., Вильховский Д. Э. Стегоанализ алгоритма Коха – Жао. URL: <https://cyberleninka.ru/article/n/steganoanaliz-algoritma-koха-zhao/viewer> (дата обращения: 14.06.2024).
6. Тхи Тху Чанг Буй, Спицын В. Г. Разложение цифровых изображений с помощью двумерного дискретного вейвлет-преобразования и быстрого преобразования Хаара. URL: <https://cyberleninka.ru/article/n/razlozhenie-tsifrovyyh-izobrazheniy-s-pomoschyu-dvumernogo-diskretnogo-veyvlet-vpreobrazovaniya-i-bystrogo-preobrazovaniya-haara> (дата обращения: 15.06.2024).

*А. Ф. Крячко\**

доктор технических наук, профессор

*А. И. Тюрина\**

ассистент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ПРОЦЕССЕ ПОВЫШЕНИЯ ОСВЕДОМЛЕННОСТИ ПЕРСОНАЛА ОРГАНИЗАЦИИ В ВОПРОСАХ ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТИ

Рассмотрены инструменты на основе искусственного интеллекта, которые позволяют ускорить подготовку материалов для мероприятий по повышению осведомленности персонала организации в вопросах информационной безопасности. Приведены статистика обучения по информационной безопасности и результаты антифишинговых кибертренировок в процентах от числа пользователей с использованием указанных технологий. Описанный пример показывает, что организация повышения осведомленности пользователей, выработка навыков противодействия фишингу возможны и при ограниченном бюджете.

**Ключевые слова:** искусственный интеллект, информационная безопасность, антифишинг.

*A. F. Kryachko\**

Dr. Sc., Tech., Professor

*A. I. Tyurina\**

Assistant

\*St. Petersburg State University of Aerospace Instrumentation

## USE OF ARTIFICIAL INTELLIGENCE IN THE PROCESS OF STAFF INFORMATION SECURITY AWARENESS RAISING

The paper considers artificial intelligence tools that can accelerate the preparation of materials for activities to raise awareness of information security among staff. The statistics of training on information security and results of conducting anti-phishing cyber-trainings in % of the number of users using these technologies are given. The example described shows that organization of awareness raising of users, development of skills to resist phishing is possible even with a limited budget.

**Keywords:** artificial intelligence, information security, antiphishing.

Компания IBM в своем отчете Cost of Data Breach Report 2023 указывает, что фишинг и скомпрометированные учетные записи стали самыми распространенными начальными векторами атак [1]. Средняя стоимость утечки данных в 2024 г. достигла рекордного уровня в 4,88 млн долл. США, что на 10% больше, чем в 2023 г., поскольку взломы становятся все более разрушительными, а также повышаются требования к киберкомандам [1].

Согласно отчету компании Positive Technologies за 4-й квартал 2023 г., 56% успешных атак на организации использовали методы социальной инженерии [2]. По этой причине, наряду с использованием различных средств защиты, построение результативной системы информационной безопасности в организации невозможно без внедрения процесса повышения осведомленности сотрудников.

Высокая важность этого процесса объясняется следующими причинами:

– ошибочные или злонамеренные действия работников являются одним из основных методов реализации кибератак;

– обучение работников компаний из некоторых отраслей является обязательным для обеспечения соответствия компании требованиям нормативных документов;

– грамотные действия работников позволят минимизировать как материальный, так и репутационный ущерб компании, возникающий при кибератаках.

Типовыми мероприятиями по повышению осведомленности пользователей организации являются:

1) предупредительные информационные рассылки по электронной почте о рисках и угрозах, изменениях законодательства, регулирующего вопросы ИБ, их влиянии на бизнес;

2) обучающие курсы, тренинги;

3) митапы;

4) киберучения (командно-штабные, антифишинговые тренировки, red teaming, тренировка на киберполигоне);

5) повышение квалификации;

6) листовки, плакаты, буклеты, тейблтенты по тематике информационной безопасности (ИБ).

Для ускорения подготовки материалов практически для всех упомянутых мероприятий, уменьшения рутинной работы, подготовки материалов, «заточенных» под конкретные целевые группы пользователей, целесообразно использовать возможности нейросетей [3–5]. В таблице приведен ряд инструментов, которые могут быть использованы для этой цели.

ИИ инструменты позволяют генерировать тексты на заданную тематику (п. 1–5 таблицы), изображения (слайды) для плакатов, презентаций (7–10), шаблоны и даже готовые презентации (12–15). Ряд инструментов позволяет генерировать курсы на основе роликов ютуб или pdf-файлов (инструменты 17–19).

**Ресурсы искусственного интеллекта для подготовки слайдов для презентаций для выступлений по тематике информационной безопасности, материалов для курсов по ИБ, подготовки контрольных вопросов**

№ п/п	Инструмент	Возможности
1	<a href="https://a.ya.ru/">https://a.ya.ru/</a>	Генерация Текста
2	<a href="https://developers.sber.ru/portal/products/gigachat">https://developers.sber.ru/portal/products/gigachat</a>	Генерация Текста
3	<a href="https://ask.chadgpt.ru/">https://ask.chadgpt.ru/</a>	Генерация Текста
4	<a href="https://chat-gpt.org/ru/chat">https://chat-gpt.org/ru/chat</a>	Генерация Текста
5	<a href="https://www.perplexity.ai/">https://www.perplexity.ai/</a>	Генерация Текста С Доступом В Интернет
6	<a href="https://www.gptforhr.com/#prompt-section">https://www.gptforhr.com/#prompt-section</a>	Коллекция Промптов
7	<a href="https://shedevrum.ai/">https://shedevrum.ai/</a>	Генерация Изображений В Приложении
8	<a href="https://fusionbrain.ai/">https://fusionbrain.ai/</a>	Генерация Изображений
9	<a href="https://www.midjourney.com/">https://www.midjourney.com/</a>	Генерация Изображений
10	<a href="https://creator.nightcafe.studio/">https://creator.nightcafe.studio/</a>	Генерация Изображений, Можно Поменять Деталь В Изображении После Генерации
11	<a href="https://www.logoai.com/">https://www.logoai.com/</a>	Генерация Лого
12	<a href="https://slidesgo.com/">https://slidesgo.com/</a>	Шаблоны И Генерация Презентаций Одним Промптом
13	<a href="https://slidesgpt.com/">https://slidesgpt.com/</a>	Генерация Презентаций Одним Промптом
14	<a href="https://drlambda.ai/">https://drlambda.ai/</a>	Генерация Презентаций Одним Промптом
15	<a href="https://www.magicslides.app/app">https://www.magicslides.app/app</a>	Генерация Презентаций Одним Промптом
16	<a href="https://hyperquiz.io/">https://hyperquiz.io/</a>	Генерация Тестов По Видео С Ютуба
17	<a href="https://learngpt.art/">https://learngpt.art/</a>	Генерация Учебника По Теме
18	<a href="https://app.courseau.co/sign-in">https://app.courseau.co/sign-in</a>	Генерация Курса Из Ютуб Или Pdf
19	<a href="https://learningstudioai.com/new/guided">https://learningstudioai.com/new/guided</a>	Генерация Курса Одним Промптом Или Из Файла
20	<a href="https://chattube.io/">https://chattube.io/</a>	Резюме Видео На Ютуб, Общение С Видео В Чате
21	<a href="http://chatpdf.com/">http://chatpdf.com/</a>	Чат С Pdf
22	<a href="https://beta.character.ai/">https://beta.character.ai/</a>	Создание Чат-Бота-Персонажа
23	<a href="https://smartbotpro.ru/">https://smartbotpro.ru/</a>	Создание Чат-Бота С AI
24	<a href="https://bot.writesonic.com/">https://bot.writesonic.com/</a>	Создание Чат-Бота С AI
25	<a href="https://voicebot.su/">https://voicebot.su/</a>	Перевод Голоса В Текст, Возможен Диалог С Несколькоими Голосами
26	<a href="https://elevenlabs.io/">https://elevenlabs.io/</a>	Перевод Голоса В Текст, Перевод Голоса В Другой Голос
27	<a href="https://soundraw.io/">https://soundraw.io/</a>	Создание Музыка По Описанию
28	<a href="https://www.suno.ai/">https://www.suno.ai/</a>	Создание Песни По Описанию
29	<a href="https://www.veed.io/">https://www.veed.io/</a>	Создание Говорящего Аватара, Работа С Видео
30	<a href="https://fusionbrain.ai/">https://fusionbrain.ai/</a>	Генерация Изображений И Коротких Видео
31	<a href="https://app.runwayml.com/">https://app.runwayml.com/</a>	Создание Коротких Видео, Изображений, Анимация Фото
32	<a href="https://downsub.com/">https://downsub.com/</a>	Выгрузка Текста Из Ролика Ютуб, Разделение По Голосам, Перевод На Другие Языки
33	<a href="https://vk.com/voice-tech">https://vk.com/voice-tech</a>	Перевод Аудио В Текст До 100 Мин
34	<a href="https://spechtotext.ru/home">https://spechtotext.ru/home</a>	Перевод Речи В Текст
35	<a href="https://300.ya.ru/summary">https://300.ya.ru/summary</a>	Резюме Видео На Ютуб, Тайм-Коды

При создании чат ботов пригодятся ресурсы 22–24 (см. таблицу). Незаменимыми инструментами могут стать ИИ-ресурсы при подготовке тезисов для презентаций, контрольных вопросов для курсов по информационной безопасности.


Конечно, полученные материалы требуют доработки с помощью «естественного» интеллекта. Однако они существенно могут сократить время подготовки материалов для нескольких целевых групп пользователей, варианты «тестовых» писем при проведении антифишинговых тренировок, адаптации (локализации) курсов по информационной безопасности под нужды конкретной компании.

Использование искусственного интеллекта позволяет поддерживать материалы для повышения осведомленности пользователей в вопросах обеспечения информационной и кибербезопасности в актуальном состоянии, создавать сценарии, заточенные под различные целевые группы пользователей организации, регулярно проводить киберучения, что позволяет снизить количество киберинцидентов, нагрузку на специалистов первой линии SOC (Security Operation Center).

Регулярные тренировки навыков кибербезопасности работников повышают осознанность и лояльность персонала. Сотрудники не отправляют рабочие документы на личную почту. Улучшаются вовлеченность работников и культура информационной безопасности в компании: люди чаще сообщают о подозрительных ситуациях. Сотрудник, который работает безопасно – лучшая защита компании!

На рисунке представлены результаты проведения в одной из промышленных компаний обучения основам информационной безопасности и проведения учебных атак (кибертренировок) в течение 20 недель.

На начальном этапе в ходе аудита информационной безопасности провокационное тестирование провалило почти 60% работников – пользователей корпоративной сети, прочитавших тестовое письмо. При этом работники были слабо вовлечены в процесс обеспечения информационной безопасности, только 18% сообщали в департамент информационной безопасности или департамент информационных технологий.



Статистика обучения по информационной безопасности и результаты проведения антифишинговых кибертренировок (в % от числа пользователей)

С целью исправления ситуации был разработан план корректирующих организационных и технических мероприятий. Прежде всего были закуплены и адаптированы несколько тематических курсов как по общим вопросам информационной безопасности, так и специфические курсы по антифишингу. Для адаптации и подготовки курсов был использован ряд инструментов ИИ, приведенных в таблице.

На рисунке зеленая кривая иллюстрирует процесс непрерывного обучения основам информационной безопасности, приемам противостояния социальной инженерии и фишингу. В течение 20 недель 95 % работников успешно прошли обязательный комплект из нескольких тематических курсов по противодействию фишингу и добровольно – курсы по личной безопасности, безопасному использованию социальных сетей и интернет-покупкам.

В качестве технических мероприятий в почтовой системе был реализован функционал, позволяющий путем нажатия одной кнопки отправить подозрительное письмо на проверку в департамент информационной безопасности, а также система «свой-чужой» – функционал, снабжающий каждое внешнее письмо ярким предупреждением о внешнем отправителе, к письмам от которых необходимо было относиться внимательнее.

Для выработки навыков безопасного поведения и оценки эффективности обучения в компании еженедельно проводились учебные атаки-кибертренировки на устойчивость персонала к фишингу для случайно выбранного ограниченного количества пользователей не из одного подразделения. Для подготовки сценариев, менявшихся один раз в декаду, привлекались нейросети.



Еще одна организационная мера, показавшая эффективность, – назначение призовых баллов в системе дистанционного обучения успешно прошедшим тренировку (не перешедшим по «вредоносной ссылке» и не открывшим «вредоносное» вложение и сообщившим о «подозрительном» письме в департамент информационной безопасности), которые можно было потом обменять на призы.

Уже через один месяц «индекс фиаско» уменьшился вдвое – до 18%, еще через месяц – еще на пять процентов, до 13%. Через три месяца необходимые курсы были пройдены 70% работников, а процент провала тренировок преодолел целевую отметку в 10% и составил 7%. Постоянно велась дополнительная работа с «провалившимися» кибертренировки, проводились предупредительные рассылки по электронной почте и корпоративному каналу в мессенджере. Через 5 месяцев «Траекторию «Антифишинг» (набор из нескольких курсов) прошли 90% работников. «Индекс фиаско» не превышал при этом 4–7%. В качестве дополнительных защитных мер для уменьшения площади атаки рассматривается вариант ограничения получения и отправки почты внешним корреспондентам, а также снабжение писем от всех внутренних служб предприятия с электронной подписью (красной виньеткой).

Описанный пример показывает, что организация повышения осведомленности пользователей, выработка навыков противодействия фишингу возможны и при ограниченном бюджете. Для этого могут быть использованы продукты с открытым кодом Gophish, King-phisher, Phishing-frenzy [6–8], бесплатные ресурсы ИИ [3–5], а также материалы из сети Интернет (материалы с сайта «Госуслуги» [9], «Киберзож» от Минцифры&RT Solar [10], материалы Google [11] и т. д.). Естественно, упомянутые ресурсы ИИ могут быть использованы для подготовки обучающих материалов не только по направлению информационной безопасности, но и по другим дисциплинам.

### Библиографический список

1. Актуальные киберугрозы: III квартал 2023 г. URL: <https://www.ptsecurity.com/ru-ru/research/analytics/cybersecurity-threatscape-2023-q3/> (дата обращения: 02.09.2024).
2. IBM: Cost of data breach report 2024. URL: <https://10guards.com/ru/articles/ibm-average-breach-costs-hit-record-4-88m-in-2024-up-10-from-last-year/> (дата обращения: 02.09.2024).
3. Бесплатные нейросети. Топ-15 лучших в 2024 г. URL: <https://digitalocean.ru/n/besplatnye-nejroseti> (дата обращения: 02.09.2024).
4. 45 классных и бесплатных нейросетей на все случаи жизни. URL: <https://journal.tinkoff.ru/short/ai-for-all/> (дата обращения: 02.09.2024).
5. 25 бесплатных нейросетей на все случаи жизни. URL: <https://journal.tinkoff.ru/short/ai-for-all/> (дата обращения: 02.09.2024).
6. Gophish // GitHub. URL: <https://github.com/gophish/gophish> (дата обращения: 02.09.2024).
7. King-phisher // GitHub. URL: <https://github.com/rsmusllp/king-phisher> (дата обращения: 02.09.2024).
8. Phishing-frenzy // GitHub. URL: <https://github.com/pentestgeek/phishing-frenzy> (дата обращения: 02.09.2024).
9. Госуслуги. URL: [https://www.gosuslugi.ru/life/details/dont\\_get\\_caught\\_phishing](https://www.gosuslugi.ru/life/details/dont_get_caught_phishing) (дата обращения: 02.09.2024).
10. Киберзож. URL: <https://киберзож.рф> (дата обращения: 02.09.2024).
11. Можете ли вы распознать фишинговую атаку? URL: <https://phishingquiz.withgoogle.com/?hl=ru> (дата обращения: 02.09.2024).

*А. Ф. Крячко\**

доктор технических наук, профессор

*А. И. Тюрина\**

ассистент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## РЕШЕНИЯ НА ОСНОВЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И ОБЕСПЕЧЕНИЕ КИБЕРБЕЗОПАСНОСТИ

Рассмотрены возможности применения технологий искусственного интеллекта для повышения уровня кибербезопасности. Отмечена необходимость разработки интегрированных систем, которые могут защитить данные и адаптироваться к эволюционирующим угрозам в реальном времени.

**Ключевые слова:** искусственный интеллект, информационная безопасность, кибербезопасность.

*A. F. Kryachko\**

Dr. Sc., Tech., Professor

*A. I. Tyurina\**

Assistant

\*St. Petersburg State University of Aerospace Instrumentation

## ARTIFICIAL INTELLIGENCE SOLUTIONS AND CYBERSECURITY

The paper considers the possibilities of using artificial intelligence (AI) technologies to increase the level of cybersecurity. There is a need to develop integrated systems that can protect data and adapt to evolving threats in real time.

**Keywords:** artificial intelligence, information security, cyber security.

Компания IBM в отчете Cost of Data Breach Report 2023 [1] указывает, что средняя стоимость утечки данных в текущем году выросла на 10% по сравнению с прошлым и достигла рекордного уровня в 4,88 млн \$. При этом организации, активно применяющие искусственный интеллект (ИИ) и автоматизацию в рабочих процессах по предупреждению киберинцидентов, сэкономили в среднем 2,2 млн долл. США на расходах, связанных с утечкой данных, по сравнению с организациями, которые не используют эти технологии [1; 2].

Элементы технологий ИИ в средствах защиты стали применяться с начала 1990-х гг. Пионерами в этой области были антивирусы.



Рис. 1. Сферы и объемы использования ИИ в сфере кибербезопасности

На рис. 1 приведены сферы применения ИИ в современных средствах защиты информации и системах обеспечения информационной безопасности по состоянию на настоящий момент [3]:

- системы обнаружения и реагирования на кибератаки (системы IPS, IDS);
- системы тестирования исходного кода программного обеспечения на наличие уязвимостей, ошибок и вредоносных (SAST и DAST);
- системы аутентификации и распознавания;
- антифрод-системы (борьба с мошенничеством, социальной инженерией и фишингом);
- управление событиями безопасности;
- защита конечных точек;
- анализ поведения пользователей и устройств;
- распознавание образов в системах видеонаблюдения;

- антивирусы;
- системы конкурентной разведки (интеллектуальный OSINT);
- предотвращение утечек данных;
- интегрированные системы.

### **Особенности применения технологий ИИ в системах обеспечения кибер- и информационной безопасности (ИБ)**

Рассмотрим подробнее некоторые аспекты применения нейросетей в ИБ. Более 71% специалистов по кибербезопасности полагают, что искусственный интеллект имеет решающее значение в борьбе с уязвимостями систем безопасности организации [4].

Одной из ключевых областей внедрения нейросетей в кибербезопасность является обнаружение вторжений и аномалий. Это может быть узловым моментом в реакции на потенциальные угрозы, и иногда нейросети помогают предотвратить вторжения на ранних этапах. Нейронные сети могут анализировать огромные массивы данных о предыдущих атаках. С помощью ИИ выявляются определенные шаблоны, на основе которых будут предотвращены будущие угрозы. Более того, в последнее время популярность набирают боты на базе искусственного интеллекта. Подобную технологию внедрили уже более 50% компаний по всему миру. ИИ-боты работают в режиме реального времени, сканируя сеть на предмет несанкционированного доступа и немедленно принимая меры по блокировке в случае обнаружения аномалий [5].

Нейросети уже проявили себя и в системах проверки кода (SAST, DAST) и поиске вредоносных программ. Они позволяют сканировать код и файлы на наличие злонамеренных компонентов [6]. Это особенно важно, учитывая разнообразие вредоносных программ и их постоянную эволюцию. Глубокое обучение, важная составляющая нейросетей, также играет свою роль. Оно позволяет создавать нейронные сети с множеством слоев, которые автоматически выявляют ключевые характеристики в данных. В результате можно на ранних стадиях обнаруживать уязвимости в системах [5].

В системах **аутентификации и распознавания** нейросети помогают создавать более безопасные методы входа в системы. Анализ голоса или лица может быть надежным способом удостовериться в подлинности пользователя [6].

Важный аспект – **мониторинг и анализ данных**. Большое количество информации можно обрабатывать с помощью нейросетей, что помогает выявить скрытые угрозы и аномалии в работе систем [7].

В рамках борьбы с **социальной инженерией и фишингом** ИИ позволяет анализировать тексты электронных писем и позволяет выявлять признаки мошенничества и атак, оберегая пользователей от потенциальных опасностей [7].

Нейросети способны выявлять **аномалии поведения пользователей** и сигнализировать «куда следует» о приговлении к несанкционированной передаче чувствительных для компании данных.

Незаменимы технологии ИИ в системах **антитифрода**. Компания HNC Software Inc. разработала ПО Falcon, позволяющее выявлять и предотвращать широкий спектр мошеннических операций с банковскими картами. Система Falcon использует технологию поддержки принятия решения, комбинирующую расширенную базу данных (БД) правил обработки транзакций, статистический анализ и искусственные нейронные сети (ИНС). Falcon, используя способность к классификации, обучается типичному поведению клиентов, отслеживает соотношения между операциями, обнаруживая подозрительные [4].

Семейство систем PRISM (компания Nestor) основано на использовании ИНС, экспертных систем и статистических методов для обнаружения мошенничества с кредитными и дебетовыми картами, а также при осуществлении финансовых или торговых сделок. ИНС была обучена на основе более чем полумиллиона транзакций с различными типами карт.

Фирмой Angoss разработано программное обеспечение KnowledgeSeeker для управления рисками и для идентификации злоумышленников, прогнозирующее с высокой долей вероятности задержки выплат по кредитам [4].

Особый интерес в целях обеспечения безопасности вызывают решения, связанные с **распознаванием образов в системах видеонаблюдения** [8]. Нейронные сети – мощный и на сегодня, пожалуй, наилучший метод для решения задач распознавания образов в ситуациях, когда отсутствуют значительные фрагменты информации, а имеющаяся информация предельно зашумлена. Так, ряд отечественных торговых и промышленных компаний используют отечественные же системы, позволяющие информировать службу безопасности при попытке входа на территорию граждан, ранее попадавших на кражах товаров или материальных ценностей, что существенно позволило снизить количество краж в магазинах и на предприятиях. Что характерно, использование зарубежных аналогов на этапе пилотирования было отвергнуто по причине «заточенности» этих систем на особенностях аномального поведения иностранных граждан, которое, как оказалось, существенно отличается от поведения местных мошенников ввиду культурно-бытовых особенностей. Детекторы фона распознают носимые предметы: сумки, чемоданы, коробки, рюкзаки и прочий багаж, – находят оставленные предметы и унесенные вещи, а также указывают их хозяев. Подобные системы могут осуществлять автоматический поиск угрожающих людям предметов, в том числе холодного и огнестрельного оружия в условиях толпы и плохого освещения, выявлять факты несанкционированного сбора информации путем фотографирования и видеозаписи смартфонами, фотоаппаратами и камерами, контролировать потенциально опасные места массового скопления людей, выявлять факты подготовки к дракам и криминальным «разборкам».

ИИ значительно позволяет экономить временные ресурсы при осуществлении мероприятий по конкурентной разведке (OSINT). Технологии ИИ позволяют избавиться от рутинной работы и сэкономить время и ресурсы при организации процессов повышения осведомленности пользователей в вопросах ИБ (подготовка слайдов для презентаций, писем для различных категорий персонала при проведении антифишинговых тренировок, тезисов для митапов и т. д.). ИИ может помочь при решении безопасником ежедневных громоздких задач, включая настройку средств защиты, написание скриптов и т. д.

### Проблемы и риски использования систем ИИ

Искусственный интеллект – это мощный инструмент, который не только борется с киберугрозами, но и становится орудием для их создания. Более 85% лидеров в области кибербезопасности заявляют, что мошенники все чаще пользуются уязвимостями в системах безопасности для взломов данных организаций и пользователей с помощью генеративного ИИ [9]. Внедрение искусственного интеллекта в сферу кибербезопасности становится актуальным, поскольку киберугрозы продолжают стремительно развиваться. Более 71% специалистов полагают, что нейросети будут активно использоваться для создания мощных атак как минимум в ближайшие три года. На рис. 2 приведены риски использования технологий искусственного интеллекта по данным компании Sario Research & Deep Instinct, 2023.



Рис. 2. Риски использования ИИ

Одна из основных угроз, которую представляют генеративные ИИ уже сейчас, – создание фейковых фотографий, видео- и аудиозаписей. Такие дипфейки, как правило, используются для фальсификации чьей-то личности и распространения недостоверной информации. Только за 2023 г. количество «поддельного контента» увеличилось более чем в 10 раз, а 70% людей не смогли с точностью определить подлинность сообщений. С помощью фальшивых материалов хакеры дискредитируют и шантажируют жертву: в результате подобных атак более 77% пользователей потерпели финансовые потери. Например, в феврале 2024 г. злоумышленникам удалось украсть 25,6 млн долл. после дипфейк-созвона. Они выбрали сотрудника, который обладает доступом ко всем счетам компании, и притворились финдиректором и владельцем компании для получения денег организации. Кроме того, ИИ применяются для распространения поддельных новостей, блогов и статей. За 2023 г. количество веб-сайтов, на которых размещаются ложные материалы, сгенерированные искусственным интеллектом, увеличилось более чем на 1000% [10]. Изначально такие мошеннические операции проводились хорошо скоординированной группой или организацией, однако сейчас нейросети позволяют генерировать фейковый контент практически любому человеку. Стремительно распространяющаяся дезинформация влечет хаос в сети, что особенно актуально в период насущных проблем, когда влияние на общественное мнение имеет большое значение.

Наравне с фейковыми новостями, популярность набирают поддельные сообщения, созданные с помощью ИИ. Только в России каждый день рассылается более 1 млн электронных писем с подозрительным или даже вредоносным содержанием. За 2023 г. фишинговые ИИ-рассылки обманным путем заставили 65% пользователей раскрыть личную информацию. Более того, 21% из получивших e-mail кликнули на вредоносную ссылку и дали злоумышленникам полный доступ к своему устройству, не подозревая об этом. В настоящий момент более 37% пользователей уверены, что ожидается скачок инновационных фишинговых атак, поэтому не стоит как-либо реагировать на попытку мошенников связаться с вами [11].

Искусственный интеллект представляет угрозу для защиты данных организаций. Нейросети используются для перебора паролей или для обхода методов аутентификации, давая злоумышленникам доступ к конфиденциальной информации самых различных организаций. Существуют специальные ИИ-программы, которые эффективны в 100% случаев, если учетная запись когда-либо «утекла». Всего за 60 с мошенники получают полный контроль над всеми материалами.

Генеративный искусственный интеллект способен обходить и биометрические методы аутентификации. С помощью нейросетей возможно обмануть идентификатор лица или создать фальшивые отпечатки пальцев. Например, считыватели отпечатков могут быть настроены с учетом различных уровней безопасности. При умеренных условиях фальшивые биометрические следы совпадали с 20% учетных записей на различных платформах. В среднем у такой технологии в 30 раз больше совпадений, чем у реального отпечатка, даже при самых высоких настройках безопасности [12].

Еще с начала 2000-х гг., когда не существовало биометрии, хакеры пользовались «лазейками» в системах безопасности для получения выгоды и перехвата важной информации, которая подвергает риску ваши финансы. С развитием технологий мошенники стали использовать совершенные методы кражи информации в диджитал-среде. Искусственный интеллект применяется в 95% случаев при атаке на банковские организации. Кибератаки на американские финансовые организации с использованием ИИ происходят каждые 39 с и обходятся владельцам банков в 6,9 млрд долл. ежегодно. Одним из примеров крупной ИИ-атаки является взлом банковского учреждения в Объединенных Арабских Эмиратах в 2022 г. Тогда злоумышленникам удалось украсть более 1 млрд долл. с помощью алгоритмов нейросети [13]. Этот инцидент вызвал обеспокоенность по поводу меняющегося характера киберпреступности и необходимости внедрять новые и более надежные способы защиты.

Чем еще может быть опасен ИИ? В настоящее время известно около 500 инцидентов, связанных с ИИ [14]. В настоящий момент ИИ уже способен выбирать цель и сценарий атаки самостоятельно. То же самое может касаться набора сканов или эксплойтов для пробива защиты сетей. В социальной инженерии боты уже в состоянии убедить человека сделать то, что требуется (назвать код из SMS, перевести сбережения на «безопасный счет»). ИИ очень быстро генерирует новые сущности, так быстро, что человек не в состоянии этого понять и осмыслить. Жизненный цикл генерации атакующих и защитных механизмов и понимания, что они неэффективны, может составлять секунды. Поэтому нужны методики, которые позволили бы контролировать этот процесс и использовать его себе на пользу. Задача защищающейся стороны состоит в создании алгоритмов, которые в полуавтоматическом режиме смогут также быстро обнаруживать эволюционирующие паттерны. Модель, давая абсолютно точный математический результат, может нарушить другие нормы – этические, нормы безопасности и пр. Корректные границы использования модели не в тех целях, для которых она была разработана и обучена, могут приводить к некорректным результатам.

Несомненно, нейронные сети – это инновационное решение проблем в кибербезопасности. Симбиоз генеративных ИИ и экспертов по информационной безопасности даст возможность создавать интегрированные системы защиты, которые смогут обнаруживать и реагировать на угрозы в реальном времени. Это позволит компаниям быть на шаг впереди мошенников и минимизировать потенциальные убытки. В настоящий момент более 50% организаций активно полагаются на инструменты кибербезопасности на основе нейросетей. К 2025 г. мировой рынок искусственного интеллекта в сфере кибербезопасности достигнет 38,2 млрд долл. [15]. В будущем ИИ может помочь в разработке более надежных систем безопасности, способных автоматически обнаруживать и предотвращать кибератаки. Последующее развитие искусственного интеллекта позволит компаниям улучшить обеспечение защиты информации и данных, что станет ключевым фактором успеха в современном цифровом мире.

#### Библиографический список

1. IBM: Cost of data breach report 2024. URL:<https://10guards.com/ru/articles/ibm-average-breach-costs-hit-record-4-88m-in-2024-up-10-from-last-year/> (дата обращения: 04.09.2024).
2. The rise of cybersecurity trends. URL: <https://cyberleninka.ru/article/n/rost-ugroz-kiberbezopasnosti/viewer> (дата обращения: 04.09.2024).
3. Ключевые области внимания на стыке искусственного интеллекта (ИИ) и кибербезопасности. URL: [https://ruscrypto.ru/resource/archive/rc2023/files/15\\_kotenko.pdf](https://ruscrypto.ru/resource/archive/rc2023/files/15_kotenko.pdf) (дата обращения: 04.09.2024).
4. Нейросетевые технологии в безопасности. URL: <https://digitalocean.ru/n/besplatnye-nejroseti> (дата обращения: 04.09.2024).
5. Нейронные сети в кибербезопасности. URL: <https://habr.com/ru/articles/587694/> (дата обращения: 04.09.2024).
6. Как нейросети борются с хакерами. URL: <https://rspectr.com/articles/kak-nejroseti-boryutsya-s-hakerami> (дата обращения: 04.09.2024).
7. Роль генеративных AI в сфере информационной безопасности. URL: <https://www.finam.ru/publications/item/rol-generativnykh-ai-v-sfere-informatsionnoy-bezopasnosti-20240422-1355/> (дата обращения: 04.09.2024).
8. Нейросети в системах безопасности и видеонаблюдения GOALcity. URL: <https://www.goal.ru/neuronet/> (дата обращения: 04.09.2024).
9. 85% of Cybersecurity Leaders Say Recent Attacks Powered by AI: Weekly Stat. URL: <https://www.cfo.com/news/cybersecurity-attacks-generative-ai-security-ransom/692176/> (дата обращения: 04.09.2024).
10. The rise of AI fake news is creating a ‘misinformation superspreader’. URL: <https://www.washingtonpost.com/technology/2023/12/17/ai-fake-news-misinformation/> (дата обращения: 04.09.2024).
11. Interaction with AI-written and human-generated phishing e-mails in European countries in March 2023. URL: <https://www.statista.com/statistics/1420881> (дата обращения: 04.09.2024).
12. Machine Learning Can Create Fake ‘Master Key’ Fingerprints. URL: <https://www.wired.com/story/deep-masterprints-fake-fingerprints-machine-learning/> (дата обращения: 04.09.2024).
13. Cybercriminals Utilizing AI Acquire Large Sum Of Money From UAE URL: Bankhttps. URL: <https://www.alvareztg.com/uae-bank-deepfake/> (дата обращения: 04.09.2024).
14. AI Incident Database. URL: <https://incidentdatabase.ai/> (дата обращения: 04.09.2024).
15. Применение методов искусственного интеллекта в задачах кибербезопасности. URL: <https://ruscrypto.ru/association/archive/rc2023.html> (дата обращения: 02.09.2024).

*В. А. Липатников\**

доктор технических наук, профессор

*А. А. Шевченко\**

кандидат технических наук

*К. В. Мелехов\**

адъюнкт

\*Военная академия связи им. Маршала Советского Союза С. М. Буденного, Санкт-Петербург, Россия

## МЕТОД ПОВЫШЕНИЯ КИБЕРБЕЗОПАСНОСТИ МАСШТАБИРУЕМОЙ КРИТИЧЕСКОЙ ИНФОРМАЦИОННОЙ ИНФРАСТРУКТУРЫ ПУТЕМ МНОГОУРОВНЕВОЙ ИНТЕЛЛЕКТУАЛЬНОЙ ОБРАБОТКИ ДАННЫХ ДЛЯ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ПО РЕАГИРОВАНИЮ НА ИНЦИДЕНТЫ БЕЗОПАСНОСТИ

На современном этапе развития цифровой среды масштабируемой критической информационной инфраструктуры угрозы в области кибербезопасности становятся максимально распространенными и более сложными. Появление временных диапазонов неработоспособности различных элементов информационной инфраструктуры, реализация которых осуществляется различными аппаратно-техническими средствами, требует совершенствования процессов поддержки принятия решений по реагированию на инциденты безопасности. Предлагается метод повышения кибербезопасности масштабируемой критической информационной инфраструктуры путем реализации машинного отражения действительности в понимании и моделировании процесса когнитивного мышления для поддержки принятия решений по реагированию на инциденты безопасности.

**Ключевые слова:** кибербезопасность, критическая информационная инфраструктура, интеллектуальная обработка информации, поддержка принятия решений, инциденты безопасности.

*V. A. Lipatnikov\**

Dr. Sc., Tech., Professor

*A. A. Shevchenko\**

PhD, Tech.

*K. V. Melekhov\**

Adjunct

\*Military Academy of the Signal Corps, S. M. Budyonny, St. Petersburg, Russia

## METHOD TO ENHANCE CYBERSECURITY OF SCALABLE CRITICAL INFORMATION INFRASTRUCTURE THROUGH MULTI-LEVEL INTELLIGENT DATA PROCESSING TO SUPPORT SECURITY INCIDENT RESPONSE DECISION-MAKING

In the current stage of digital development of scalable critical information infrastructure, cybersecurity threats are becoming more widespread and more complex. The emergence of non-working time ranges for various information infrastructure elements implemented by different hardware and technical means requires improved decision support processes to respond to security incidents. Proposed a method to enhance cybersecurity of scalable critical information infrastructure by implementing machine reflection of reality in understanding and modeling the process of cognitive thinking to support decision making for incident response security.

**Keywords:** cybersecurity, critical information infrastructure, intelligent processing of information, support for decision-making, security incidents.

Наличие специфических проблем кибербезопасности (КБ) масштабируемой критической информационной инфраструктуры (КИИ), связанных с совместимостью различных платформ и версий операционных систем, средств и технологий прикладного программного обеспечения, приводит к необходимости разработки решений по объединению этих технологий [1–3]. Это требует определенных усилий и ресурсов. Они должны включать: моделирование вероятных ситуаций, отработку надежных сценариев переходов и высокой квалификации специалистов.

Система поддержки принятия решений (СППР) может влиять на процесс принятия как организационных, так технических решений КБ за счет оперативности сбора и анализа большого количества данных. СППР рассматривается как «интерактивная автоматизированная система, которая помогает специалистам, принимающим решения, использовать данные и модели, чтобы решать неструктурированные проблемы» [4].

Анализ релевантных работ [5–8] последних лет свидетельствует о том, что, несмотря на интенсивные исследования в области разработки методов и систем обеспечения КБ, проблема остается чрезвычайно актуальной. Требуется разработка новых подходов к ее решению. Одним из них являются исследования в области методологии интеллектуального обеспечения процессами КБ. В настоящее время способность нейронных сетей (НС)

точно распознавать закономерности при кибервторжениях становится бесценным инструментом в стратегии противостояния киберпреступности.

Одним из ключевых преимуществ интеграции НС в КБ масштабируемой КИИ является расширение возможностей обнаружения и распознавания динамики атак. Традиционные системы КБ [9] часто полагаются на подходы, основанные на правилах. Они могут с трудом успевать за развивающимися тактиками, используемыми киберпреступниками. НС, с другой стороны, отлично выявляют сложные закономерности и аномалии в наборах данных. Это позволяет на ранней стадии обнаруживать и прогнозировать потенциально вредоносные действия.

Объект исследования – масштабируемая критическая информационная инфраструктура. Предмет исследования – расширение возможности многоуровневой интеллектуальной обработки данных при реализации машинного отражения действительности в понимании и моделировании процесса когнитивного мышления для поддержки принятия решений по реагированию на инциденты безопасности.

**Цель** исследования – повышение интеллектуальности обработки данных, улучшение распознавания, запоминания, формирования новых полезных данных и извлечения их из памяти сети для поддержки принятия решений по реагированию на инциденты безопасности. **Задача:** разработать метод повышения КБ масштабируемой критической информационной инфраструктуры путем многоуровневой интеллектуальной обработки данных с функциями отражения действительности для поддержки принятия решений по реагированию на инциденты безопасности.

Выбрано направление решения задачи – применение элементов искусственного интеллекта на основе нейронных сетей. НС широко применяются при разработке искусственного интеллекта (ИИ). Искусственные НС представляют собой сеть искусственных нейронов. Они объединены между собой синаптической связью [10]. Сеть обрабатывает поток входных данных и уже в зависимости от изменений своего состояния во времени формирует совокупность выходных сигналов. Основой служит рассмотрение простых однотипных объектов, соединенных в сложную и крупную сеть [11]. НС мозга является «стабильной» сетью. Она проявляет высокую устойчивость к помехам, отдельные сбои которой не оказывают влияния на результаты её функционирования [12]. При наличии сбоев и повреждений мозга его степень избыточности нервных клеток и межнейронных связей позволяет многовариантно изменять существующие конфигурации нейронных соединений. При этом обеспечивается требуемая надежность и устойчивость всей системы в целом.

Задача заключается в согласовании модели ИИ для обеспечения требуемых процессов, особенно в СППР [13]. Дополненная интеллектуальная модель со встроенной парадигмой когнитивных вычислений и отражение действительности могут быть одним из возможных подходов для преодоления текущих ограничений ИИ, а также продвижения исследований в области вычислений. Отражение действительности – это новый сдвиг парадигмы. Проблемы машинного отражения действительности заключаются в понимании и моделировании процесса когнитивного мышления людей. Рассматривается **система правил, норм, представлений и методов, которые определяют конкретную систему мышления или деятельности, она будет полезна для улучшения производительности приложений ИИ, которые включают человеческое познание.**

Отражение действительности путем проведения нейроморфных вычислений на основе цифровых нейронов, применяемых для повышения интеллектуальности обработки данных, улучшение распознавания как мышление позволяют получать знание о кибератаках, их свойствах и отношениях реального противоборства динамических распределенных киберсред. Они не могут быть непосредственно восприняты на чувственной ступени познания.

В основу модели положен требуемый набор функций свойств мозга:

- отображение внешнего и внутреннего мира;
- синтез случайной и детерминированной активности;
- композиция отражения действительности;
- формирование абстракций и целей;
- прогнозирование;

– оперативная, кратковременная и долговременная память для хранения абстракций разного уровня в виде совокупности знаний;

– обучаемость;

– автономное или управляемое из внешнего пространства мышление.

Исходный базис такого пространства состоит из компонентов закона отражения (отражаемый объект, отражающий объект, след), производный базис – из компонентов акта познания (объект, субъект, аспект, базис, след). Структура определяется причинно-следственной связью, полученной в составе рассматриваемой модели. Элементарные образы мышления в этом пространстве соответствуют в пассивном состоянии нульмерным, а в активном – одномерным симплексам.

В НС нульмерные симплексы реализуются структурами, аналогичными голограммам, но когерентными не во всем пространстве одновременно, а лишь в составе одномерных симплексов, представляющих акты отражения. При этом пространство мышления и знаний, реализуемое в НС, интерпретируется в виде самоорганизующейся многогранной сети. Известные понятия коннекционизма и двойственности функционирования в рассматриваемой модели приобретают неограниченную размерность и поэтому теряют свой первоначальный смысл. Распространенной наглядной моделью НС является пирамида, состоящая из отдельных слоев. Нижний слой извлекает признаки из входных данных, а каждый последующий – из того, что подается на его вход, все более абстрактные признаки. Анализ лучше всего исследованных систем мозга показывает, что в них существует широкое разнообразие иерархических структур, в которых имеются обратные связи [14; 15].

Средства вычислительной техники – это искусственная материальная среда. Она реализует пространство булевых функций. С их помощью пользователи по итогу кодируют знания и имитируют мышление. Нейроморфные процессоры, создаваемые на стыке биологии, физики, математики, информатики и полупроводникового производства, строятся из привычных транзисторов, но с иной организацией архитектуры, подобно строению нейронов биологического мозга. По аналогии с биологическим образцом искусственный нейрон имеет один выход (аксон), сигнал с которого может поступать на большое количество входов других нейронов и тем самым изменять их состояние. В живом мозге реальное мышление реализует не булево пространство, а множество актов отражения. Одно из решений механизма мышления заключается в конструировании математики, логических исчислений и прочих знаний из тех элементов, которые реализует мозг, т. е. из актов отражения.

Для этого необходимо создать пространство актов отражения с определенной структурой. Например, можно реализовать его в виде искусственной материальной среды (нейросети). Оно будет не кодировать знания, а отображать их тождественно живому мозгу. Соответственно, ранее пройденный путь с булевым пространством необходимо повторить на качественно ином уровне. Для этого закон отражения (отражаемый объект, отражающий объект, след) рассматривается как  $n$ -х мерный базис  $e_j$  ( $j = 1, 2, 3$ ) пространства описания материального мира и мозга в частности. Тогда мозг можно описать с помощью пространственно-временных координат и координат  $x_j$  в базисе  $e_j$ . Выбранный базис  $e_j$  уникален. Он отличается от базисных понятий математики и существующих логических исчислений. Его компоненты абстрактны, а соответствующие им координаты  $x_j$  как компоненты актов отражения конкретны.

Предполагаемая реализация модели в виде искусственного мозга и области их применения обусловлена. Это зависит от возможностей современных технологий по изготовлению электронных схем.

Таким образом, рассмотрена возможность использования многоуровневой интеллектуальной обработки данных в нейронных сетях с функциями отражения действительности для поддержки принятия решений по реагированию на инциденты кибербезопасности масштабируемой критической информационной инфраструктуры.

#### Библиографический список

1. Котенко И. В. Искусственный интеллект для кибербезопасности: новая стадия противоборства в киберпространстве // Искусственный интеллект и принятие решений. 2024. № 1. С. 3–19.
2. Velankar M. R., Mahalle P. N., Shinde G. R. Machine Thinking: New Paradigm Shift // Cognitive Computing for Machine Thinking. Innovations in Sustainable Technologies and Computing. 2024. P. 43–53.
3. Takano S. Thinking Machines. Machine Learning and Its Hardware Implementation. Academic Press, 2021. 306 p.
4. Патент RU2413304. Способ и устройство интеллектуальной обработки информации в нейронной сети / Осипов В. Ю., Осипова М. В. 2011.
5. Осипов В. Ю. Интеллектуальная нейросетевая машина с функциями мышления // Информатика и автоматизация. 2024. Т. 23, № 4. С. 1077–1109.
6. Патент RU2737227. Способ интеллектуальной многоуровневой обработки информации в нейронной сети / Осипов В. Ю. 2020.
7. Задбоев В. А., Липатников В. А., Мелехов К. В. Активная защита информационно-вычислительной сети от атак типа Advanced persistent threat // Актуальные проблемы инфотелекоммуникаций в науке и образовании: сб. науч. ст. XIII Междунар. науч.-техн. и науч.-метод. конф.: в 4 т. СПб., 2024. С. 347–351.
8. Липатников В. А., Мелехов К. В., Робак В. А. Моделирование процесса проактивного управления СПД в условиях киберугроз // Военная связь будущего. Квантовый скачок как неизбежность: сб. матер. Междунар. науч.-практ. конф. СПб., 2023. С. 90–95.
9. Подсистема предупреждения компьютерных атак на объекты критической информационной инфраструктуры: анализ функционирования и реализации / И. В. Котенко, И. Б., Сасенко, Р. И. Захарченко, Д. В. Величко // Вопросы кибербезопасности. 2023. № 1(53). С. 13–27.
10. Security assessment based on attack graphs using NVD and MITRE ATT & CK database for heterogeneous infrastructures / R. O. Kryukov, E. V. Fedorchenko, I. V. Kotenko [et al.] // Информационно-управляющие системы. 2024. № 2. С. 39–50.
11. Тьюринг А. Может ли машина мыслить? С приложением статьи Дж. фон Неймана «Общая и логическая теория автоматов» / пер. с англ. Ю. А. Данилова. М.: Физ.-мат. лит., 1960. 112 с.
12. Neural networks based on vectorized neurons / J. He, H. Yang, L. He, L. Zhao // Neurocomputing. 2021. Vol. 465. P. 63–70.
13. Котенко И. В. Интеллектуальные механизмы управления кибербезопасностью // Управление рисками и безопасностью: Труды Института системного анализа РАН. М.: УРСС, 2009. Т. 41. С. 74–103.
14. Липатников В. А., Мелехов К. В. Способ обработки результатов сетевого контроля при поддержке принятия решения администратора безопасности информации // Актуальные проблемы защиты и безопасности: тр. XXVII Всерос. науч.-практ. конф. СПб., 2024. С. 306–310.
15. Липатников В. А., Мелехов К. В., Лезков Н. А. Защита аутентификационных данных на объектах сети передачи данных // Транспорт России: проблемы и перспективы: матер. Междунар. науч.-практ. конф. / Ин-т проблем транспорта им. Н. С. Соломенко Рос. акад. наук. 2022. С. 221–225.



*Д. И. Пекин\**

студент

*А. В. Афанасьева\**

старший преподаватель

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## КЛАССИФИКАЦИЯ СОСТЯЗАТЕЛЬНЫХ АТАК НА ИНФОРМАЦИОННЫЕ СИСТЕМЫ И СРЕДСТВА

Представлена классификация состязательных атак, предложенная Национальным институтом стандартов и технологий США (NIST). Рассматриваются три ключевые цели атак: нарушение доступности, целостности и компрометация конфиденциальности данных. Анализируются методы, используемые злоумышленниками на различных стадиях жизненного цикла модели, включая этапы обучения и развертывания. Обсуждаются уровни осведомленности атакующих, такие как атаки «белого ящика» (полное знание о модели) и «черного ящика» (минимальная информация о модели), а также описываются специфические модальности данных, которые могут стать объектом атак.

**Ключевые слова:** состязательные атаки.

*D. I. Pekin\**

Student

*A. V. Afanasyeva\**

Senior Lecturer

\*St. Petersburg State University of Aerospace Instrumentation

## CLASSIFICATION OF COMPETITIVE ATTACKS ON INFORMATION SYSTEMS AND TOOLS

The study presents a classification of competitive attacks proposed by the US National Institute of Standards and Technology (NIST). Three key attack goals are considered: breach of availability, integrity and compromise of data confidentiality. Methods used by the intruders at different stages of the model's life cycle, including learning and deployment phases are analysed. The article discusses the levels of awareness of attackers, such as "white box" (full knowledge of the model) and "black box" (minimal information about the model), and describes specific data modalities that may be targeted by attacks.

**Keywords:** competitive attacks.

### Введение

Состязательное машинное обучение исследует уязвимости машинных моделей, которые злоумышленники могут использовать для манипуляции результатами их работы. Это направление стало актуальным с ростом применения машинного обучения в критически важных областях, таких как автономные транспортные средства, медицинская диагностика и финансовые технологии. Основным интересом представляет то, как модели могут быть обмануты или искажены с помощью специально сконструированных входных данных, называемых состязательными примерами. Важность понимания этих уязвимостей и разработки методов защиты от них неуклонно растет.

Статья [1] представляет собой важное исследование в области машинного обучения, особенно в контексте защиты моделей от злонамеренных вмешательств. В ней систематизированы знания о различных атаках на системы предсказательного искусственного интеллекта (PredAI), а также методы их смягчения. В данной работе представлена классификация типов атак, которые могут использовать злоумышленники для изменения поведения моделей или получения доступа к конфиденциальной информации.

### Значимость классификации атак

1. *Рост применения машинного обучения.* Машинное обучение все чаще используется в критически важных системах, таких как автономные транспортные средства и медицинская диагностика. Уязвимости в них могут привести к серьезным последствиям, и понимание того, как защитить их от атак, крайне важно.

2. *Систематизация знаний.* Безусловно, большое значение имеет четкая и всесторонняя классификация атак и методов защиты от них, что помогает специалистам по безопасности лучше понимать потенциальные угрозы и разрабатывать более эффективные стратегии защиты.

3. *Практическая значимость.* Понимание методов защиты от состязательных атак позволяет организациям и разработчикам машинного обучения улучшать устойчивость своих моделей к возможным атакам, что снижает риски их эксплуатации.

### Классификация атак

В статье NIST представлена классификация атак, которые могут быть направлены на системы предсказательного искусственного интеллекта. В этом контексте под атаками понимаются попытки злоумышленников изменить поведение модели или получить доступ к конфиденциальной информации.

## Основные цели атак

Злоумышленники могут преследовать три ключевые цели, каждая из которых требует определенных действий:

### 1. Нарушение доступности.

– *Цель*: сделать модель недоступной или неэффективной, чтобы она перестала выполнять свою основную функцию.

– *Методы*: злоумышленники могут использовать «отравление данных» (внедрение неправильных данных в модель) или изменять параметры модели, чтобы вызвать сбой в ее работе. Примеры таких атак включают **ZOO** и **Biggio**.

### 2. Нарушение целостности.

– *Цель*: заставить модель выдавать неправильные результаты.

– *Методы*: например, злоумышленник может изменить данные на этапе тестирования модели, чтобы модель делала ошибки. Также возможно отравление модели на этапе обучения, когда в нее внедряются данные, которые специально подготавливаются для нарушения ее работы. Примеры таких атак включают **FGSM (Fast Gradient Sign Method)**, **DeepFool**, **BIM (Basic Iterative Method)**, **C & W (Carlini & Wagner)**, **JSMA (Jacobian-based Saliency Map Attack)**, **Spatial Attack**, **One-Pixel Attack**, **EAD (Elastic-Net Attacks to DNNs)** и **HotFlip**.

### 3. Компрометация конфиденциальности.

– *Цель*: получить доступ к конфиденциальной информации, такой как данные, использованные для обучения модели, или к самой модели.

– *Методы*: например, злоумышленник может пытаться реконструировать данные обучения (узнать, какие данные использовались) или определить, была ли конкретная информация включена в обучающие данные модели. Примеры таких атак включают **Substitute Attack**, **Explanation Attack** и **Word Embedding Attack**.

## Способы достижения целей

Злоумышленники могут использовать различные возможности (средства), чтобы достичь своих целей. Вот основные из них.

1. *Контроль над данными для обучения*: злоумышленник может вставить или изменить обучающие данные, чтобы ввести модель в заблуждение. Это используется для «отравления» данных (data poisoning). Примером таких атак являются **Biggio** и **Zugner's Attack**.

2. *Контроль над моделью*: злоумышленник может изменить параметры модели, например внедрить вредоносный код. Это может произойти в процессе обновления модели, например в распределенных системах (федеративное обучение). Примером таких атак являются **Meta Attack** и **Dai's Attack**.

3. *Контроль над данными для тестирования*: здесь злоумышленник изменяет тестовые данные, чтобы обмануть модель и получить неправильные результаты. Это часто используется в атаках типа «уклонение» (evasion attacks), когда вводятся небольшие изменения, незаметные для человека, но сбивающие с толку модель. В качестве примеров таких атак можно указать **FGSM**, **DeepFool**, **JSMA**, **One-Pixel Attack**, **EAD** и **Spatial Attack**.

4. *Ограничение управления метками*: в некоторых атаках злоумышленники могут быть ограничены в возможности изменять метки данных (например, когда данные маркируются как «правильные» или «неправильные»). В таких случаях проводятся «чистые» атаки, где злоумышленник не меняет метки, но все равно пытается внести искажения. Примером является **FGSM**.

5. *Контроль над исходным кодом*: в этом случае злоумышленник вносит изменения в исходный код алгоритма, что может привести к уязвимостям в модели. Например, можно изменить генератор случайных чисел или внедрить вредоносный код в сторонние библиотеки.

6. *Доступ к запросам*: если злоумышленник не имеет прямого доступа к модели, он может использовать доступ к ее интерфейсу (например, через облачные сервисы) для отправки запросов и получения ответов. Это позволяет ему проводить атаки «черного ящика», когда о внутреннем устройстве модели ничего не известно, но ее можно обмануть через внешние взаимодействия. Примерами таких атак являются **Substitute Attack** и **ZOO**.

## Виды атак

Атаки на системы машинного обучения могут происходить на разных этапах жизненного цикла модели. Разделим их на два основных этапа: обучение и развертывание (использование).

### 1. Атаки на стадии обучения (Training-time attacks [4]).

– *Отравление данных (Data Poisoning)*: злоумышленник изменяет обучающие данные, чтобы модель начала делать ошибки. Это может происходить в любой методике обучения, но наиболее опасно в распределенных системах, где данные собираются от многих участников (федеративное обучение). Примерами таких атак являются **Biggio**, **Zugner's Attack** и **Meta Attack**.

– *Отравление модели (Model Poisoning)*: здесь изменяются параметры модели, чтобы внедрить в нее уязвимости или сбой. В качестве примера можно указать **Dai's Attack**.

### 2. Атаки на стадии развертывания (Deployment-time attacks [5]).

– *Атаки типа «уклонение» (Evasion Attacks)*: злоумышленник изменяет данные на входе модели так, чтобы она дала неправильный результат. Например, добавляются небольшие искажения, которые изменяют предсказание модели. Примерами являются **FGSM**, **DeepFool**, **BIM**, **JSMA**, **C & W**, **One-Pixel Attack**, **Universal Attack**, **HotFlip**, **Spatial Attack** и **Face Recognition Attack**.

– *Атаки на конфиденциальность (Privacy Attacks)*: злоумышленник пытается выяснить, какие данные использовались для обучения модели или извлечь информацию о самой модели, используя доступ к ее интерфейсу. Примерами можно назвать **Substitute Attack**, **ZOO** и **Explanation Attack**.

### Уровни знаний злоумышленника

Атаки также различаются по степени знаний злоумышленника о системе:

1. **Белый ящик (White-box attacks)**.

– *Описание*: злоумышленник обладает полной информацией о модели, включая данные обучения, архитектуру и параметры. Эти атаки позволяют тестировать систему на ее уязвимость в наихудших сценариях. Примеры таких атак включают **C & W**, **DeepFool** и **JSMA**.

2. **Черный ящик (Black-box attacks)**.

– *Описание*: злоумышленник практически ничего не знает о внутреннем устройстве модели, но может взаимодействовать с ней через запросы. Такие атаки наиболее практичны, так как не требуют доступа к внутренним данным системы. Примеры таких атак включают **ZOO**, **Substitute Attack** и **Universal Attack**.

3. **Серый ящик (Gray-box attacks)**.

– *Описание*: это промежуточный вариант, когда злоумышленник знает что-то о системе, но не все. Например, он может знать архитектуру модели, но не ее параметры, или иметь доступ к данным, похожим на те, что использовались для обучения. Примерами таких атак можно назвать **Meta Attack** и **EAD**.

### Модальности данных

Атаки могут быть направлены на модели, работающие с разными типами данных.

1. *Изображения*: например, атаки, добавляющие небольшие искажения, которые незаметны для глаза, но сбивают модель. Примеры включают **FGSM**, **DeepFool**, **One-Pixel Attack**, **Universal Attack** и **Spatial Attack**.

2. *Текст*: в обработке естественного языка (NLP) злоумышленники могут изменять текстовые данные для обмана модели. Примеры включают **HotFlip**, **Word Embedding Attack** и **Jia & Liang Attack**.

3. *Аудио и видео*: здесь применяются аналогичные методы для ввода модели в заблуждение. Примером служит **Face Recognition Attack**.

4. *Кибербезопасность*: данные могут включать сетевые и программные данные, на которые направлены атаки, чтобы обмануть системы обнаружения угроз. Примером является **RL Attack** (атаки на модели, обученные с подкреплением).

5. *Табличные данные*: используются в таких областях, как финансы и здравоохранение, и также подвержены атакам. Примеры включают такие атаки, как **EAD** и **Biggio**.

В последнее время появляется тенденция к использованию мультимодальных моделей, которые работают с несколькими типами данных одновременно (например, изображения и текст). Такие модели могут быть более устойчивыми к атакам, но и сами подвержены новым видам угроз.

### Заключение

В работе [1] описываются способы, с помощью которых злоумышленники могут атаковать системы машинного обучения, их цели и возможности. Знание этих аспектов позволяет лучше защищать модели ИИ и предсказательные системы от различных видов атак. Разработка методов защиты и повышение осведомленности о возможных угрозах остаются приоритетными задачами в быстро развивающейся области машинного обучения. Интеграция конкретных атак, таких как **FGSM**, **DeepFool**, **C & W** и др., в классификацию помогает понять, как они вписываются в общую картину угроз и как их можно эффективно предотвратить.

### Библиографический список

1. Adversarial Machine Learning: A Taxonomy and Terminology of Attacks and Mitigations / A. Vassilev, A. Oprea, A. Fordyce, H. Anderson. 2024. URL: <https://csrc.nist.gov/pubs/ai/100/2/e2023/final> (дата обращения: 21.07.2024).

2. Li H., Namiot D. A Survey of Adversarial Attacks and Defenses for image data on Deep Learning. 2022. URL: <https://cyberleninka.ru/article/n/a-survey-of-adversarial-attacks-and-defenses-for-image-data-on-deep-learning#:~:text=B.%20Classification%20of%20Adversarial%20Attack,the%20set%20used%20for%20training> (дата обращения: 21.07.2024).

3. 2020. Adversarial Attacks and Defenses in Images, Graphs and Text / H. Xu, H. Liu, Y. Ma, D. Deb. 2020. URL: [https://www.researchgate.net/publication/340235164\\_Adversarial\\_Attacks\\_and\\_Defenses\\_in\\_Images\\_Graphs\\_and\\_Text\\_A\\_Review](https://www.researchgate.net/publication/340235164_Adversarial_Attacks_and_Defenses_in_Images_Graphs_and_Text_A_Review) (дата обращения: 21.07.2024).

4. Training-Time Attacks against k-Nearest Neighbors / A. Vartanian, W. Rosenbaum, S. A. Vartanian [et al.]. URL: <https://arxiv.org/abs/2208.07272> (дата обращения: 21.07.2024).

5. 2023. Adversarial Machine Learning: A Systematic Survey of Backdoor Attack, Weight Attack and Adversarial Example / B. Wu, L. Liu, Z. Zhu [et al.]. URL: <https://arxiv.org/pdf/2302.09457v1> (дата обращения: 21.07.2024).

*Т. В. Тимочкина\**

ассистент

*В. А. Миклуш\**

кандидат технических наук, доцент

\*Санкт-Петербургский государственный университет аэрокосмического приборостроения

## АНАЛИЗ СОБЫТИЙ БЕЗОПАСНОСТИ С ПОМОЩЬЮ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Проведен обзор событий информационной безопасности и возможностей технологий искусственного интеллекта (ИИ) в реагировании на события информационной безопасности. Рассмотрены возможности технологий ИИ, способствующие повышению эффективности выявления незарегистрированных угроз безопасности, скорости анализа и обнаружения попыток компрометации данных на конечных устройствах и в приложениях.

**Ключевые слова:** информационная система, события безопасности, искусственный интеллект, угроза.

*T. V. Timochkina\**

Assistant

*V. A. Miklush\**

PhD, Tech., Associate Professor

\*St. Petersburg State University of Aerospace Instrumentation

## SECURITY EVENT ANALYSIS USING ARTIFICIAL INTELLIGENCE

The paper provides an overview of information security events and the capabilities of artificial intelligence technologies in responding to information security events. The possibilities of AI technologies that contribute to improving the effectiveness of detecting unregistered security threats, the speed of analysis and detection of attempts to compromise data on end devices and in applications are considered.

**Keywords:** information system, security events, artificial intelligence, threat.

В настоящее время решения, использующие искусственный интеллект (ИИ), активно применяются в информационной безопасности, и со временем его значение только растет. ИИ особенно хорошо справляется со сбором и анализом огромных объемов данных, извлечением ценной информации и соответствующим реагированием. Эти возможности значительно повышают возможность обнаружения и реагирования на угрозы безопасности, в итоге минимизируют потенциальный ущерб, наносимый злоумышленниками.

В информационной системе (ИС) регистрации подлежат следующие события [1]:

– вход/выход в ИС, попытки загрузки и (или) остановки операционной системы;

– подключение носителей информации и вывод информации на них;

– запуск/завершение программ и процессов (заданий, задач), связанных с обработкой защищаемой информации;

– попытки доступа программных средств к защищаемым объектам (техническим средствам, узлам сети, линиям (каналам) связи, внешним устройствам, программам, томам, каталогам, файлам, записям, полям записей) и иным объектам доступа;

– попытки удаленного доступа.

События безопасности могут быть зарегистрированы следующими составными частями информационной (автоматизированной) системы:

– средствами защиты информации (СЗИ);

– средствами обеспечения безопасности информационных технологий;

– иными программно-техническими средствами, а также программным обеспечением (ПО), применяемыми в информационных и/или автоматизированных системах.

СЗИ регистрируют события безопасности в соответствии с реализованными в них функциями безопасности.

Средства обеспечения безопасности информационных технологий и иные программно-технические средства, в том числе ПО, применяемые в информационных (автоматизированных) системах, регистрируют события безопасности, связанные с выполняемыми ими мерами защиты.

При необходимости зарегистрированная информация о событиях безопасности может быть передана в средства автоматизации мониторинга информационной безопасности. Для этого средства, осуществляющие регистрацию событий безопасности, должны обеспечивать предоставление доступа к информации о зарегистрированных событиях безопасности и (или) передавать сведения о событиях безопасности в средства автоматизации мониторинга информационной безопасности.

Для создания защищенных ИС используются СЗИ, которые должны обеспечивать [2; 3]:

– конфиденциальность информационных ресурсов (защита от несанкционированного доступа к ним);

- целостность информации и предотвращение несанкционированных изменений данных (контроль устройств, подключаемых к компьютеру);
- доступность (обнаружение вторжений в информационные системы и межсетевое экранирование сетевого трафика для обеспечения непрерывного функционирования);
- надежность (антивирусная защита для предотвращения воздействия вредоносных программ);
- управление доступом (авторизация сетевых соединений для ограничения доступа к ресурсам только уполномоченным пользователям).

Основные задачи, которые может выполнять ИИ: обнаружение, прогнозирование, автоматизация, ответное реагирование и адаптация на основе полученных ранее результатов [4].

ИИ может решать большой объем задач информационной безопасности и в перспективе этот список будет только увеличиваться.

Чтобы противодействовать возрастающему объему угроз информационной безопасности, идет активное внедрение технологии ИИ в разрабатываемые системы защиты информации, машинного и глубокого обучения. Это дает возможность в режиме реального времени осуществлять обнаружение и прогнозирование угроз безопасности и реагирования на них.

Разрабатываемые системы с использованием технологий поведенческого и предиктивного анализа, можно классифицировать по функциональному и технологическому типу и по сценариям применения.

*SIEM (Security Information and Event Management).*

Системы SIEM предназначены для сбора и обработки больших объемов данных из различных источников (журналы хостов, ИС, баз данных, сетевых устройств, базы данных, ИТ-сервисы, инфраструктура, база данных сетевых устройств, приложения и т. д.). Они позволяют выявлять потенциальные инциденты, основываясь на логике предполагаемого злоумышленника. На основе получаемых данных осуществляется непрерывный анализ событий безопасности, который позволяет обнаруживать инциденты в сфере информационной безопасности. При интеграции с ИИ выявляет аномалии и минимизирует ложные срабатывания, отслеживает изменения в модулях и паттернах данных.

*SOAR (Security Orchestration and Automated Response).*

SOAR-системы используются для обнаружения угроз информационной безопасности и автоматизации процесса противодействия угрозе. Применение ИИ в этих системах позволяет не только проводить анализ угроз, но и осуществлять противодействие для нейтрализации выявленных угроз. В отличие от SIEM, SOAR-системы используются для автоматизации и рассчитаны на координацию и управление работой нескольких различных систем информационной безопасности.

*TIP (Threat Intelligence Platform).*

Платформы обнаружения и реагирования на угрозы. Системы, основанные на анализе обширных массивов данных (Data Lake) и индикаторов компрометации (IoC), таких как вредоносные домены, IP-адреса, ссылки и хеш-суммы файлов. Платформа дает возможность подключения нескольких источников, фидов, обычно одного типа, и сравнения их по разным параметрам. Например, выявить пересечения индикаторов в разных фидах, что позволяет обнаруживать дублирующие потоки и, возможно, отказаться от некоторых из них. Платформа TIP в режиме реального времени позволяет фильтровать и выгружать индикаторы, сортировать инциденты, представлять их в графическом интерфейсе для удобства аналитика и многое другое. Платформа TIP устанавливается во внутренней сети компании, осуществляет процесс анализа и сопоставления поступающих данных, что значительно снижает рабочую нагрузку на SIEM-систему. Она позволяет генерировать собственные оповещения при обнаружении угроз и через программный интерфейс приложения (API) интегрируется с уже существующими процессами мониторинга и реагирования. Применение технологий ИИ позволяет TIP-платформам эффективно выявлять угрозы на ранних стадиях.

*EDR (Endpoint Detection and Response).*

Системы обнаружения и реагирования на угрозы конечной точки. Это платформы, предназначенные для обнаружения атак на рабочие станции, серверы и иные вычислительные устройства, а также оперативного реагирования на них. Принятие решений в EDR-системах основано на возможностях традиционных решений безопасности, помогает с проблемами отсутствия: обнаружения угроз после взлома и возможности глубокого обзора и анализа. Эти проблемы решаются благодаря мониторингу всех действий конечных точек для обнаружения: целевых и сложных угроз, горизонтального перемещения в сети, использования краденых учетных данных, инсайдерской активности и иных аномальных действий со стороны злоумышленников.

Решения EDR предлагают важные преимущества:

- непрерывный мониторинг широкого диапазона конечных устройств в корпоративных сетях и за их пределами;
- использование искусственного интеллекта;
- запись огромных объемов активности в сети;
- интеграция с расширенными функциями;
- включение упреждающего поиска индикаторов атаки;
- расширенные возможности анализа;
- исправление последствий осуществленных атак;
- создание детализированных политик для обработки USB-устройств;
- включение защиты для удаленных сотрудников.

#### *NDR (Network Detection and Response).*

Системы анализа сетевого трафика, предназначенные для обнаружения сетевых угроз и реагирования на них. Представляют собой комплекс аппаратных и программных средств, предназначенных для выявления атак на сетевом уровне и обеспечения своевременной реакции на них. Предназначены для перехвата потоков данных и обнаружения признаков сложных атак. Сетевое обнаружение и реагирование (NDR) – это решение кибербезопасности, предназначенное для мониторинга, обнаружения угроз внутри сети и реагирования на них в режиме реального времени. В отличие от традиционных инструментов сетевой безопасности, NDR использует расширенную аналитику, машинное обучение и поведенческий анализ для выявления аномалий и потенциальных угроз, которые могут остаться незамеченными обычными системами.

#### *UEBA (User and Entity Behavior Analytics).*

Системы поведенческого анализа пользователей и информационных систем. Предназначены для выявления случаев нетипичного поведения и в большей степени фокусируются на внутренних угрозах, таких как сотрудники, действия которых вышли из-под контроля. Основной принцип работы таких систем, основанный на использовании ИИ, заключается в автоматическом выявлении аномалий в поведенческих моделях. UEBA-системы используют машинное обучение, алгоритмы и статистический анализ, чтобы понять, когда происходит отклонение от установленных правил, определяя, какие из этих аномалий могут привести к потенциальной или реальной угрозе. UEBA также могут агрегировать данные, содержащиеся в отчетах и журналах, анализировать информацию о файлах, потоках и пакетах. Данные системы позволяют выявлять атаки, которые не могут быть обнаружены традиционными СЗИ.

#### *Application Security.*

Системы защиты приложений. Предназначены для обнаружения и управления угрозами безопасности прикладных программ. Искусственный интеллект в таких системах автоматизирует сбор данных об уязвимостях, атаках и инфицировании из открытых источников. На основе полученной информации ИИ выполняет автоматизированные защитные действия, такие как сканирование на наличие уязвимостей, изменение правил защиты веб-приложений, выявление угроз и корректировку модели оценки рисков.

### **Заключение**

Анализ текущего состояния применения искусственного интеллекта в сфере информационной безопасности свидетельствует о его значимом вкладе в противодействие современным угрозам. Внедрение технологий ИИ в системы информационной безопасности организаций, как правило, приводит к сокращению времени обнаружения и ликвидации инцидентов, а также оптимизации затрат на управление персоналом. Кроме того, использование ИИ повышает эффективность выявления неизвестных угроз и ускоряет анализ вредоносной активности как на конечных устройствах, так и в приложениях.

### **Библиографический список**

1. ГОСТ Р 59548–2022. Защита информации. Регистрация событий безопасности. Требования к регистрируемой информации: утв. и введен приказом Федерального агентства по техническому регулированию и метрологии от 13.01.2022 № 2-ст. URL: <https://docs.cntd.ru/document/1200182791?ysclid=m0p1eu22ht44948626> (дата обращения: 25.08.2024).
2. Меры защиты информации в государственных информационных системах: утв. и введен ФСТЭК России 11.02.2014. URL: <https://fstec.ru/dokumenty/vse-dokumenty/spetsialnye-normativnye-dokumenty/metodicheskij-dokument-ot-11-fevralya-2014-g?ysclid=m0p12e5h8k778564821> (дата обращения: 20.08.2024).
3. Татарникова Т. М. Защищенные корпоративные сети. СПб.: РГГМУ. 2012. 113 с.
4. Reinventing Cybersecurity with Artificial Intelligence The new frontier in digital security. Capgemini Research Institute. URL: [www.capgemini.com](http://www.capgemini.com) (дата обращения: 25.08.2024).

*С. Г. Фомичева*

кандидат технических наук, профессор

Санкт-Петербургский государственный университет аэрокосмического приборостроения

## ЭВОЛЮЦИЯ И УЯЗВИМОСТИ ДЕТЕКТОРОВ ОБЪЕКТОВ СЕМЕЙСТВА YOLO

Анализируются эволюционные архитектурные изменения ML-моделей семейства YOLO с точки зрения выявления структурных компонент, потенциально способных быть контейнерами для вредоносных вложений, а также уязвимости детекторов к состязательным атакам. Современные модели, используемые в реальных приложениях, требуют основательной работы по их тестированию с точки зрения не только производительности базового функционала, но и устойчивости к различным типам атак, в том числе состязательных. Самая надежная стратегия защиты от последних – состязательное обучение, при котором состязательные примеры генерируются и добавляются к чистым примерам во время обучения.

**Ключевые слова:** машинное обучение, YOLO, атаки.

*S. G. Fomicheva*

PhD, Tech., Professor

St. Petersburg State University of Aerospace Instrumentation

## EVOLUTION AND VULNERABILITY OF YOLO OBJECT DETECTORS

The paper analyzes the evolutionary architectural changes of ML-models of the YOLO family in terms of identification of structural components potentially capable of being containers for malicious inputs, as well as vulnerability of detectors to competing attacks. Modern models used in real applications require a thorough work to test them not only in terms of performance of the basic functionality, but also in terms of resistance to various types of attacks, including competitive ones. The most reliable strategy for protecting against the latter is competitive learning, where competing examples are generated and added to pure examples during training.

**Keywords:** machine learning, YOLO, attacks.

### Введение

Прогресс в области систем искусственного интеллекта базируется на революционном развитии моделей машинного обучения (ML-моделей) компьютерного зрения (Computer Vision, CV), в частности таких как однопроходные детекторы объектов семейства YOLO [1]. В отличие от двухпроходных ML-моделей [2] (например, таких как ResNet-50, FastResnet, FasterResnet и т. п.), они обладают высочайшими характеристиками при сопоставимом качестве прогнозов. Это позволило их массово внедрять в различные высокопроизводительные пограничные (edge) устройства, работающие в режиме реального времени, к числу которых относятся видеокамеры, системы наведения на цели и др. Как и любая другая ML-модель, YOLO-модель требует дообучения на новых пользовательских наборах данных. Часто такое обучение может быть трансферным или федеративным, что открывает потенциальную возможность несанкционированного отравления (poison) параметров модели и/или внедрения вредоносных вложений в ее архитектуру [3–5]. Такие изменения способны привести к выведению из штатных режимов работы скомпрометированных детекторов, что актуализирует задачи мониторинга существующих и вновь создаваемых ML-моделей на наличие уязвимостей в контексте их информационной безопасности.

В данной статье анализируются эволюционные архитектурные изменения ML-моделей семейства YOLO с точки зрения выявления структурных компонент, потенциально способных быть контейнерами для вредоносных вложений, а также уязвимости детекторов к состязательным атакам. Состязательная атака [3] – это угроза безопасности, которая включает манипулирование обучающими данными модели с целью поставить под угрозу точность и надежность ML-модели. Основная цель состязательной атаки состоит в том, чтобы внести минимальное изменение во входные данные (сгенерировать состязательный пример), которое может привести к желаемой для злоумышленника неправильной классификации. Среди наиболее известных алгоритмов генерации состязательных примеров следует назвать FGSM [6] и PGD [7] – эффективные методы, добавляющие минимальное возмущение к входным данным в направлении градиента функции потерь входных данных, вынуждая ML-модель неправильно классифицировать входные данные, даже если искаженное изображение может показаться наблюдателю похожим на исходное [8].

ML-модель YOLOv1 (You Only Look Once) [1], впервые предложенная Джозефом Редмоном в 2015 г., благодаря инновациям в своей архитектуре существенно ускорила процесс распознавания объектов за счет учета как локальных признаков изображений, так и глобального контекста анализируемого изображения. В отличие от современных версий однопроходных детекторов объектов, архитектура которых основана на структуре «позвоночник – шея – голова» (Backbone-Neck-Head, BNH), YOLOv1 не имела «шеи», базировалась на архитектуре GoogleNet и имела 24 сверточных слоя и два полносвязных слоя. Сверточные слои образуют «позвоночник»

и действуют как магистраль, а два дополнительных полностью связанных слоя действуют как головка обнаружения. Задача головки обнаружения состоит в прогнозе координат ограничивающего прямоугольника, оценке объектности и класса объекта, поэтому функции потерь YOLOv1 имеет три составляющих: терм потерь локализации, терм потерь уверенности в прогнозе и терм потерь классификации. Каждый из этих термов представляется в виде среднеквадратического отклонения прогнозных значений от целевых.

Здесь следует обратить внимание на наличие в архитектуре двух полносвязных слоев с соответствующей размерностью 4096 и  $7 \times 7 \times 30$ , что в итоге позволяет использовать их как контейнер размером  $[5566 \times a \times h]$  для потенциальных вложений ( $h$  – размерность типа данных, используемая для элемента матриц весов нейронов,  $a$  – доля искажаемых бит в ходе внедрения). Являясь моделью контролируемого обучения YOLOv1 подвержена полному спектру состязательных атак [3].

В архитектуре моделей YOLOv2 (2016) и YOLOv3 (2018) [9] были добавлены компоненты Feature Pyramid Networks (FPN), которые повысили точность обнаружения за счет многомасштабного обучения и применения якорных ограничивающих рамок, в остальной архитектура не изменилась и унаследовала те же уязвимости, что и YOLOv1. Наличие таких уязвимостей зафиксировано в международной базе CVE с номером CVE-2021-31681 – десериализация уязвимости ненадежных данных в YOLOv3 позволяет злоумышленникам выполнять произвольный код с помощью созданного файла `yaml`. Уровень критичности данной уязвимости высок – 7,8 из 10.

Существенное изменение базовой архитектуры было произведено в YOLOv4 [10], созданную в 2019 г. Алексеем Бочковским, Чием-Яо Ваном и Хун-Юанем Марком Ляо. Именно ими в семейство моделей YOLO добавлена архитектурная компонента, называемая «шеей» (Neck). Шея построена как пространственная пирамида пула (Spatial Pyramid Pooling, SPP) и предназначена для сбора характерных признаков (features), выявленных на разных стадиях из магистрали (позвоночника) и передаче их в голову. Кроме того, авторы изменили концепцию обучения, применяя Bag of freebies и Bag of specials. Использование Bag of freebies приводит к повышению затрат на обучение за счет, например, аугментации данных, но не изменяет затраты на прогноз модели. Напротив, Bag of specials незначительно повышает затраты на прогноз, но не влияет на стоимость процесса обучения. Для их внедрения в архитектуру авторы использовали алгоритмы генетической эволюции, а также модули внимания. В результате, YOLOv4 существенно повысила точность обнаружения объектов. По сути, реализация архитектуры YOLOv4 на Pytorch стали считать моделью YOLOv5. Наличие в архитектуре полносвязных слоев и хранение значений весов их нейронов в отдельном открытом `yaml`-файле по-прежнему оставляет потенциальную уязвимость CVE-2021-31680 – десериализация уязвимости ненадежных данных в `yolo 5` позволяет злоумышленникам выполнять произвольный код с помощью созданного файла `yaml`.

При создании модели YOLO-R [11] те же авторы, которые разработали YOLOv4, пытались построить модели для поддержки многозадачного обучения, способную для одного и того же входного представления данных решать одновременно разные задачи компьютерного зрения (обнаружение объекта, классификация, оценка позы и т. п.). В ходе экспериментов ими в архитектуру был добавлен целый ряд дополнительных компонент, как правило выполняющих поддержку неявных (подсознательных) знаний, однако данный подход не получил широкого распространения. С точки зрения информационной безопасности, добавленные в YOLO-R компоненты для неявных знаний, являясь полносвязными нейросетевыми структурами, существенно увеличили поверхность рассматриваемых атак, основанных на внедрении вредоносных составляющих в веса нейронов.

Модель YOLO-X (2021) [11] разработана компанией Megvii Technology (Китай), считаясь одним из лучших по производительности детекторов объектов, является усовершенствованием модели YOLOv3 за счет разделения головок, прогнозирующих обнаружения объектов, отказа от якорных привязок и модифицированного подхода к аугментации данных при обучении. Уязвимости в YOLO-X аналогичны уязвимостям YOLOv3.

Модель YOLOv7 (2022) [11] была разработана на два месяца раньше, чем модель YOLOv6, и является усовершенствованием модели Scaled-YOLOv4. В ней модернизированы способы масштабирования модели (использовался NAS – автоматический поиск сетевой архитектуры), введена плановая перепараметризованная свертка, используется стохастическое усреднение весов моделей, обученных на разных наборах данных и на разных эпохах. Уязвимости YOLOv7 аналогичны уязвимостям YOLOv4.

В модели YOLOv8 (2023) [9] на базе архитектуры модели YOLOv3 были разделены функциональности головок и улучшены функции потерь, что позволило повысить точность обнаружения мелких объектов, а также качественно решать задачу сегментации объектов. Уязвимости YOLOv8 аналогичны уязвимостям YOLOv3.

Архитектура модели YOLO-NAS (2023) сгенерирована автоматически алгоритмами поиска сетевой архитектуры (AutoNAC), способна эффективно обнаруживать мелкие объекты и обладает повышенной точностью локализации. Модели YOLO-NAS включают в состав своей архитектуры механизмы внимания и перепараметризации при прогнозе. обучения моделей. При обучении YOLO-NAS использовались такие методы, как дистилляция знаний (KD) и фокусная потеря распределения (DFL). В результате YOLO-NAS обладает сбалансированным соотношением производительности и вычислительных ресурсов, что делает ее идеальной для приложений, работающих на периферийных устройствах в реальном времени. Наличие в архитектуре механизмов внимания, основанных на полносвязных слоях, оставляет потенциальные уязвимости как для состязательных атак, так и атак внедрения вредоносных составляющих.

YOLOv9 (2024) [13] является современной версией детекторов объектов рассматриваемого семейства и усовершенствованием YOLOv7. В ней использован подход программируемой градиентной информации (Programmable Gradient Information, PGI) и новая сетевая архитектура под названием Generalized Efficient Layer



Aggregation Network (GELAN) для решения проблем потери данных в сетях глубокого обучения во время извлечения и преобразования фичей (features). PGI-метод предназначен для сохранения полной входной информации (используются вспомогательные обратимых ветви) для надежных расчетов градиента и улучшения обновления весов. GELAN повышает гибкость за счет взаимозаменяемых вычислительных блоков, обеспечивает глубокую параметризацию для эффективного использования ресурсов и обеспечивает стабильную производительность в различных конфигурациях с разными типами блоков и глубины для масштабируемого обнаружения объектов.

Экспериментально YOLOv9, использующий GELAN и PGI, превосходит другие детекторы объектов в реальном времени с точки зрения точности и эффективности. Успех YOLOv9 объясняется превосходным использованием параметров и способностью PGI сохранять важную информацию для эффективного сопоставления целевых данных. Число параметров (являющихся потенциальным контейнером для злонамеренных внедрений) измеряется от 2Мб для YOLOv9t до 58,1Мб для YOLOv9e.

Кроме того, по-прежнему данный детектор остается подверженным состязательным атакам. В таблице для модели YOLOv9s приведены изменения значений метрики mAP (%) при реализации атак FGSM и PDG на модифицированном наборе морских данных Сингапура (SMD-Plus), состоящего из видеороликов высокой четкости, снятых на разрешение 1920 на 1080 пикселей. Для реализации атак использована библиотека ART (Adversarial Robustness Toolbox) [14].

В качестве сигнала возмущения использовался белый шум с уровнями возмущения [0,01,0,3]. Состязательные примеры создавались ML-моделями GoogLeNet, YOLOv5s, YOLOv9s с сопоставимыми гиперпараметрами. На этих же моделях проводилось состязательное предобучение (pretraining).

#### Изменение точности обнаружения YOLOv9s при состязательных атаках

Уровень сигнала возмущения (epsilon)	FGSM (pretraining GoogLeNet)	FGSM (pretraining YOLOv5s)	FGSM (pretraining YOLOv9s)	PGD (pretraining GoogLeNet)	PGD (pretraining YOLOv5)	PGD (pretraining YOLOv9)
0	0,896	0,896	0,896	0,896	0,896	0,896
0,01	0,827	0,871	0,886	0,829	0,891	0,896
0,05	0,766	0,807	0,845	0,771	0,854	0,889
0,1	0,551	0,751	0,809	0,728	0,831	0,856
0,2	0,266	0,516	0,731	0,721	0,799	0,822
0,3	0,115	0,342	0,678	0,71	0,767	0,798

Как видно из таблицы, атака FGSM приводит к значительному снижению точности обнаружения, но при этом состязательные примеры заметно с визуальной точки искажаются. Это позволяет нейтрализовать данный тип атак использованием статистических фильтров. Атаки PGD, генерируя состязательные примеры итеративно, «отравляют» датасет более скрытно, практически не меняя распределение данных в домене, но снижая производительность самого современного на текущий момент детектора на 10% при уровне сигнала возмущения, равном  $\epsilon = 0,3$ .

На момент написания данной статьи появилась новая версия детектора обнаружения YOLOv10 [15], созданная с использованием фреймворка Ultralytics Python исследователями из Университета Цинхуа (Tsinghua University). Ее архитектура включает «позвоночник» на базе CSPNet (Cross Stage Partial Network), шею на базе PAN (Path Aggregation Network) и две компоненты разделения головок: компонента 1:M генерирует несколько прогнозов для каждого объекта во время обучения, чтобы обеспечить богатые контрольные сигналы и повысить точность обучения; компонента 1:1 генерирует единственный наилучший прогноз для каждого объекта во время логического вывода, устраняя необходимость в NMS, тем самым сокращая задержку и повышая эффективность. Данную модель автор намерен исследовать на устойчивость к состязательным атакам в будущих работах.

В итоге на сегодняшний день атаковать ML-модель значительно проще, чем обеспечить ее надежную защиту. Современные модели, используемые в реальных приложениях, требуют основательной работы по их тестированию с точки зрения не только производительности базового функционала, но и устойчивости к различным типам атак, в том числе состязательных. Самая надежная стратегия защиты от последних – состязательное обучение, при котором состязательные примеры генерируются и добавляются к чистым примерам во время обучения. Поиск новых атак и лучших стратегий защиты является активной областью исследований. Требуется много теоретической и эмпирической работы, чтобы сделать ML-модели по-настоящему безопасными.

#### Библиографический список

1. You only look once: Unified, real-time object detection / J. Redmon, S. Divvala, R. Girshick, A. Farhadi // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 27–30 June 2016. P. 779–788.

2. *Tan M., Pang R., Le Q. V.* EfficientDet: Scalable and Efficient Object Detection // Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 13–19 June 2020. P. 10778–10787.
3. *Фомичева С. Г., Беззатеев С. В.* Механизмы защиты моделей машинного обучения от состязательных атак // Т-Comm: Телекоммуникации и транспорт. 2023. Т. 17, № 10. С. 28–42.
4. *Фомичева С. Г.* Влияние ранжирования индикаторов атак на качество моделей машинного обучения в агентных системах непрерывной аутентификации // Т-Comm: Телекоммуникации и транспорт. 2023. Т. 17, № 8. С. 45–55.
5. *Беззатеев С. В., Фомичева С. Г., Супрун А. Ф.* Повышение эффективности мультиагентных систем информационной безопасности методами постквантовой криптографии // Проблемы информационной безопасности. Компьютерные системы. 2022. № 4(52). С. 71–88.
6. *Goodfellow I. J., Shlens J., Szegedy C.* Explaining and harnessing adversarial examples. URL: arXiv 2015, arXiv:1412.6572.
7. Towards deep learning models resistant to adversarial attacks / A. Madry, A. Makelov, L. Schmidt [et al.]. URL: arXiv 2018, arXiv:1706.06083.
8. Adversarial attack and defense strategies of speaker recognition systems: A survey / H. Tan, L. Wang, H. Zhang [et al.] // Electronics. 2022. Vol. 11. P. 218320.
9. *Terven J., Cordova-Esparza D.-M.* A Comprehensive Review of YOLO: From YOLOv1 to YOLOv8 and Beyond. 2023. URL: [https://www.researchgate.net/publication/369760111\\_A\\_Comprehensive\\_Review\\_of\\_YOLO\\_From\\_YOLOv1\\_to\\_YOLOv8\\_and\\_Beyond](https://www.researchgate.net/publication/369760111_A_Comprehensive_Review_of_YOLO_From_YOLOv1_to_YOLOv8_and_Beyond) (дата обращения: 01.06.2024).
10. *Bochkovskiy A., Wang Ch.-Y., Liao H.* YOLOv4: Optimal Speed and Accuracy of Object Detection. 2020. URL: [https://www.researchgate.net/publication/340883401\\_YOLOv4\\_Optimal\\_Speed\\_and\\_Accuracy\\_of\\_Object\\_Detection](https://www.researchgate.net/publication/340883401_YOLOv4_Optimal_Speed_and_Accuracy_of_Object_Detection) (дата обращения: 01.06.2024).
11. YOLOv5, YOLO-x, YOLO-r, YOLOv7 Performance Comparison: A Survey / I. Gillani, M. Munawar, M. Talha [et al.]. 2022. URL: [https://www.researchgate.net/publication/363848609\\_YOLOv5\\_YOLO-x\\_YOLO-r\\_YOLOv7\\_Performance\\_Comparison\\_A\\_Survey](https://www.researchgate.net/publication/363848609_YOLOv5_YOLO-x_YOLO-r_YOLOv7_Performance_Comparison_A_Survey) (дата обращения: 01.06.2024).
12. YOLO-NAS (Neural Architecture Search). URL: <https://docs.ultralytics.com/models/yolo-nas/> (дата обращения: 01.06.2024).
13. YOLOv9: A Leap Forward in Object Detection Technology. URL: <https://docs.ultralytics.com/models/yolov9/> (дата обращения: 01.06.2024).
14. Adversarial Robustness Toolbox. URL: <https://adversarial-robustness-toolbox.readthedocs.io/en/latest/> (дата обращения: 01.06.2024).
15. YOLOv10: Real-Time End-to-End Object Detection. URL: <https://docs.ultralytics.com/models/yolov10/> (дата обращения: 01.06.2024).

## СОДЕРЖАНИЕ

ВСТУПИТЕЛЬНОЕ СЛОВО .....	3
<b>Технологии искусственного интеллекта в аэрокосмическом приборостроении и инженерии .....</b>	<b>5</b>
<i>Антохина Ю. А., Татарникова Т. М., Охтилев М. Ю., Коромысличенко В. Н., Охтилев П. А.</i> ИНТЕЛЛЕКТУАЛЬНАЯ ТЕХНОЛОГИЯ ЦИФРОВИЗАЦИИ ИНФОРМАЦИОННО-АНАЛИТИЧЕСКОГО ОБЕСПЕЧЕНИЯ ЖИЗНЕННОГО ЦИКЛА РАКЕТНО-КОСМИЧЕСКОЙ ТЕХНИКИ.....	5
<i>Аминова А. С.</i> МЕТРОЛОГИЧЕСКАЯ ЭКСПЕРТИЗА ПРОЕКТОВ СТАНДАРТОВ: ПЕРСПЕКТИВА РАЗРАБОТКИ НЕЙРОННОЙ СЕТИ ДЛЯ АВТОМАТИЗАЦИИ ПРОЦЕССА.....	10
<i>Беляев С. И., Кузнецов П. М.</i> ПРИМЕНЕНИЕ ГЕНЕРАТИВНЫХ НЕЙРОСЕТЕЙ ДЛЯ ПОСТРОЕНИЯ ЦИФРОВЫХ ДВОЙНИКОВ В МЕЛКОСЕРИЙНОМ ПРОИЗВОДСТВЕ.....	15
<i>Бирюков М. П.</i> ПОЛИМОДЕЛЬНЫЙ КОМПЛЕКС ДИАГНОСТИЧЕСКИХ МОДЕЛЕЙ РАЗГОННОГО БЛОКА КАК ОБЪЕКТА АНАЛИЗА ТЕХНИЧЕСКОГО СОСТОЯНИЯ .....	17
<i>Бурькин А. А., Грачев М. Н.</i> ПУТИ РЕАЛИЗАЦИИ ПЕРСПЕКТИВНЫХ СИСТЕМ УПРАВЛЕНИЯ БЕЗЭКИПАЖНОГО СУДНА ДВОЙНОГО НАЗНАЧЕНИЯ С ИСПОЛЬЗОВАНИЕМ ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА.....	20
<i>Венгеренко В. В., Лукашевич М. М., Инютин А. В.</i> РАЗРАБОТКА МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНАЛИЗА ТЕЛЕМЕТРИЧЕСКОЙ ИНФОРМАЦИИ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ПОИСКА АРХИТЕКТУР.....	25
<i>Войтов И. В., Охтилев М. Ю., Штепа В. Н.</i> АКТУАЛЬНОСТЬ СОЗДАНИЯ И ВНЕДРЕНИЯ НА ВОДОПРОВОДНО-КАНАЛИЗАЦИОННЫХ ХОЗЯЙСТВАХ ИНТЕЛЛЕКТУАЛЬНО-АНАЛИТИЧЕСКИХ ПРОГРАММНЫХ ПРОДУКТОВ .....	29
<i>Волков В. Ф., Шуваев Н. А., Хайдаров Р. Р.</i> МЕТОДОЛОГИЧЕСКИЙ ПОДХОД К ПРИМЕНЕНИЮ ЦИФРОВОГО ДВОЙНИКА ДИСТАНЦИОННО ОБСЛУЖИВАЕМОГО ОБЪЕКТА В ПРОЦЕССЕ ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ В ИНТЕРЕСАХ СОКРАЩЕНИЯ ВРЕМЕНИ ПРИНЯТИЯ РЕШЕНИЯ ОПЕРАТОРОМ .....	32
<i>Григорьева Е. Д., Ушаков В. А.</i> РАЗРАБОТКА АППАРАТНО-ПРОГРАММНОГО КОМПЛЕКСА «УМНОГО» ПРОИЗВОДСТВА С ПРИМЕНЕНИЕМ ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА .....	37
<i>Григорьева Н. Н.</i> ПРОБЛЕМЫ ВНЕДРЕНИЯ СРЕДСТВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ПРИ СОЗДАНИИ АВИОНИКИ ГРАЖДАНСКОЙ АВИАЦИИ С ТОЧКИ ЗРЕНИЯ ПРОЦЕССНОГО ПОДХОДА .....	40
<i>Долженкова Д. С., Соколова А. П., Егоров М. Ю.</i> АДАПТИВНЫЕ СИСТЕМЫ УПРАВЛЕНИЯ АВТОНОМНЫХ СИСТЕМ В УСЛОВИЯХ КОСМИЧЕСКОГО ПРОСТРАНСТВА.....	44
<i>Зеленев Д. В., Лыков А. Р., Волков М. Н.</i> ГЕНЕРАЦИЯ СИНТЕТИЧЕСКИХ ТЕЛЕМЕТРИЧЕСКИХ ДАННЫХ ДЛЯ ТЕСТИРОВАНИЯ СИСТЕМ КОНТРОЛЯ И ДИАГНОСТИКИ БОРТОВЫХ СИСТЕМ КОСМИЧЕСКИХ АППАРАТОВ .....	48
<i>Ковтун В. С.</i> КОНЦЕПТУАЛЬНАЯ МОДЕЛЬ СИТУАЦИОННОГО УПРАВЛЕНИЯ ДИНАМИЧЕСКИМИ СИСТЕМАМИ В СИНЕРГЕТИЧЕСКОЙ СРЕДЕ.....	51
<i>Коновалов К. Д., Кулешов С. В.</i> ВАРИАНТЫ АЛГОРИТМОВ ПЛАНИРОВАНИЯ МАРШРУТОВ ДЛЯ ВИЗУАЛЬНОЙ НАВИГАЦИИ.....	61
<i>Куркова О. П.</i> АЛГОРИТМ МОДЕЛИРОВАНИЯ ПОСЛЕДОВАТЕЛЬНОСТИ СБОРКИ СВАРКОЙ НЕСУЩИХ КОНСТРУКЦИЙ БОРТОВОГО ПРИБОРНОГО КОМПЛЕКСА КОСМИЧЕСКОГО АППАРАТА.....	64
<i>Микони С. В., Семёнов С. С.</i> ВЫБОР ВАРИАНТА БЕСПИЛОТНОГО ЛЕТАТЕЛЬНОГО АППАРАТА НА ОСНОВЕ ЗАДАННЫХ ТРЕБОВАНИЙ К ЕГО ПОКАЗАТЕЛЯМ.....	75
<i>Митогуз С. С., Аюева А. В., Ватаева Е. Ю.</i> ПЕРСПЕКТИВЫ РАЗВИТИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ПРОМЫШЛЕННЫХ ПРЕДПРИЯТИЯХ РОССИЙСКОЙ ФЕДЕРАЦИИ.....	79
<i>Павленко Д. А., Снежко Э. В., Ковалев В. А.</i> ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ БЮДЖЕТНОГО ТЕНЗОРНОГО ПРОЦЕССОРА GOOGLE CORAL ДЛЯ РЕШЕНИЯ ПРАКТИЧЕСКИХ ЗАДАЧ КЛАССИФИКАЦИИ ИЗОБРАЖЕНИЙ .....	82

<i>Сенцов А. А., Иванов С. А.</i> РЕАЛИЗАЦИЯ ГЕНЕРАТИВНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ РЕШЕНИЯ ЗАДАЧИ ВЫДЕЛЕНИЯ ТЕХНОГЕННЫХ ВОЗДУШНЫХ ОБЪЕКТОВ ПРИ РАДИОЛОКАЦИОННОМ ОБЗОРЕ.....	91
<i>Спесивцев А. В., Тиличко Ю. Н., Спесивцев В. А.</i> МЕТОДОЛОГИЯ ПОСТАНОВКИ И РЕШЕНИЯ ЗАДАЧИ УПРАВЛЕНИЯ ВЗАИМОВЛИЯНИЕМ В КОМПЛЕКСНОЙ СИСТЕМЕ «СЛОЖНЫЙ ОБЪЕКТ – ОКРУЖАЮЩАЯ СРЕДА» .....	97
<i>Толмачев С. Г.</i> АДАПТИВНЫЙ ВЫБОР ПРИЗНАКОВ ДЛЯ РАСПОЗНАВАНИЯ ОБЪЕКТОВ В МНОГОКАНАЛЬНЫХ ИНФОРМАЦИОННЫХ СИСТЕМАХ.....	101
<i>Тюгашев А. А.</i> ПРОБЛЕМЫ ИНТЕЛЛЕКТУАЛЬНОГО УПРАВЛЕНИЯ СЛОЖНЫМИ ТЕХНИЧЕСКИМИ СИСТЕМАМИ .....	104
<i>Харланов А. С., Яковлева Е. А.</i> ГЕНЕРАТИВНЫЙ ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И ТРАНСФОРМАЦИЯ ГЛОБАЛЬНОЙ КОСМИЧЕСКОЙ ОТРАСЛИ.....	113
<i>Шмелёв В. В., Попов А. М., Баранов А. Н.</i> МОДЕЛИРОВАНИЕ И ОТЛАДКА АЛГОРИТМОВ ОБРАБОТКИ ИЗМЕРИТЕЛЬНОЙ ИНФОРМАЦИИ.....	116
<i>Шмелёв В. В., Самойлов Е. Б., Плахин О. А.</i> ОБОСНОВАНИЕ ИСПОЛЬЗОВАНИЯ КОМПЛЕКСНОГО ПОКАЗАТЕЛЯ ЗНАЧИМОСТИ ТЕЛЕМЕТРИРУЕМЫХ ПАРАМЕТРОВ НА ОСНОВЕ ИХ ДИНАМИЧЕСКИХ И КОРРЕЛЯЦИОННЫХ СВОЙСТВ ДЛЯ ФОРМИРОВАНИЯ РЕПОРТАЖНОГО ПОТОКА.....	122
<i>Штепа В. Н., Смелов В. В., Карпович Д. С.</i> СТРУКТУРНЫЕ СХЕМЫ ЦИФРОВЫХ ДВОЙНИКОВ ПРОЦЕССОВ ПРОМЫШЛЕННОГО ВОДООТВЕДЕНИЯ .....	126
<b>Технологии искусственного интеллекта в образовании.....</b>	<b>130</b>
<i>Аграновский А. В., Турнецкая Е. Л.</i> ФОРМИРОВАНИЕ ОБРАЗОВАТЕЛЬНОЙ ТРАЕКТОРИИ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА .....	130
<i>Антохина Ю. А., Кричевский М. Л.</i> РИСКИ ИСПОЛЬЗОВАНИЯ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ В ОБРАЗОВАНИИ.....	133
<i>Бердин А. Э.</i> ИСПОЛЬЗОВАНИЕ БОЛЬШИХ ДАННЫХ В ОБРАЗОВАТЕЛЬНОЙ ДЕЯТЕЛЬНОСТИ .....	136
<i>Бойназаров И. М.</i> АДАПТИВНЫЕ МЕТОДЫ ОЦЕНКИ КАЧЕСТВА ОБРАЗОВАТЕЛЬНОГО КОНТЕНТА .....	139
<i>Величко М. В., Бобович Т. А.</i> ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В ОБРАЗОВАНИИ: РОЛЬ ЧАТ-БОТОВ .....	144
<i>Величко М. В., Бобович Т. А.</i> СРАВНЕНИЕ ЭФФЕКТИВНОСТИ ОБУЧЕНИЯ С УЧАСТИЕМ ГЕНЕРАТИВНОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И БЕЗ НЕГО .....	146
<i>Городецкий В. И.</i> ИСТОЧНИКИ ЗНАНИЙ ДЛЯ ПРИЛОЖЕНИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И ПРОБЛЕМЫ ДОСТУПА К НИМ.....	149
<i>Егорова М. Р., Миклуш В. А.</i> АНАЛИЗ УРОВНЯ ЗНАНИЙ ОБУЧАЮЩИХСЯ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА.....	156
<i>Коршунов И. Л., Омельян А. В.</i> ПРОБЛЕМЫ ПРИМЕНЕНИЯ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ ДЛЯ РЕШЕНИЯ ЗАДАЧ РАЗЛИЧНОГО НАЗНАЧЕНИЯ.....	158
<i>Лисюков Д. С., Яковлева Е. А.</i> ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И АНАЛИТИКИ ДАННЫХ В СИСТЕМАХ УПРАВЛЕНИЯ ОБУЧЕНИЕМ .....	160
<i>Путилова Н. В.</i> ОПТИМИЗАЦИЯ ПАРАМЕТРОВ ОБРАЗОВАТЕЛЬНЫХ ПРОГРАММ И ПЕДАГОГИЧЕСКОЙ НАГРУЗКИ С ИСПОЛЬЗОВАНИЕМ ИНТЕЛЛЕКТУАЛЬНЫХ ТЕХНОЛОГИЙ .....	163
<i>Савенко А. Г., Парамонов А. И.</i> ИСПОЛЬЗОВАНИЕ ИНТЕЛЛЕКТУАЛЬНОЙ ЦИФРОВОЙ ПЛАТФОРМЫ В ОБРАЗОВАТЕЛЬНОМ ПРОЦЕССЕ .....	166
<i>Строганов В. Ю., Строганов Д. В.</i> ФОРМАЛЬНЫЕ МОДЕЛИ НЕЧЕТКИХ МНОЖЕСТВ И НЕЧЕТКОЙ ЛОГИКИ В СИСТЕМЕ ПОДГОТОВКИ ИНДИВИДУАЛЬНЫХ ОБРАЗОВАТЕЛЬНЫХ ПРОГРАММ.....	169
<i>Строганов В. Ю., Строганов Д. В.</i> МОДЕЛИ АДАПТИВНОГО ТЕСТОВОГО КОНТРОЛЯ И МЕТОДЫ ОЦЕНКИ ИХ ЭФФЕКТИВНОСТИ НА ОСНОВЕ КРИТЕРИЕВ ОШИБОЧНОЙ КЛАССИФИКАЦИИ.....	172
<i>Фомин В. В., Фомина И. К.</i> ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ В АЛГОРИТМАХ ВОЗРАСТНОЙ ГРАДАЦИИ ШКОЛЬНОЙ ЛИТЕРАТУРЫ.....	175

<b>Разработка интеллектуальных интерфейсов .....</b>	<b>178</b>
<i>Балезин Л. Н., Виноградов Д. Ф., Крейзо М. Д.</i> ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ РАСПОЗНАВАНИЯ РЕЧИ .....	178
<i>Ильиных М. В., Турнецкая Е. Л.</i> ПЕРСПЕКТИВЫ ВНЕДРЕНИЯ ГОЛОСОВЫХ ПОМОЩНИКОВ В ИНТЕРФЕЙСЫ ГРАФИЧЕСКИХ РЕДАКТОРОВ .....	181
<i>Космынин Д. А., Григорьев Е. К.</i> МЕТОД РАСПОЗНАВАНИЯ СИНТЕЗИРОВАННОЙ РЕЧИ НА ОСНОВЕ ВЫЧИСЛЕНИЯ ЭНТРОПИИ АУДИОСИГНАЛА .....	184
<i>Курьян С. М., Петрушкевич М. А., Селиванова Е. А.</i> ТЕХНОЛОГИЯ NDEX5 КАК КОГНИТИВНЫЙ СЕРВИС АНАЛИЗА ПАТТЕРНОВ ПОВЕДЕНИЯ В ОНЛАЙН-РЕЖИМЕ.....	190
<i>Мирошниченко Н. И.</i> ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ РАСПОЗНАВАНИЯ ЭМОЦИЙ ПО ГОЛОСУ: СОВРЕМЕННЫЕ ПОДХОДЫ И ПЕРСПЕКТИВЫ РАЗВИТИЯ.....	193
<i>Митрофанова Т. В., Сорокин С. С.</i> ИСПОЛЬЗОВАНИЕ GIGASNAT ПРИ МОДЕЛИРОВАНИИ БИЗНЕС-ПРОЦЕССОВ В НОТАЦИИ VRMN .....	196
<i>Салиева А. Р., Верзун Н. А., Колбанёв М. О.</i> ОБУЧЕНИЕ С ПОДКРЕПЛЕНИЕМ В ЗАДАЧАХ АКУСТИЧЕСКОГО РАСПОЗНАВАНИЯ В ЛОГИСТИКЕ .....	199
<i>Сенина Я. И., Григорьева Н. Н.</i> АВТОМАТИЗАЦИЯ СИНТАКСИЧЕСКОГО ФОРМАТИРОВАНИЯ ТЕКСТА, СОСТАВЛЕННОГО НА ОСНОВЕ РАСПОЗНАВАНИЯ РЕЧИ.....	202
<i>Черкашин Е. А., Зайцева А. А.</i> МЕТОДЫ НЕЙРОСЕТЕВОЙ ОБРАБОТКИ ВИДЕОДАННЫХ ДЛЯ ПОСТРОЕНИЯ МОДЕЛИ ПОВЕДЕНИЯ БИОЛОГИЧЕСКИХ ОБЪЕКТОВ .....	204
<i>Чулочникова Н. И., Турнецкая Е. Л.</i> ИСПОЛЬЗОВАНИЕ НЕЙРОСЕТЕЙ ДЛЯ УЛУЧШЕНИЯ КАЧЕСТВА ЗВУКОВОЙ ЗАПИСИ И СОЗДАНИЯ ВИДЕОКОНТЕНТА.....	208
<i>Шальнев И. О., Аксенов А. Ю.</i> ИСПОЛЬЗОВАНИЕ ОПТИЧЕСКОГО ПОТОКА ДЛЯ ВЫДЕЛЕНИЯ ДИНАМИЧЕСКИХ ПРИЗНАКОВ ДВИЖУЩИХСЯ ОБЪЕКТОВ .....	212
<b>Прикладные интеллектуальные и информационные системы.....</b>	<b>215</b>
<i>Акопян Б. К.</i> ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ КЛАССИФИКАЦИИ ЭПИЗОДОВ НАРУШЕНИЙ СЕРДЕЧНОГО РИТМА.....	215
<i>Бардовский А. А., Фомичева С. Г.</i> ДОВЕРЕННАЯ СРЕДА ВЫПОЛНЕНИЯ ОР-ТЭЕ В ЗАДАЧАХ ЗАЩИТЫ ИНТЕЛЛЕКТУАЛЬНЫХ ИОТ-РЕШЕНИЙ.....	218
<i>Батайкин Г. А., Поляк М. Д.</i> ОПРЕДЕЛЕНИЕ ПОЛОЖЕНИЯ КНИГ НА СТЕЛЛАЖЕ И РАСПОЗНАВАНИЕ ИХ НАЗВАНИЙ .....	221
<i>Бердина М. Ю.</i> ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ВО ФРАНЧАЙЗИНГЕ.....	226
<i>Васяева Т. А., Рябко М. А.</i> ПРИМЕНЕНИЕ ГЕНЕТИЧЕСКИХ АЛГОРИТМОВ ДЛЯ РАЗРАБОТКИ АДАПТИВНЫХ ВЕБ-САЙТОВ .....	229
<i>Головкин М. М., Татарникова Т. М.</i> НЕЙРОСЕТЕВЫЕ ПОДХОДЫ К ИДЕНТИФИКАЦИИ КЛАССИЧЕСКИХ АЛГОРИТМОВ В RUTNOM .....	232
<i>Григорьева Е. Д., Ушаков В. А.</i> ПРИМЕНЕНИЕ ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В МЕТЕОРОЛОГИИ .....	234
<i>Губайдулин В. Ф., Скобцов Ю. А.</i> ПРОЕКТИРОВАНИЕ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ ОТСЛЕЖИВАНИЯ ТРАНСПОРТНЫХ СРЕДСТВ НА ПРОИЗВОДСТВЕННОЙ ТЕРРИТОРИИ .....	236
<i>Киргизбоев Т. А., Мирзокулов Х. Б.</i> ИСПОЛЬЗОВАНИЕ ТЕХНОЛОГИИ РАДИОЧАСТОТНОЙ ИДЕНТИФИКАЦИИ ДЛЯ МОНИТОРИНГА СКОРОСТИ ДВИЖЕНИЯ АВТОМОБИЛЕЙ .....	239
<i>Колесникова С. И., Васильев В. А., Алешина Д. Р.</i> СРАВНЕНИЕ ЭФФЕКТИВНОСТИ УПРАВЛЕНИЙ МАНИПУЛЯТОРОМ С НЕИЗВЕСТНОЙ МАССОЙ ЗВЕНА .....	244
<i>Колесникова С. И., Фоменкова А. А., Поляк М. Д., Щеголева А. А.</i> СИСТЕМА СТАБИЛИЗАЦИИ БИОИНЖЕНЕРНОГО СТОХАСТИЧЕСКОГО ОБЪЕКТА НА ОСНОВЕ МНОЖЕСТВЕННОСТИ ЦЕЛЕВЫХ МАКРОСОСТОЯНИЙ .....	252
<i>Кудрин И. М., Миклуш В. А.</i> ИНТЕЛЛЕКТУАЛЬНЫЕ ИНСТРУМЕНТЫ ДЛЯ СОЗДАНИЯ АДАПТИВНЫХ ВЕБ-ДИЗАЙНОВ: ПОДХОДЫ И ПЕРСПЕКТИВЫ.....	261

<i>Кузнецов Д. А.</i> УНИФИЦИРОВАННАЯ АНАЛИТИЧЕСКАЯ ПЛАТФОРМА НА БАЗЕ МАРШРУТНОГО ТРАНСПОРТА КАК СРЕДСТВО ПОЛУЧЕНИЯ ИНФОРМАЦИИ О СОСТОЯНИИ ГОРОДСКОЙ ИНФРАСТРУКТУРЫ .....	263
<i>Латыпов А. С., Миклуш В. А.</i> ГЕНЕРАЦИЯ ПЕРСОНАЛИЗИРОВАННОЙ РЕКЛАМЫ НА ОСНОВЕ ПОИСКОВЫХ ЗАПРОСОВ .....	268
<i>Маслова Ж. Н.</i> ВОЗМОЖНОСТИ ПРИМЕНЕНИЯ ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ОБЛАСТИ МАШИННОГО ПЕРЕВОДА .....	270
<i>Мельник П. Г., Светличная В. А., Васяева Т. А.</i> МЕТОДЫ УЛУЧШЕНИЯ ЭФФЕКТИВНОСТИ АЛГОРИТМОВ БЫСТРОРАСТУЩИХ ДЕРЕВЬЕВ ДЛЯ ТРЕХМЕРНОГО ПРОСТРАНСТВА.....	273
<i>Митогуз С. С., Аюева А. В., Гречкин Н. Л.</i> РАСПОЗНАВАНИЕ ОБЪЕКТОВ В RUTRON С ИСПОЛЬЗОВАНИЕМ БИБЛИОТЕКИ IMAGEAI .....	276
<i>Мокрецов Н. С., Татарникова Т. М.</i> АЛГОРИТМ ОПТИМИЗАЦИИ МОДЕЛЕЙ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОБРАБОТКИ ТЕКСТА НА ЕСТЕСТВЕННОМ ЯЗЫКЕ.....	280
<i>Мусаев М. М., Хужаяров И. Ш., Очиллов М. М.</i> ТЕХНОЛОГИИ РАСПОЗНАВАНИЯ РЕЧИ НА БАЗЕ АЛГОРИТМОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА.....	283
<i>Нарвойш П. Ю., Парамонов А. И.</i> ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ПРИ ИССЛЕДОВАНИИ ДЕЯТЕЛЬНОСТИ ГОЛОВНОГО МОЗГА МЕТОДОМ ЭЭГ .....	290
<i>Никитин А. В., Кухарь М. А.</i> МАШИННОЕ ОБУЧЕНИЕ БЕСПИЛОТНЫХ АВТОМОБИЛЕЙ В МЕТАВСЕЛЕННОЙ ГУАП .....	293
<i>Охтилев М. Ю., Коромысличенко В. Н., Охтилев П. А.</i> ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В ПРОГРАММНОЙ ИНЖЕНЕРИИ. ВОПРОСЫ РАЗРАБОТКИ И ПРОЕКТИРОВАНИЯ ПРОГРАММНОЙ ПРОДУКЦИИ .....	296
<i>Примова Х. А., Р. Ахмедова, Каршибоев Ж. У.</i> ВЫБОР СТРОИТЕЛЬНОГО МАТЕРИАЛА НА ОСНОВЕ АЛГОРИТМА БИПОЛЯРНОГО КОМПЛЕКСНОГО АНАЛИЗА .....	300
<i>Раббонакулов О., Мирзокулов Х. Б.</i> АЛГОРИТМ И МОДЕЛЬ СИСТЕМЫ ДИСТАНЦИОННОГО УПРАВЛЕНИЯ СВЕТОФОРАМИ НА ОСНОВЕ ИНТЕРНЕТА ВЕЩЕЙ.....	304
<i>Рогачев С. А.</i> АНАЛИЗ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ .....	309
<i>Саенко В. И.</i> ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ТЕХНОЛОГИЯХ FINOPS.....	312
<i>Саенко В. И., Тихоненкова О. В.</i> ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ КАК КИБЕРЦИФРОВОЙ ОРГАНИЗМ .....	315
<i>Сениченкова Я. О., Поляк М. Д.</i> СРАВНИТЕЛЬНЫЙ АНАЛИЗ НЕЙРОСЕТЕВЫХ МЕТОДОВ КЛАССИФИКАЦИИ СТЕПЕНИ НАПОЛНЕННОСТИ МУСОРНЫХ БАКОВ.....	318
<i>Сергеев А. М., Дунаев М. В.</i> ПРОГНОЗИРОВАНИЕ ВРЕМЕНИ ОБУЧЕНИЯ И ПРИМЕНЕНИЯ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ.....	324
<i>Сергеев А. М., Кучеренко А. С., Топчий А. С.</i> РАЗРАБОТКА СИСТЕМЫ УПРАВЛЕНИЯ СВЕТОФОРАМИ НА ПЕРЕКРЕСТКАХ, ВЗАИМОДЕЙСТВУЮЩЕЙ С ДОРОЖНЫМ ТРАФИКОМ .....	330
<i>Скобцов Ю. А.</i> РОЕВЫЕ КВАНТОВЫЕ АЛГОРИТМЫ .....	334
<i>Скобцов В. Ю.</i> ГИБРИДНЫЕ КЛАССИФИКАЦИОННЫЕ МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОПРЕДЕЛЕНИЯ СОСТОЯНИЯ ФУНКЦИОНИРОВАНИЯ СЛОЖНЫХ СИСТЕМ.....	337
<i>Скобцов В. Ю.</i> РЕГРЕССИОННЫЙ АНАЛИЗ ДАННЫХ СЛОЖНЫХ СИСТЕМ НА ОСНОВЕ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ.....	341
<i>Совков В. В., Сергеев М. Б.</i> О НЕЙРОСЕТЕВОМ УПРАВЛЕНИИ ПЕРЕДВИЖЕНИЕМ ПЕРСОНАЖЕЙ В UNITY КАК СПОСОБЕ ПРОЕКТИРОВАНИЯ РОБОТОТЕХНИЧЕСКИХ СИСТЕМ .....	345
<i>Татарникова Т. М., Раскопина А. С.</i> СОВРЕМЕННЫЕ ПОДХОДЫ К РАЗРАБОТКЕ ЛЕКАРСТВ С ПРИМЕНЕНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА.....	349
<i>Тафеева А. А., Поляк М. Д.</i> ОПРЕДЕЛЕНИЕ ПОЛА ЧЕЛОВЕКА ПО ФОТОГРАФИИ ЧАСТИЧНО ЗАКРЫТОГО ЛИЦА.....	352
<i>Токарев Д. А., Никитин А. В., Решетникова Н. Н.</i> ИНТЕЛЛЕКТУАЛИЗАЦИЯ НЕИГРОВЫХ ПЕРСОНАЖЕЙ В МЕТАВСЕЛЕННОЙ ГУАП .....	356

<i>Ушаков В. А.</i> ПОСТРОЕНИЕ ОБЛАСТЕЙ ДОСТИЖИМОСТИ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ .....	359
<i>Шабунин А. П., Фомин В. В.</i> ТЕМАТИЧЕСКАЯ КЛАССИФИКАЦИЯ НОВОСТНЫХ СТАТЕЙ ИЗ ИНТЕРНЕТА МЕТОДАМИ NLP .....	362
<i>Щукин А. А., Поляк М. Д.</i> ПРОГНОЗИРОВАНИЕ КОНЦЕНТРАЦИИ ХЛОРОФИЛЛА А С ПОМОЩЬЮ МЕТОДОВ МАТЕМАТИЧЕСКОЙ СТАТИСТИКИ И НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ .....	365
<i>Юдин И. А., Решетников Д. С.</i> СОЗДАНИЕ ETL-ДВИЖКА ДЛЯ РЕПЛИКАЦИИ ДАННЫХ ИЗ ARASHE NIVE В SLICKHOUSE .....	371
<b>Искусственный интеллект в информационной безопасности .....</b>	<b>373</b>
<i>Афанасьева А. В., Беззатеев С. В.</i> ОСОБЕННОСТИ ПРИМЕНЕНИЯ ДОВЕРЕННЫХ ВЫЧИСЛИТЕЛЬНЫХ СРЕД ДЛЯ ЗАЩИТЫ СИСТЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА .....	373
<i>Балонин Н. А., Сергеев М. Б.</i> ПРОБЛЕМА СОХРАННОСТИ НАУЧНОГО НАСЛЕДИЯ УЧЕНЫХ .....	377
<i>Беззатеев С. В., Елина Т. Н., Красников Н. С.</i> АЛГОРИТМ МИКШИРОВАНИЯ РЕАЛЬНОГО И СИНТЕТИЧЕСКОГО НАБОРОВ ДАННЫХ ДЛЯ ОБУЧЕНИЯ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ .....	380
<i>Беззатеев С. В., Елина Т. Н., Красников Н. С.</i> ПРОБЛЕМЫ МОШЕННИЧЕСТВА С ИСПОЛЬЗОВАНИЕМ СИНТЕТИЧЕСКИХ ДАННЫХ В ЗАДАЧАХ КОМПЬЮТЕРНОГО ЗРЕНИЯ .....	383
<i>Беззатеева В. С.</i> СПОСОБЫ ЗАЩИТЫ НЕСОВЕРШЕННОЛЕТНЕГО В СЕТИ ОТ ДЕСТРУКТИВНОГО КОНТЕНТА ПРИ ПОМОЩИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА .....	386
<i>Булгаков Д. А.</i> ИСПОЛЬЗОВАНИЕ УМНЫХ КОНТРАКТОВ В ЗАДАЧАХ ПО АУТЕНТИФИКАЦИИ ПОЛЬЗОВАТЕЛЕЙ .....	388
<i>Козелов Г. Е., Афанасьева А. В.</i> СОВРЕМЕННЫЕ МЕТОДЫ ЗАЩИТЫ НЕЙРОСЕТЕЙ ОТ СОСЯЗАТЕЛЬНЫХ АТАК: ОБЗОР И СРАВНЕНИЕ .....	391
<i>Козелов Г. Е., Беззатеев С. В.</i> ОСНОВНЫЕ АРХИТЕКТУРНЫЕ ПРИНЦИПЫ, ЗАЛОЖЕННЫЕ В ТEE, ОРИЕНТИРОВАННЫЕ НА ИСПОЛЬЗОВАНИЕ В ИНТЕЛЛЕКТУАЛЬНЫХ ИНФОРМАЦИОННЫХ СИСТЕМАХ .....	394
<i>Козелов Г. Е., Пекин Д. И., Беззатеев С. В.</i> ОПИСАНИЕ МЕТРИК КЛАССИФИКАЦИИ СОСЯЗАТЕЛЬНЫХ АТАК НА МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ .....	396
<i>Кругляков Р. С., Семенов И. М., Сохбатова Э. Э., Фомичева С. Г.</i> ИССЛЕДОВАНИЕ РОБАСТНОСТИ ДЕТЕКТОРОВ ОБЪЕКТОВ СЕМЕЙСТВА YOLO НА УСТОЙЧИВОСТЬ К ШУМОВОЙ МОДИФИКАЦИИ ПАРАМЕТРОВ .....	401
<i>Крячко А. Ф., Тюрина А. И.</i> ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ПРОЦЕССЕ ПОВЫШЕНИЯ ОСВЕДОМЛЕННОСТИ ПЕРСОНАЛА ОРГАНИЗАЦИИ В ВОПРОСАХ ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТИ .....	406
<i>Крячко А. Ф., Тюрина А. И.</i> РЕШЕНИЯ НА ОСНОВЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И ОБЕСПЕЧЕНИЕ КИБЕРБЕЗОПАСНОСТИ .....	410
<i>Липатников В. А., Шевченко А. А., Мелехов К. В.</i> МЕТОД ПОВЫШЕНИЯ КИБЕРБЕЗОПАСНОСТИ МАСШТАБИРУЕМОЙ КРИТИЧЕСКОЙ ИНФОРМАЦИОННОЙ ИНФРАСТРУКТУРЫ ПУТЕМ МНОГОУРОВНЕВОЙ ИНТЕЛЛЕКТУАЛЬНОЙ ОБРАБОТКИ ДАННЫХ ДЛЯ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ПО РЕАГИРОВАНИЮ НА ИНЦИДЕНТЫ БЕЗОПАСНОСТИ .....	414
<i>Пекин Д. И., Афанасьева А. В.</i> КЛАССИФИКАЦИЯ СОСЯЗАТЕЛЬНЫХ АТАК НА ИНФОРМАЦИОННЫЕ СИСТЕМЫ И СРЕДСТВА .....	417
<i>Тимочкина Т. В., Миклуш В. А.</i> АНАЛИЗ СОБЫТИЙ БЕЗОПАСНОСТИ С ПОМОЩЬЮ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА .....	420
<i>Фомичева С. Г.</i> ЭВОЛЮЦИЯ И УЯЗВИМОСТИ ДЕТЕКТОРОВ ОБЪЕКТОВ СЕМЕЙСТВА YOLO .....	423

Научное издание

ПРИКЛАДНОЙ  
ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ:  
ПЕРСПЕКТИВЫ И РИСКИ

Международная научная конференция

17 октября 2024 г.

Сборник докладов

ISBN: 978-5-8088-1975-7



9 785808 819757

Ответственные за выпуск:

*Б. К. Акопян,*

доктор технических наук, профессор *Т. М. Татарникова*

Редакторская подготовка *С. В. Денисовой*

Компьютерная верстка *И. А. Мосиной*

---

Подписано к печати 10.10.2024. Дата выхода в свет: 16.10.2024. Формат 60×84 1/8.

Усл. печ. л. 50,2. Уч.-изд. л. 69,4. Тираж 150 экз. Заказ № 352.

---

Редакционно-издательский центр ГУАП

190000, г. Санкт-Петербург, ул. Большая Морская, д. 67, лит. А

Распространяется бесплатно