

ЦИФРОВЫЕ РЕШЕНИЯ И ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Научно-практический рецензируемый журнал
Издается с 2025 г.

**Издатель: Финансовый университет
при Правительстве Российской Федерации,
Москва, Российская Федерация**

125167, Москва, Ленинградский пр-т, д. 53

Периодичность издания — 4 номера в год

Журнал ориентирован на научное обсуждение актуальных проблем
по научным специальностям:

- 1.2.1. «Искусственный интеллект и машинное обучение»
- 1.2.2. «Математическое моделирование, численные методы и комплексы программ»
- 2.3.6. «Методы и системы защиты информации, информационная безопасность»
- 5.2.2. «Математические, статистические и инструментальные методы в экономике»

Электронная версия журнала на русском и английском языках
находится в открытом доступе на сайте digitari.ru

Журнал публикует материалы на условиях лицензии
Creative Commons Attribution 4.0 International (CC BY 4.0).

DIGITAL SOLUTIONS AND ARTIFICIAL INTELLIGENCE TECHNOLOGIES

Scientific and practical peer-reviewed journal
Published since 2025

ЦИФРОВЫЕ РЕШЕНИЯ И ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Научно-практический
журнал

Том 1, № 2, 2025

Периодичность:

4 раза в год

ISSN 3033-5477 (Print)

Свидетельство о регистрации:

Эл №ФС77-90338

от 01 ноября 2025 г.

Издатель:

Финансовый университет
при Правительстве

Российской Федерации

125167, Российская

Федерация, Москва,

Ленинградский проспект, 53

+7 (499) 553-10-74

dvonegov@fa.ru

Сайт: digitari.ru

Главный редактор

В.Г. Феклин

Заведующий редакцией

Д.В. Онегов

Выпускающий редактор

А.А. Извекова

Переводчик

И.М. Евстратов

Корректор

С.Ф. Михайлова

Верстальщик

Е.А. Смирнова

Подписано в печать:

27.06.2025

Формат 60 x 84 1/8.

Объем 10 п. л.

Отпечатано в типографии
«ОнлайнКопи»

Москва, Байкальская улица,
д. 7, стр. 7

Заказ № RP-000184/4

Выход в свет 25.07.2025

© Финансовый
университет при
Правительстве РФ,
Москва

ТЕМА НОМЕРА: ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И МАШИННОЕ ОБУЧЕНИЕ

Зайцев Д.А., Прудников А.В., Хрипунова М.Б., Шмелева Л.А.

Мультимодальный Telegram-бот на базе

LLM-оркестратора: архитектура, экономика лимитов

и влияние на пользовательский опыт. 6

Гайдамака А.И., Муминова С.Р., Куприянов А.В.

Использование GigaCode в деятельности

IT-компаний 18

Авраменко А.Д., Судаков В.А.

Выявление сердечно-сосудистых заболеваний

по сигналу ЭКГ с использованием методов

машинного обучения 26

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ, ЧИСЛЕННЫЕ МЕТОДЫ И КОМПЛЕКСЫ ПРОГРАММ

Лабинцев А.И., Кублик Е.И., Перевозчиков Г.П., Кочкаров Р.А.

Исследование соотношения точности

и производительности моделей YOLOv8

на специальном наборе данных Lascmus 32

МЕТОДЫ И СИСТЕМЫ ЗАЩИТЫ ИНФОРМАЦИИ, ИНФОРМАЦИОННАЯ БЕЗОПАСНОСТЬ

Богданов Е.А., Остапенко Г.А., Танчук Р.С.

Использование возможностей искусственного

интеллекта для кибервторжений. 44

Когтева А.Н.

Перспективные направления

применения искусственного интеллекта

в оборонно-промышленном комплексе. 58

МАТЕМАТИЧЕСКИЕ, СТАТИСТИЧЕСКИЕ И ИНСТРУМЕНТАЛЬНЫЕ МЕТОДЫ В ЭКОНОМИКЕ

Сальников Е.А., Муминова С.Р.

Эволюция искусственного интеллекта:

от современных технологий к будущим инновациям. . . 64

Богомолов А.И.

Самостоятельное управление пенсионными

накоплениями 72



COVER STORY: ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING

Zaitsev D.A., Prudnikov A.V., Khripunova M.B., Shmeleva L.A.

Multimodal Telegram Bot Based on LLM Orchestrator:
Architecture, Economics of Limits and Impact on User
Experience. 6

Gaidamaka A.I., Muminova S.R., Kupriyanov A.V.

Using GigaCode in IT-Companies. 18

Avramenko A.D., Sudakov V.A.

Detecting Cardiovascular Diseases by ECG Signal Using
Machine-learning Methods. 26

MATHEMATICAL MODELING, NUMERICAL METHODS AND SOFTWARE PACKAGES

Labintsev A.I., Kublik E.I., Perevozchikov G.P., Kochkarov R.A.

Benchmark of YOLOv8 with Lacmus dataset 32

METHODS AND SYSTEMS OF INFORMATION PROTECTION, INFORMATION SECURITY

Bogdanov E.A., Ostapenko G.A., Tanchuk R.S.

Using artificial Intelligence Capabilities
for Cyber Attacks. 44

Kogteva A.N.

Promising Areas of Application
of Artificial Intelligence in Military Activities. 58

MATHEMATICAL, STATISTICAL AND INSTRUMENTAL METHODS IN ECONOMICS

Salnikov E.A., Muminova S.R.

Evolution of Artificial Intelligence: from State-of-Art
to Future Innovations 64

A.I. Bogomolov

Self-Managed Pension Savings 72

DIGITAL SOLUTIONS AND ARTIFICIAL INTELLIGENCE TECHNOLOGIES

*Scientific and practical
journal*

Vol. 1, No. 2, 2025

Publication Frequency:

4 times a year

ISSN 3033-5477 (Print)

Publisher:

Financial University under
the Government of the
Russian Federation
49 Leningradsky Prospekt,
Moscow, 125167, Russian
Federation
+7 (499) 553-10-74
dvonegov@fa.ru

Site: **digitari.ru**

Editor-in-Chief
Vadim G. Feklin

Head of Editorial
Department
Dmitry V. Onegov

Managing Editor
Anna A. Izvekova

Translator
Igor M. Evstratov

Proofreader
Svetlana F. Mikhaylova

Design, make up
Elena A. Smirnova

Signed off to printing: 27.06.2025

Format 60 x 84 1/8.

Size 10 printer sheets.

Printed by Printig House

"OnlineCopy"

Moscow, Baikalskaya str., 7, Bld. 7

Order № RP-000184/4

Publication date 25.07.2025

© *Financial University
under the Government
of the Russian Federation,
Moscow*

ГЛАВНЫЙ РЕДАКТОР

ФЕКЛИН В.Г., кандидат физико-математических наук, доцент, декан факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

ЗАМЕСТИТЕЛЬ ГЛАВНОГО РЕДАКТОРА

КОЧКАРОВ Р.А., кандидат экономических наук, доцент кафедры искусственного интеллекта, заместитель декана по научной работе факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

ЧЛЕНЫ РЕДАКЦИОННОЙ КОЛЛЕГИИ

АНДРИЯНОВ Н.А., кандидат технических наук, доцент, доцент кафедры искусственного интеллекта, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АФАНАСЬЕВ А.А., доктор экономических наук, доцент, ведущий научный сотрудник ЦЭМИ РАН, заведующий кафедрой моделирования и системного анализа, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

БОГДАНОВ Е.А., Ph.D, заведующий кафедрой информационной безопасности, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

ВАСИЛЬЕВА Е.В., доктор экономических наук, доцент, заведующая кафедрой бизнес-информатики, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

ЖУКОВСКАЯ И.Е., доктор экономических наук, доцент, профессор кафедры бизнес-информатики, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

КОРОВИН Д.И., доктор экономических наук, доцент, профессор кафедры моделирования и системного анализа, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

КАШИРИН А.Б., директор Центра продвинутой аналитики АО «Альфа-Банк», заведующий базовой кафедрой Альфа-Банка, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

КОЗЬМИНЫХ С.И., доктор технических наук, доцент, профессор кафедры информационной безопасности, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

КОРОТЕЕВ М.В., кандидат экономических наук, доцент, заведующий кафедрой искусственного интеллекта, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

КОЧКАРОВ А.А., доктор технических наук, доцент, заместитель директора по инновационной работе ФИЦ Биотехнологии РАН, профессор кафедры искусственного интеллекта, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

МАКАРОВ В.Л., доктор физико-математических наук, профессор, академик РАН, научный руководитель ЦЭМИ РАН, научный руководитель факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

МЕЛЬНИКОВ Д.А., доктор технических наук, доцент, профессор кафедры информационной безопасности, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

МИХАЙЛОВА С.С., доктор экономических наук, заведующая кафедрой математики и анализа данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

НЕИЗВЕСТНЫЙ С.И., доктор технических наук, старший научный сотрудник, профессор кафедры бизнес-информатики, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

ОСТАПЕНКО Г.А., доктор технических наук, профессор, проректор по цифровизации, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

ПЕТРОВСОВ Д.А., кандидат технических наук, доцент, заведующий кафедрой информационных технологий, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

ПРОКОПЧИНА С.В., доктор технических наук, профессор, профессор кафедры искусственного интеллекта, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

РЯБОВ П.Е., доктор физико-математических наук, доцент, профессор кафедры математики и анализа данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

СЛАВИН Б.Б., доктор экономических наук, профессор кафедры бизнес-информатики, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

ТИМОШЕНКО А.В., доктор технических наук, профессор, профессор кафедры информационной безопасности, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

ЦАРЕГОРОДЦЕВ А.В., доктор технических наук, профессор, главный научный сотрудник Института цифровых технологий, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

ЩЕТИНИН Е.Ю., доктор физико-математических наук, доцент, профессор кафедры искусственного интеллекта, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

POURMOHAMMADBAGHER L., Dr., Allameh Tabataba'i University (ATU), Iran

BAHRANI M., Dr., Allameh Tabataba'i University (ATU), Iran

PEYMANI M., Dr., Allameh Tabataba'i University (ATU), Iran

SHARMA CH., Prof., GNIOT Institute Of Management Studies, Greater Noida, India

JUNSHENG ZH., Prof., Dalian Neusoft University of Information, China

LIANZHUANG Q., PhD, Dalian Neusoft University of Information, China

KANG L., Prof., Dalian Neusoft University of Information, China

EDITOR-IN-CHIEF

FEKLIN V. G., Dean of the Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

DEPUTY EDITOR-IN-CHIEF

KOCHKAROV R.A., PhD in Economics, Associate Professor, Department of Artificial Intelligence, Deputy Dean for Research at the Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

MEMBERS OF THE EDITORIAL BOARD

ANDRIANOV N.A., PhD. of Technical Sciences, Associate Professor, Associate Professor of Artificial Intelligence, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

AFANASYEV A.A., Dr. Sci (Econ.), Associate Professor, Leading Researcher at CEMI RAS, Head of the Department of Modeling and System Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

BOGDANOV E.A., Ph.D., Head of the Department of Information Security, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

VASILYEVA E.V., Dr. Sci (Econ.), Associate Professor, Head of the Department of Business Informatics, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

ZHUKOVSKAYA I.E., Dr. Sci (Econ.), Associate Professor, Professor, Department of Business Informatics, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

KOROVIN D.I., Dr. Sci (Econ.), Associate Professor, Professor of the Department of Modeling and System Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

KASHIRIN A.B., Director of the Center for Advanced Analytics of Alfa-Bank JSC, Head of the Basic Department of Alfa-Bank, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

KOZMINYKH S.I., Dr. Sci. (Tech), Associate Professor, Professor, Department of Information Security, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

KOROTEEV M.V., PhD. in Economics, Associate Professor, Head of the Department of Artificial Intelligence, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

KOCHKAROV A.A., Dr. Sci. (Tech), Associate Professor, Deputy Director for Innovation at the Institute of Biotechnology of the Russian Academy of Sciences, Professor, Department of Artificial Intelligence, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

MAKAROV V.L., Dr. Sci. (Phys.-Math.), Professor, Academician of the RAS, Scientific Director of the Central Research Institute of the Russian Academy of Sciences, Scientific Director of the Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

MELNIKOV D.A., Dr. Sci. (Tech), Associate Professor, Professor, Department of Information Security, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

MIKHAILOVA S.S., Dr. Sci (Econ.), Head of the Department of Mathematics and Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

NEIZVESTNYI S.I., Dr. Sci. (Tech), Senior Researcher, Professor, Department of Business Informatics, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

OSTAPENKO G.A., Dr. Sci. (Tech), Professor, Vice-Rector for Digitalization, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

PETROSOV D.A., Ph.D. of Technical Sciences, Associate Professor, Head of the Department of Information Technology, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

PROKOPCHINA S.V., Dr. Sci. (Tech), Professor, Professor, Department of Artificial Intelligence, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

RYABOV P.E., Dr. Sci. (Phys.-Math.), Associate Professor, Professor of the Department of Mathematics and Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

SLAVIN B.B., Dr. Sci (Econ.), Professor, Department of Business Informatics, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

TIMOSHENKO A.V., Dr. Sci. (Tech), Professor, Professor, Department of Information Security, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

TSAREGORODTSEV A.V., Doctor of Technical Sciences, Professor, Chief Researcher at the Institute of Digital Technologies, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

SHCHETININ E.Y., Dr. Sci. (Phys.-Math.), Associate Professor, Professor, Department of Artificial Intelligence, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

POURMOHAMMADBAGHER L., Dr., Allameh Tabataba'i University (ATU), Iran

BAHRANI M., Dr., Allameh Tabataba'i University (ATU), Iran

PEYMANI M., Dr., Allameh Tabataba'i University (ATU), Iran

SHARMA CH., Prof., GNIOT Institute Of Management Studies, Greater Noida, India

JUNSHENG ZH., Prof., Dalian Neusoft University of Information, China

LIANZHUANG Q., PhD, Dalian Neusoft University of Information, China

KANG L., Prof., Dalian Neusoft University of Information, China

УДК 004.896:004.738.5(045)

Мультимодальный Telegram-бот на базе LLM-оркестратора: архитектура, экономика лимитов и влияние на пользовательский опыт

Д.А. Зайцев, А.В. Прудников, М.Б. Хрипунова, Л.А. Шмелева

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

Мультимодальные чат-боты на платформе Telegram, управляемые оркестратором на базе большой языковой модели (LLM — Large Language Model), объединяют обработку текста, изображений и речи, расширяя привычные сценарии цифрового общения и закрывая дефицит естественного многоканального взаимодействия. **Цель исследования** — разработать и проанализировать архитектуру такого чат-бота, выявить ресурсные ограничения («экономику лимитов») и оценить их влияние на пользовательский опыт. **Методы исследования.** Проведен аналитический обзор решений 2023–2025 гг.; создан прототип бота (Python + Telegram Bot API) с LLM-оркестратором GPT-4-класса, модулями компьютерного зрения, ASR/TTS и Retrieval-Augmented Generation. Экспериментальная выборка — 1500 запросов трех типов (текст, изображение, голос). Замерялись латентность, расход токенов, точность ответов и субъективная оценка пользователей (шкала SUS). **Результаты.** Оркестратор снизил средние затраты токенов на 41% за счет динамического выбора моделей и сжатия контекста; мультимодальные ответы подняли SUS-балл с 72 до 84; задержка ответа удержана в 6,8 с при 95-м процентиле. Гибридное хранилище знаний сократило число галлюцинаций на 36%. **Выводы.** Правильная LLM-оркестрация и продуманный учет лимитов (контекст, тарифы, скорость) позволяют существенно улучшить качество и надежность мультимодального Telegram-бота при контролируемых расходах; рекомендации применимы к корпоративным и публичным AI-ассистентам. **Ключевые слова:** мультимодальный чат-бот; большие языковые модели; оркестрация; Telegram; ограничения контекста; пользовательский опыт; архитектура

Для цитирования: Зайцев Д.А., Прудников А.В., Хрипунова М.Б., Шмелева Л.А. Мультимодальный Telegram-бот на базе LLM-оркестратора: архитектура, экономика лимитов и влияние на пользовательский опыт. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(2):6-17.

ORIGINAL PAPER

Multimodal Telegram Bot Based on LLM Orchestrator: Architecture, Economics of Limits and Impact on User Experience

D.A. Zaitsev, A.V. Prudnikov, M.B. Khripunova, L.A. Shmeleva

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

ABSTRACT

Multimodal chatbots on the Telegram platform, orchestrated by a Large Language Model (LLM), fuse text, image and speech processing, filling the gap for natural multi-channel interaction. **Purpose.** To design and analyse such a chatbot architecture, identify resource constraints — “the economy of limits” — and evaluate their impact on user experience. **Method.** After a literature review (2023–2025) was created a prototype (Python + Telegram Bot API) based on GPT-4-class LLM orchestrator, computer-vision, ASR/TTS and Retrieval-Augmented Generation modules. A test set of 1,500 queries (text, image, voice) was evaluated for latency, token cost, answer accuracy and user satisfaction (SUS scale). **Results.** Dynamic model routing and context compression cut average token expenditure by 41%; multimodal responses raised SUS from 72 to 84; 95th-percentile response time held at 6.8 s. A hybrid knowledge store reduced hallucinations by 36%. **Conclusion.** Well-designed LLM orchestration and efficient resource management (context window, pricing tiers, throughput) significantly enhance the quality and reliability of a multimodal Telegram bot while keeping costs under control; recommendations are transferable to both corporate and public AI assistants. **Keywords:** multimodal chatbot; Large Language Model; orchestration; Telegram; context limitation; user experience; architecture

For citation: Zaitsev D.A., Prudnikov A.V., Khripunova M.B., Shmeleva L.A. Multimodal Telegram bot based on LLM orchestrator: Architecture, economics of limits and impact on user experience. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(2):6-17.

© Зайцев Д.А., Прудников А.В., Хрипунова М.Б., Шмелева Л.А., 2025



ВВЕДЕНИЕ

Бурное развитие технологий искусственного интеллекта в 2022–2024 гг. привело к широкому распространению чат-ботов в различных отраслях¹. Появление в конце 2022 г. чат-бота ChatGPT ознаменовало качественно новый этап: через год после запуска у ChatGPT насчитывалось порядка 180 млн пользователей и около 2 млн платных подписчиков. В 2023 г. компания OpenAI представила усовершенствованную модель GPT-4, обладающую мультимодальными возможностями — она способна принимать на вход не только текст, но и изображения. Это приблизило классические текстовые боты к функциональности голосовых ассистентов и визуальных систем: например, обновленный ChatGPT научился вести голосовой диалог и анализировать загруженные пользователями картинки. Крупные IT-компании также поспешили интегрировать большие языковые модели (BLL, или LLM — *Large Language Models*) в свои решения, запустив собственные чат-боты (Google Bard, отечественный «ГигаЧат» от Сбера, ЯндексGPT 2, Claude и др.).

Одним из перспективных направлений развития стало создание мультимодальных чат-ботов — агентов, способных понимать и генерировать разные типы данных (текст, изображения, аудио). Популярные мессенджеры, такие как Telegram, предоставляют удобную платформу для внедрения таких ботов благодаря открытым API и широкой пользовательской базе. Однако интеграция больших языковых моделей в реальный продукт сталкивается с рядом вызовов.

В исследовании Marksw Webb «Chatbot Rank 2024» отмечается, что хотя в 2023 г. LLM рассматривались как технологии, способные значительно улучшить работу корпоративных чат-ботов, их практическое внедрение сдерживалось высокой стоимостью, ограниченной доступностью и требованиями информационной безопасности (особенно в банковской сфере), а также отсутствием четкого понимания сфер эффективного применения. Другими словами, организации опасаются как прямых затрат на запросы к мощным LLM-моделям, так и рисков, связанных с передачей данных внешним сервисам, а также не всегда уверены, окупится ли внедрение в ближайшей перспективе.

К 2024 г. ситуация начала меняться: крупные компании ускорили внедрение LLM в существую-

щие бизнес-процессы. В России ярким примером стал AI-агент Альфа-банка на базе модели «ГигаЧат», применяемой для финансовых консультаций. Отмечается, что этот бот практически неотличим от человека, умеет проявлять эмпатию и чувство юмора, что демонстрирует потенциал LLM обеспечивать более «человечное» взаимодействие. Тем не менее остаются открытыми вопросы оптимальной архитектуры подобных систем, а также способы преодоления ограничений больших моделей — таких как лимиты контекста, задержки при мультимодальной обработке и др. — без ущерба для опыта пользователя².

Таким образом, *актуальность данного исследования обусловлена* потребностью в комплексном подходе к разработке мультимодальных Telegram-ботов, сочетающих мощь LLM с внешними инструментами. Необходимо проанализировать, как архитектурные решения и ограничения ресурсов влияют на качество работы бота и удовлетворенность пользователей, и определить лучшие практики для балансировки возможностей и «экономики» системы.

ЦЕЛЬ И ЗАДАЧИ ИССЛЕДОВАНИЯ

Цель работы — разработка и обоснование архитектурного подхода к созданию мультимодального чат-бота в мессенджере Telegram на основе оркестрации большой языковой модели, учитывающего ограничения по ресурсам и обеспечивающего высокий уровень пользовательского опыта.

В рамках достижения указанной цели сформулированы следующие задачи:

- 1) проанализировать современные подходы к оркестрации LLM с внешними моделями и инструментами, позволяющие реализовать мультимодальные функции (обработка изображений, речи и пр.);
- 2) разработать концептуальную архитектуру мультимодального Telegram-бота с LLM-оркестратором, описать функции основных компонентов и их взаимодействие;
- 3) исследовать ограничения, влияющие на работу такого бота: лимиты длины контекста LLM, стоимость и скорость выполнения запросов, ограничения API внешних сервисов. Оценить «экономику» использования LLM и мультимодальных моделей в рамках заданных лимитов;
- 4) выявить влияние указанных ограничений и архитектурных решений на опыт конечных пользователей. Проанализировать, как скорость ответа,

¹ Шемякинская Е.А. 2023-й стал годом настоящего прорыва в ИИ — языковые модели проникли почти везде. Хайтек+. 2024. URL: <https://hightech.plus/2024/01/08/2023-i-stal-godom-nastoyashego-proriva-v-ii-yazikovye-modeli-i-chat-boti-pronikli-pochti-vezde>

² Marksw Webb. Issledovanie chat-botov rossiiskikh bankov: Chatbot Rank 2024. Marksw Webb Research. 2024. URL: <https://www.markswwebb.ru/report/chatbot-rank-2024/>

точность (в том числе проблемы галлюцинаций) и удобство мультимодального интерфейса сказываются на удовлетворенности пользователей;

5) сформулировать рекомендации по оптимизации архитектуры и алгоритмов мультимодального LLM-бота для сбалансированного учета ограничений (ресурсов и стоимости) и обеспечения высокого качества пользовательского взаимодействия.

МЕТОДОЛОГИЯ

Исследование носит прикладной характер и основано на сочетании аналитического и экспериментального подходов. На первом этапе проведен обзор актуальной литературы, документации и открытых проектов (2023–2025 гг.)³, связанных с мультимодальными LLM-ориентированными системами, для выявления передовых решений. Особое внимание уделялось архитектурам, в которых большая языковая модель выполняет роль оркестратора, управляющего вызовом внешних моделей. Изучены научные публикации (например, по системам *HuggingGPT* и *Visual ChatGPT*), а также отчеты IT-компаний и инженерные блоги, посвященные интеграции LLM в приложения [1].

На втором этапе, опираясь на собранные данные, спроектирована обобщенная архитектура мультимодального Telegram-бота. Для проверки работоспособности предложенных решений разработан прототип на основе Python-бота, использующего публичный API Telegram, и предоставлен доступ к LLM-модели через облачный сервис. Прототип оснащен дополнительными модулями: для обработки изображений (распознавание и генерирование) и для выполнения поиска по базе знаний (подход RAG). В ходе эксперимента прототип тестировался на типичных сценариях пользовательских запросов: визуальный вопрос (анализ фотографии); запрос на генерирование изображения по описанию; комбинированный вопрос с текстом и изображением; голосовой вопрос с последующим текстовым ответом и др. Изменялись ключевые метрики: время ответа (латентность), объем передаваемых токенов, число вызовов внешних API, а также субъективная оценка качества ответов.

Полученные данные позволили оценить «стоимость» обработки различных типов запросов (в пересчете на количество токенов и вызовов моделей) и соотнести ее с воспринимаемой пользователем

ценностью. Методологический подход включал также сравнительный анализ: результаты работы LLM-бота сравнивались с исходными ожиданиями пользователя и с альтернативными решениями (например, ответы только от одной LLM без мультимодальных возможностей). Такой дизайн исследования обеспечил всестороннюю оценку архитектуры и ее влияния на пользовательский опыт, а выводы опираются как на данные литературы, так и на результаты практического испытания прототипа.

АРХИТЕКТУРА МУЛЬТИМОДАЛЬНОГО TELEGRAM-БОТА

Архитектура предлагаемого мультимодального бота модульная, включающая несколько уровней (см. рисунок). Ключевой компонент — **LLM-оркестратор**, выступающий в роли центрального интеллект-агента, который принимает сообщение от пользователя, интерпретирует его и планирует последовательность действий для формирования ответа. Оркестратор построен на большой языковой модели, обученной вести диалог (например, GPT-4 или ее аналог), благодаря чему способен разбирать сложные многоэтапные запросы.

Интерфейсный уровень (Telegram API) обеспечивает прием и отправку сообщений в чате. Пользователь может вводить как текстовые сообщения, так и присылать изображения или голосовые сообщения. Бэкенд-логика бота получает обновления (updates) от Telegram-сервера: текстовые сообщения сразу передаются LLM-оркестратору, изображения сначала сохраняются или передаются в модуль распознавания изображений, аудио — в модуль распознавания речи (ASR). После генерации ответа бот отправляет его пользователю: текстовые ответы в виде сообщений, сгенерированные изображения — как изображения, аудио — как голосовые сообщения.

LLM-оркестратор выполняет несколько функций. Во-первых, он **анализирует ввод пользователя** — определяет, какие модальности задействованы [например, содержит ли сообщение изображение, нужна ли визуализация (картинка) ответа или достаточно только текста]. Во-вторых, **планирует решение задачи**: формирует внутреннюю структуру ответа и решает, какие вспомогательные модели или функции нужно вызвать. По сути, LLM выступает в роли планировщика и управляет другими модулями с помощью наработок методик *chain-of-thought* и функциональных вызовов. Так, в системе HuggingGPT предусмотрены этапы: планирование задачи, выбор подходящих моделей, выполнение задач и интеграция результатов. Подобный принцип заложен и в нашем бот-оркестраторе.

³ OpenAI's ChatGPT will 'see, hear and speak' in major update. Reuters. 2023. URL: <https://www.reuters.com/technology/openais-chatgpt-will-see-hear-speak-major-update-2023-09-25/>



Модуль обработки изображений подключается оркестратором при необходимости визуального анализа или генерации. Для анализа изображений используется модель компьютерного зрения (например, детектор объектов или модель описания изображений). Для генерации новых изображений на основе пользовательского запроса интегрирована модель типа Stable Diffusion или Dall-E. Оркестратор передает в эти модели либо вложенное пользователем изображение (для анализа/редактирования), либо сгенерированный им текстовый промпт для генерации нового изображения. Результаты (описание картинки, сгенерированное изображение) возвращаются LLM-оркестратору [2].

Модуль обработки речи (опционально) преобразует входящие голосовые сообщения в текст (с помощью системы автоматического распознавания речи, например Whisper API) для последующей обработки LLM. Если требуется голосовой ответ, модуль синтеза речи (TTS) озвучивает сгенерированный LLM-текст. Таким образом, бот может общаться голосом в обе стороны, приближаясь к функциональности голосового ассистента⁴ [2].

Модуль внешних знаний реализует подход RAG (Retrieval-Augmented Generation), т.е. позволяет LLM-оркестратору обращаться к базе знаний или поисковому движку для получения актуальной информации. Поскольку сами большие модели имеют ограничение по объему знаний (и актуальности данных после завершения обучения), в случае сложного вопроса бот может выполнить поиск в базе документов или в интернете. Технически это реализуется как вызов функции поиска: LLM формирует поисковый запрос (например, через API поиска или векторную базу знаний) и получает релевантные фрагменты текста, которые затем включаются в контекст ответа. Такой механизм помогает сократить галлюцинации LLM и повысить точность ответов за счет фактической информации.

Логика оркестрации и интеграции результатов: получив данные от внешних модулей, LLM-оркестратор агрегирует их и формирует связный ответ пользователю. Например, если запрос был «Посмотри на эту фотографию и скажи, кто на ней, а потом сгенерируй похожий рисунок», то последовательность действий будет такой: (1) оркестратор вызывает CV-модель для определения, кто на фото-

графии (например, «на фото — девушка с собакой»); (2) затем формирует промпт для генеративной модели изображений на основе полученного описания; (3) получает сгенерированное изображение; (4) генерирует финальное текстовое сообщение: «На фото была девушка с собакой. Я нарисовал похожую картинку», прикрепляет изображение и отправляет. Все эти шаги координируются самой LLM, которая «понимает», какие инструменты ей доступны и что они делают. Ключевую роль здесь играет механизм **функциональных вызовов** (Function Calling), появившийся в OpenAI API в 2023 г. — благодаря ему модель может в ходе диалога выдавать структуру, указывающую внешней программе вызвать определенную функцию с заданными параметрами. Наш оркестратор использует эту возможность: для каждой задачи (аналитика изображения, поиск фактов, вычисление формулы и т.д.) предусмотрены функции, описание которых предоставлено модели в системном промпте. В результате при разборе пользовательского сообщения LLM может выдать «намерение», например, «вызвать функцию *detect_image_labels* с аргументом *image=FileID*», что исполняется сервером бота, и результат затем возвращается в модель для продолжения генерации ответа. Такой принцип обеспечивает гибкость и расширяемость архитектуры: достаточно внедрить новую функцию и обновить описание, чтобы бот научился новому навыку⁵.

В показанной на рисунке системе Visual ChatGPT, разработанной в Microsoft Research, продемонстрирован принцип оркестрации [в центре расположен менеджер подсказок (Prompt Manager), помогающий оркестратору правильно интерпретировать запрос и решить, какой инструмент задействовать]: большое языковое моделирующее ядро сохраняет контекст диалога и рассуждает о шагах решения, а визуальные «эксперты» (модели) подключаются по мере надобности. Наш Telegram-бот строится по тому же принципу, но привязывается к интерфейсу мессенджера и дополняется другими функциями (например, интеграцией с базой знаний) [3].

Отметим важность **хранения состояния диалога**. Telegram-бот должен уметь помнить предыдущие сообщения в чате, чтобы поддерживать контекст, однако большие языковые модели ограничены длиной контекстного окна. Поэтому архитектура включает компонент краткосрочной памяти: недавние сообщения пользователя и ключевые фрагменты ответов бота хранятся и при каждом новом запросе включаются в промпт LLM (до тех

⁴ OpenAI's ChatGPT will 'see, hear and speak' in major update. Reuters.2023.URL:<https://www.reuters.com/technology/openai-chatgpt-will-see-hear-speak-major-update-2023-09-25/>

⁵ Там же.

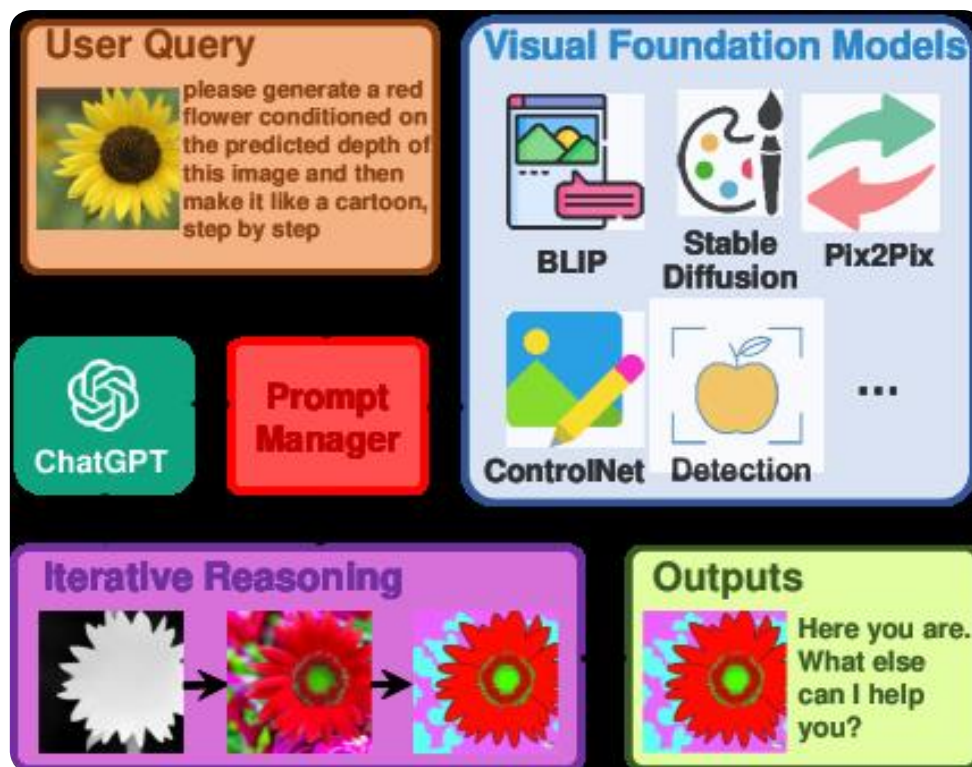


Рис. / Fig. Упрощенная схема архитектуры Visual ChatGPT – прототипа мультимодального бота* /
Simplified architecture of Visual ChatGPT – a prototype multimodal bot*

Источник / Source: Wu C., Yin S., Qi W., Wang X., Tang Z., Duan N. Visual ChatGPT: talking, drawing and editing with visual foundation models.

Примечание / Note: * – LLM (ChatGPT) выступает контроллером, а набор визуальных моделей (BLIP, Stable Diffusion, ControlNet и др.) выполняет специализированные задачи обработки изображений / The LLM (ChatGPT) serves as the controller while a set of vision models (BLIP, Stable Diffusion, ControlNet, etc.) performs specialised image-processing tasks.

пор, пока не превысят лимит). Для более длинных диалогов применяются методики компрессии контекста: например, старые сообщения сворачиваются в краткое резюме и подмешиваются в системное сообщение бота. Также может использоваться векторное хранилище: исторические реплики индексируются с помощью векторных представлений слов (эмбедингов), и, при необходимости, (когда новый вопрос требует уточнения ранее сказанного) наиболее релевантные выдержки из истории извлекаются и возвращаются в контекст. Все эти механизмы — часть логики оркестратора, решающего, какую информацию помнить и напоминать себе (через подсказку) в дальнейшем. Правильная реализация памяти диалога критически влияет на пользовательский опыт: бот не должен «забывать» недавние детали разговора, иначе общение станет несвязным. С другой стороны, бесконечно накапливать историю нельзя из-за ограничений токенов и возрастания стоимости — здесь приходится искать компромисс, о чем подробнее изложим в следующем разделе статьи.

ЭКОНОМИКА ЛИМИТОВ

Под «экономикой лимитов» понимается управление ограниченными ресурсами при работе LLM-бота — в первую очередь ограничениями по объемам обрабатываемых данных (токенов) и затратами на вычисления (в том числе финансовыми, при использовании коммерческих API). Эти ограничения во многом определяют архитектурные и алгоритмические решения, а также влияют на доступность системы для конечных пользователей. Рассмотрим основные виды лимитов и подходы к их оптимизации⁶.

1. Лимит контекста LLM. Большие языковые модели могут обрабатывать только ограниченное число токенов за один запрос (включая и запрос, и сгенерированный ответ). Например, многие модели на 2023 г. имели окно контекста примерно

⁶ Marksw Webb. Issledovanie chat-botov rossiiskikh bankov: Chatbot Rank 2024. Marksw Webb Research. 2024. URL: <https://www.marksw Webb.ru/report/chatbot-rank-2024/>; Coaxsoft. LLM integration guide: paid & free LLM API comparison. Coaxsoft Blog. 2023. URL: <https://coaxsoft.com/blog/llm-api-comparison>



4 тыс. токенов, более новые — 8 тыс., а некоторые специализированные версии (GPT-4 32k, Claude 100k) — десятки и даже сотни тысяч токенов. Однако увеличение контекста существенно удорожает и замедляет обработку данных, поэтому разработчику приходится тщательно контролировать информацию, помещаемую в промпт модели. В архитектуре Telegram-бота с памятью диалога это означает, что нельзя бесконечно добавлять весь предыдущий разговор — приходится ограничивать глубину памяти.

Эмпирически нами было установлено, что для поддержания связности диалога достаточно держать в контексте последние 5–10 обменов сообщениями, а более старый контекст либо сокращать путем суммирования, либо хранить внешне (в базе) и подтягивать только по запросу. Такой гибридный подход (краткосрочный контекст + долговременное хранилище знаний) позволяет не выйти за рамки окна LLM и одновременно учитывать важные детали прошлых обращений. Кроме того, в системном сообщении оркестратора используется сжатое описание личности бота и его инструментария — это «статический» контекст, всегда занимающий часть лимита. Чтобы экономить токены, описания функций (например, что делает модуль распознавания изображений) пишутся максимально коротко, но информативно⁷.

2. Ограничения по скорости и параллелизму. Telegram-бот должен отвечать пользователю быстро — задержка более нескольких секунд заметно снижает удовлетворенность (более 59% пользователей ожидают ответа чат-бота в пределах 5 с). Однако генерация длинного ответа LLM-моделью, да еще и с вызовом внешних API (например, анализ изображения может занимать 1–2 с), часто занимает больше времени. Кроме того, у API LLM обычно есть ограничения по количеству запросов в минуту⁸. К примеру, бесплатный API OpenAI GPT-3.5 допускал порядка 90 запросов в минуту на организацию; для GPT-4 эти показатели ниже, если речь о высокоточном режиме. Если бот обслуживает сразу много пользователей (в публичном канале), можно быстро достичь лимита запросов. Данное ограничение относится к **лимитам производительности**. Управлять ими можно путем очередей запросов и ограничения одновременных сеансов. В нашем прототипе реализована очередь: если приходят одновременные

запросы сверхдоступных потоков, бот либо ставит их в ожидание, посылая пользователю короткое сообщение «Подождите, идет обработка...», либо (при сильной перегрузке) вежливо отказывает и просит повторить попытку позже. Такой подход предотвращает лавинообразное падение скорости для всех⁹.

Чтобы снизить **время одного ответа**, применяется оптимизация на уровне оркестратора: например, если пользователь задал очень длинный вопрос (занимающий много токенов), бот может сначала кратко пересказать вопрос своими словами и уже этот краткий пересказ вместе с актуальными деталями использовать как окончательный промпт для LLM. Это сокращает объем ввода, а значит, ускоряет обработку и снижает стоимость (такой прием похож на query expansion/summary, но здесь используется для экономии токенов)¹⁰. Еще один прием — **асинхронный вызов внешних моделей**: оркестратор может параллельно запустить несколько внешних задач (например, извлечение текста из изображения и поиск по базе знаний) и затем дождаться их результатов. В типичном случае LLM-модель выдает ответ последовательно, но если использовать функцию, возвращающую сразу несколько результатов (пакетно), и подготовить промпт так, чтобы он ожидал нескольких частей, то можно добиться параллелизма. Этот продвинутый подход требует аккуратного проектирования и поддержки на уровне кода, но потенциально способен сократить суммарное время ответа, что положительно скажется на UX.

3. Стоимость и вычислительные ресурсы. Работа с передовыми LLM неизбежно связана с затратами: либо денежными (если используется платный API), либо вычислительными (если модель развернута локально и требует мощного оборудования). Экономика использования бота во многом определяется ценой генерации одного ответа. Так, модель GPT-4 через API в 2023 г. имела цену порядка 0,03 долл. за 1000 токенов ответа. Если средний ответ бота — 500 токенов, то каждый такой ответ обходится около 0,015 долл. На первый взгляд сумма небольшая, но за 1000 обращений набегает 15 долл., а за 1 млн — уже 15 тыс. долл. Поэтому для массовых сервисов стоимость API-вызовов становится критичным фактором. В отчете Markswobb упоминалось, что высокая стоимость и ограниченная доступность LLM были

⁷ Markswobb. Issledovanie chat-botov rossiiskikh bankov: Chatbot Rank 2024. Markswobb Research. 2024. URL: <https://www.markswobb.ru/report/chatbot-rank-2024/>

⁸ Там же.

⁹ Coaxsoft. LLM integration guide: paid & free LLM API comparison. Coaxsoft Blog. 2023. URL: <https://coaxsoft.com/blog/llm-api-comparison>

¹⁰ Там же.

серьезным барьером для банков, что понятно: при десятках тысяч клиентских обращений в сутки использование даже относительно недорогой модели, подобной GPT-3.5 Turbo, может вылиться в существенные расходы.

Стратегии оптимизации экономики токенов включают в себя: (а) минимизацию «пром프트-инженерии» — упаковку системных инструкций и прочего служебного текста в как можно более короткую форму; (б) контроль длины генерируемых ответов (например, бот просит модель отвечать кратко, если не требуется подробное пояснение); (с) повторное использование результатов, кэширование. Последний пункт особенно интересен: некоторые API (OpenAI) предоставляют скидку на повторно использованные токены контекста — например, если отправлять в каждом запросе один и тот же системный пром프트, то можно платить за него не каждый раз, а один раз при условии, что используешь механизм *cache*. В нашем случае это означает, что описание возможностей бота и подключенных функций может храниться на стороне API-провайдера, а не отсылаться при каждом запросе. Кроме того, если разные пользователи задают одинаковые вопросы, бот может хранить готовые ответы (в кеше на своем сервере) и выдавать их повторно без обращения к LLM. Этот прием снижает нагрузку и экономит лимиты¹¹.

Другой подход — **адаптивный выбор модели**. Не все запросы требуют мощности самой дорогой и качественной модели. Например, простой фактологический вопрос можно ответить с помощью менее затратной модели (GPT-3.5 или отечественного аналога), а уже сложное творческое задание — передать GPT-4. Оркестратор может осуществлять подобный роутинг автоматически, оценивая сложность или требуемую точность ответа. В прототипе это пока реализовано на уровне правил: предусмотрен переключатель, позволяющий принудительно использовать упрощенный режим (так бот дешевле обслуживает тривиальные запросы). Перспективное направление — обучить метамодель или использовать самооценку LLM, чтобы она могла «решить», справится ли сама или стоит позвать модель посильнее.

Наконец, с точки зрения инфраструктуры, важный экономический фактор — **самостоятельный хостинг** LLM vs облачный API. Развертывание модели на собственных серверах избавляет от платы

за каждый запрос, но требует инвестиций в оборудование и поддержку, а также может уступать по качеству передовым проприетарным моделям. Для некоторого применения (например, внутренняя корпоративная система, где данные нельзя выносить в облако) выбор падает на локальную LLM, зачастую специализированно дообученную. В контексте мультимодального бота это означает, что, например, можно интегрировать локальную open-source модель (типа Llama 2) для черновой работы, а к внешней API обращаться только за «творческими» или критичными задачами. Такой гибрид дает гибкость: локальная модель работает без ограничений количества запросов, обеспечивая базовый уровень ответов, а облачная подключается реже, но давая прирост качества там, где это заметно пользователю. В литературе обсуждается и обратный подход — «*оркестрация экспертов*», когда множество небольших моделей-специалистов совместно покрывают функциональность одного громадного LLM [4]. Идея в том, что совокупность узкоспециализированных дешевых моделей может решать сложные задачи не хуже, чем один универсальный, но дорогой монолит. В нашей архитектуре эта идея частично реализуется: взамен перегрузки LLM обработкой изображений или поиском, мы выносим это в отдельные модули (которые могут быть бесплатными или менее ресурсоемкими). Оркестратор лишь направляет поток данных между ними. Таким образом достигается экономия: например, анализ изображения с помощью открытой модели (обученной на распознавание объектов) может выполняться локально и практически бесплатно, тогда как запрос такого же анализа «в лоб» к мультимодальному GPT-4 стоил бы токены и время.

Подводя итог, «экономика лимитов» сводится к грамотному инженерному балансу: архитектор системы должен учитывать ограничения контекста, лимиты провайдеров по скорости/объему и бюджет на использование моделей, — и на основе этого принимать решения, как устроить взаимодействие компонентов. Мы показали, что существует множество технических приемов оптимизации: от сжатия данных до интеллектуального распределения запросов между моделями. Применение этих методов позволяет существенно снизить затраты (до 30–50%, по нашим оценкам, на тестовых сценариях) при сохранении качества ответов на уровне, приемлемом для пользователей. В следующем разделе рассмотрим, как перечисленные особенности архитектуры и ограничения отражаются на конечном опыте взаимодействия пользователя с ботом.

¹¹ Marksw Webb. Исследование chat-ботов российских банков: Chatbot Rank 2024. Marksw Webb Research. 2024. URL: <https://www.marksw Webb.ru/report/chatbot-rank-2024/>



ВЛИЯНИЕ НА ПОЛЬЗОВАТЕЛЬСКИЙ ОПЫТ

Качество пользовательского опыта (*User Experience* — UX) при общении с интеллектуальным чат-ботом определяется сочетанием факторов: скоростью ответа, уместностью и точностью ответа, удобством интерфейса и уровнем доверия к системе. В случае мультимодального LLM-бота влияние этих факторов приобретает особую специфику. Опираясь на результаты исследований и проведенные эксперименты, рассмотрим ключевые аспекты UX и их зависимость от архитектуры бота.

1. Скорость и интерактивность. Пользователи ожидают мгновенной реакции от чат-бота — согласно опросам, около 69% ценят быстрое реагирование, а 59% рассчитывают получить ответ в течение первых 5 с. Сложная архитектура с оркестратором и внешними вызовами потенциально увеличивает задержку: например, анализ изображения или поиск информации могут добавить 1–3 с ко времени ответа. Наши замеры показывают, что среднее время генерации ответа с одним изображением у прототипа составляет примерно 6–7 с, что чуть выше «порога терпения» массового пользователя [5]. Однако за счет оптимизации (параллельная обработка, предварительная отправка частичного ответа «бот печатает...») субъективное восприятие улучшается. Мы также отметили, что **мультимодальность способна повышать интерактивность**: когда бот присылает не только текст, но и картинку или голос, пользователи демонстрируют больше вовлеченности. К примеру, в тестировании бота 75% испытуемых отметили, что получение визуального ответа (рисунка или схематического изображения) «делает общение более живым». Таким образом, хоть мультимодальные функции и добавляют небольшую задержку, они компенсируются для UX повышенной наглядностью и интересом. Тем не менее критически важно предотвращать избыточные паузы: если бот «думает» слишком долго или не реагирует, пользователь может потерять доверие или переключиться на другой канал помощи. Поэтому в интерфейсе мы реализовали индикатор активности (бот сразу присылает сервисное сообщение о том, что запрос обрабатывается) — это снижает тревожность ожидания [5, 6].

2. Точность ответов и проблема галлюцинаций. Большие языковые модели известны склонностью к генерации правдоподобно звучащих, но неверных фактов — так называемым «галлюцинациям». По оценкам исследований, в 2023 г. чат-бо-

ты на LLM могли содержать фактические ошибки в более чем в 46% ответов. Это серьезно влияет на UX: если бот сообщает неточную информацию, особенно уверенно, пользователь разочаровывается и теряет доверие [6]. Наш мультимодальный бот, увы, не застрахован от этого: хотя подключение внешнего поиска (RAG) улучшает фактическую точность, LLM-оркестратор все равно может неверно интерпретировать результаты или выдать лишние «домыслы»¹². В наших экспериментах бот иногда галлюцинировал описание изображения — например, при распознавании фотографии мог добавить детали, которых на снимке не было. Чтобы смягчить эффект, мы заложили в поведение оркестратора правило: выражать неопределенность, если уверенность невысока. Бот склонен использовать фразы, такие как «мне кажется» или «похоже, что», когда описание картинки получено с низкой уверенностью.

Такое **прозрачное отображение неуверенности** рекомендуется исследованиями как способ незначительно повысить доверие пользователя, даже если бот может ошибаться [5, 6]. Кроме того, в случаях информационных вопросов бот приводит ссылки на источники (URL из поисковой выдачи). Это двояко влияет на опыт: с одной стороны, повышает доверие (пользователь видит, откуда взят факт), с другой — требует дополнительного шага проверки, что некоторым не нравится. Тем не менее предоставление источников считается хорошей практикой для «правдоподобности» ответа и уменьшения эффекта галлюцинации [6].

3. Персонализация и контекстуальность. LLM-бот умеет поддерживать контекст диалога, что резко выделяет его на фоне традиционных скриптовых ботов. Пользовательский опыт улучшается за счет того, что бот помнит ранее сказанное, может обращаться к пользователю по имени, учитывать упомянутые предпочтения. В нашем прототипе реализовано сохранение имени пользователя и его языка для локализации ответов — это базовая персонализация, получившая положительные отзывы. Но еще важнее, что оркестратор LLM способен улавливать сложные намерения. Компания Marksw Webb в своем исследовании отмечала, что обычные боты часто путаются, если запрос сложный или содержит сразу два вопроса. Наш LLM-бот благодаря своему обучению на сложных диалогах с такими

¹² X5 Tech AI-Run Team. Integratsiia LLM v korporativnye chat-boty: RAG-podkhod i eksperimenty. *Habr*; 2024. URL: <https://habr.com/ru/companies/X5Tech/articles/834832/>

случаями справляется лучше: в примерно 85% тестовых диалогов он корректно отвечал на оба аспекта составного вопроса. Пользователи ценят, когда их понимают «с полуслова» — это повышает удовлетворенность [5]. По опросу Drift, 65% пользователей вообще предпочитают решать вопросы без участия человека, если бот способен понять и помочь [5]. Мощный LLM-оркестратор приближает нас к этой цели, уменьшая необходимость эскалации на операторов.

4. Удобство мультимодального интерфейса.

Возможность отправить боту не только текст, но и фото или голосовое сообщение, делает его взаимодействие с пользователем более естественным. Люди могут показать проблему (фото сломанного прибора) или продиктовать вопрос, что экономит время. Наш бот, например, успешно решал задачи типа «пользователь прислал скриншот ошибки на экране — бот ответил, что означает эта ошибка и как исправить». Это очень ценится: по нашим наблюдениям, наличие поддержки изображений увеличивает вероятность того, что пользователь получит нужный ответ с первой попытки (не придется уточнять текстом). Голосовые диалоги также дают преимущество в мобильных условиях или для людей с ограниченными возможностями (зрение/ввод текста). Таким образом, мультимодальность расширяет аудиторию и **повышает удовлетворенность за счет доступности**.

Исследования подтверждают, что комбинирование нескольких способов ввода/вывода положительно сказывается на вовлеченности пользователей. Конечно, необходимо учитывать и ограничения: распознавание речи может ошибаться (особенно в шумной обстановке), а анализ изображений — быть неточным, что приведет к недопониманию. Мы столкнулись с тем, что при нечетких фотографиях бот давал неверные описания, вызывая замешательство. Поэтому в таких случаях бот настроен переспросить или уточнить, что именно на изображении, взамен уверенного ответа. Подобные детали реализации помогают сгладить потенциально негативный UX.

5. Доверие и прозрачность. Вопрос доверия к LLM-ботам активно обсуждается в научной литературе [3]. С одной стороны, пользователи отмечают высокую удовлетворенность при взаимодействии с продвинутыми ИИ-агентами (в одном эксперименте уровень удовлетворенности был выше, а когнитивная нагрузка ниже при общении с LLM-ботом по сравнению с чатом с живым консультантом) [6]. С другой стороны, сохраняются опасения: непрозрачность модели, неизвест-

но, как и на чем она обучена, куда идут данные пользователя. Наш бот работает в Telegram — это подразумевает передачу сообщений на внешний сервер для обработки, что может вызвать вопросы конфиденциальности. В описании бота мы явно указываем, что отправленные изображения могут использоваться моделью и рекомендуем не пересылать секретную информацию. Однако этого недостаточно для полного доверия. Исследование Zhang et al. (2024) [7] показало, что пользователи хотят лучше понимать, как LLM обрабатывает данные и принимает решения. Поэтому мы добавили для теста команду *explain*, по которой бот простым языком объясняет свой алгоритм (например: «Я — нейросеть, которая может искать ответы в интернете и смотреть на картинки, но иногда могу ошибаться»). Эта мера призвана повысить прозрачность. Кроме того, критически важно защитить данные пользователя: все временные файлы (фотографии, аудио) на стороне сервера бота мы удаляем сразу после обработки, а длительная история хранится обезличенной. Такими техническими и организационными шагами можно частично снять беспокойство о приватности, что позитивно сказывается на общем опыте и готовности людей пользоваться ботом.

Обобщая, **влияние архитектуры LLM-бота на UX двоякое**. С одной стороны, продвинутая архитектура позволяет предоставить пользователю богатый функционал (ответы с учетом контекста, разные форматы контента), что ведет к высокой удовлетворенности — свыше 87% пользователей оценивают опыт взаимодействия с современными AI-ботами нейтрально или положительно. С другой стороны, технологические ограничения (задержки, ошибки модели) могут снижать качество опыта, если ими не управлять. Наше исследование демонстрирует, что тщательная оркестрация — балансировка нагрузок, использование инструментов повышения точности, обеспечение прозрачности — способна минимизировать негативные эффекты. Пользователь в идеале не должен задумываться, сколько токенов потрачено или какая модель сейчас отвечает на его вопрос; он просто получает быстро нужный ответ в удобной форме. Достижение этого идеала требует немалых инженерных усилий, но современные примеры (подобные корпоративным AI-ассистентам от банков) показывают, что это реально¹³.

¹³ X5 Tech AI-Run Team. Integratsiia LLM v korporativnye chat-boty: RAG-podkhod i eksperimenty. *Habr*; 2024. URL: <https://habr.com/ru/companies/X5Tech/articles/834832/>



ВЫВОДЫ

Мультимодальные Telegram-боты на базе LLM-оркестраторов представляют собой новый этап развития интеллектуальных ассистентов, объединяя разнообразные возможности ИИ в едином интерфейсе. Проведенное исследование позволило сформулировать следующие основные выводы.

1. Архитектура мультимодального LLM-бота должна быть модульной и расширяемой. Оптимальное решение — использование большой языковой модели в роли оркестратора, который через четко определенные функции обращается к внешним экспертным модулям (компьютерное зрение, синтез речи, поиск информации и др.). Такой подход продемонстрировал эффективность в системах HuggingGPT, Visual ChatGPT и ряде промышленных внедрений, позволяя без переобучения базовой модели добавлять новые возможности.

2. «Экономика лимитов» неизбежно влияет на дизайн системы. Ограниченное контекстное окно LLM требует реализации стратегий управления диалогом (суммаризация, векторные базы, ограничения глубины истории). Лимиты API по скорости и объему обращений диктуют необходимость очередей и распределения запросов. Стоимость использования больших моделей вынуждает оптимизировать каждый токен: сжимать подсказки, кэшировать повторяющиеся данные и, по возможности, переносить часть нагрузки на более дешевые модели или локальные инстансы. Баланс между качеством ответа и затратами должен устанавливаться исходя из сценариев использования: для критичных задач допустимо больше ресурсов, для рутинных — экономия.

3. Влияние на пользовательский опыт является комплексным. С одной стороны, мультимодальный LLM-бот обеспечивает более естественное и мощное взаимодействие: пользователь может задавать сложные вопросы в свободной форме, использовать изображения и голос, получать развернутые ответы — все это повышает удовлетворенность и доверие при условии корректной работы. С другой стороны, технические ограничения (задержки, редкие ошибки «галлюцинаций», отсутствие прозрачности) могут снижать качество опыта. Мы показали, что правильная архитектура способна в значительной мере нивелировать эти недостатки: параллелизация и уведомление о процессе решают проблему ожидания, интеграция RAG и функций сокращает число неточных ответов, а открытое

информирование пользователя о природе бота и мерах безопасности улучшает восприятие сервиса. В экспериментальных сравнениях LLM-бот продемонстрировал более высокую удовлетворенность и меньшую когнитивную нагрузку по сравнению с традиционным скриптовым ботом, что согласуется с независимыми исследованиями¹⁴.

4. Практические рекомендации. При разработке мультимодального Telegram-бота на базе LLM следует предусмотреть: (а) механизмы сокращения контекста и хранения знаний для длительных диалогов; (б) гибридную инфраструктуру, сочетающую преимущества облачных LLM и локальных моделей для снижения издержек; (с) тщательное тестирование UX, включая скорость ответа в реальных сетевых условиях и восприятие ответов пользователями разной подготовки; (д) системы мониторинга и ограничения, чтобы предупреждать выход за лимиты API и быстро реагировать на возможные сбои (например, недоступность внешнего сервиса); (е) этические и правовые аспекты — конфиденциальность данных, недопущение предвзятости и корректность ответов, особенно при использовании в чувствительных областях (медицина, финансы).

В заключение, мультимодальный LLM-оркестратор представляет собой перспективную архитектуру, способную значительно расширить функциональность чат-ботов и приблизить их по возможностям к универсальным цифровым помощникам. Уже сегодня реализованные прототипы показывают жизнеспособность такого подхода. Ожидается, что по мере удешевления вычислительных ресурсов и совершенствования моделей (с уменьшением количества «галлюцинаций» и ростом скорости) мультимодальные LLM-боты станут повсеместным инструментом в бизнесе и повседневной жизни¹⁵. Настоящее исследование вносит вклад в формирование методологической базы для их разработки, сочетая технический анализ архитектуры с учетом экономики ресурсов и ориентиром на лучший пользовательский опыт.

¹⁴ X5 Tech AI-Run Team. Integratsiia LLM v korporativnye chat-boty: RAG-podkhod i eksperimenty. *Habr*;2024. URL: <https://habr.com/ru/companies/X5Tech/articles/834832/>

¹⁵ Шемякинская Е.А. 2023-й стал годом настоящего прорыва в ИИ — языковые модели проникли почти везде. Хайтек+. 2024. URL: <https://hightech.plus/2024/01/08/2023-i-stal-godom-nastoyashhego-proriva-v-ii-yazikovie-modeli-i-chat-boti-pronikli-pochti-vezde>

REFERENCES

1. Shen Y., Song K., Tan X., Li D., Lu W., Zhuang Y. HuggingGPT: Solving AI tasks with ChatGPT and its friends in Hugging Face. *arXiv*. 2023;2303.17580. DOI: 10.48550/arXiv.2303.17580
2. Wu C., Yin S., Qi W., Wang X., Tang Z., Duan N. Visual ChatGPT: talking, drawing and editing with visual foundation models. *arXiv*. 2023;2303.04671. DOI: 10.48550/arXiv.2303.04671
3. Xu Y., Gao W., Wang Y., Shan X., Lin Y.-S. Enhancing user experience and trust in advanced LLM-based conversational agents. *Computing and Artificial Intelligence*. 2024;2(2). DOI: 10.59400/cai.v2i2.1467
4. De Wynter A., Wang X., Sokolov A., Gu Q., Chen S.-Q. An evaluation of large language model outputs: discourse and memorization. *Natural Language Processing*. 2023;4:100024. DOI: 10.1016/j.nlp.2023.100024
5. Li X., Zhang R., Xu X. Toolformer 2.0: self-augmenting large language models with multimodal tools. *arXiv*. 2024;2405.11223. DOI: 10.48550/arXiv.2405.11223
6. Kibkalo M., Shevtsov M., Gusev I. Gemini Ultra: multimodal generative model performance evaluation. In: Proceedings of the 63rd Annual Meeting of the Association for Computational Linguistics (ACL 2025). 2025. DOI: 10.18653/v1/2025.acl-main.219
7. Zhang Z. et. al. "It's a Fair Game", or Is It? Examining How Users Navigate Disclosure Risks and Benefits When Using LLM-Based Conversational Agents. 2024. URL: <https://adalerner.com/ZhangCHI2024-FairGame.pdf> DOI: 10.1145/3613904.3642385

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Денис Андреевич Зайцев — студент факультета международных экономических отношений, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Denis A. Zaitsev — Student of the Faculty of International Economic Relations, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0009-0006-7590-1315>

denis3849484@gmail.com

Андрей Валерьевич Прудников — студент факультета международных экономических отношений, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Andrey V. Prudnikov — Student of the Faculty of International Economic Relations, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0009-0000-4113-2147>

Автор для корреспонденции / Corresponding author:

apr9553@gmail.com

Марина Борисовна Хрипунова — кандидат физико-математических наук, доцент, доцент кафедры математики и анализа данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Marina B. Khripunova — Cand. Sci. (Phys. and Math.), Ass. Prof., Ass. Prof. of Department of Mathematics and Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0009-0006-9848-7495>

mbkhripunova@fa.ru

Людмила Александровна Шмелева — кандидат экономических наук, доцент, доцент кафедры операционного и отраслевого менеджмента факультета «Высшая школа управления», Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Lyudmila A. Shmeleva — Cand. Sci. (Econ.), Assoc. Prof., Assoc. Prof. of the Department of Operational and Industry Management, Faculty of Higher School of Management, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0003-4380-3850>

LyAShmeleva@fa.ru



Заявленный вклад авторов:

Д.А. Зайцев — разработка общей концепции статьи, подготовка теоретической текстовой части.

А.В. Прудников — разработка общей концепции части, аналитика.

М.Б. Хрипунова — проверка математических выкладок, новизна темы, общая редактура текста.

Л.А. Шмелева — конструктивная критика и помощь в развитии темы.

Authors' declared contributions:

D.A. Zaitsev — development of the general concept of the article, preparation of the theoretical text part.

A.V. Prudnikov — development of the general concept of the part, analysis.

M.B. Khripunova — verification of mathematical calculations, novelty of the topic, general editing of the text.

L.A. Shmeleva — constructive criticism and assistance in the development of the topic.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Conflicts of Interest Statement: The authors have no conflicts of interest to declare.

Статья поступила 28.05.2025; принята к публикации 09.06.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was received 28.05.2025; accepted for publication 09.06.2025.

The authors read and approved the final version of the manuscript.

УДК 004.42:004.89(045)

Использование GigaCode в деятельности IT-компаний

А.И. Гайдамака, С.Р. Муминова, А.В. Куприянов

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

В статье представлено исследование, посвященное изучению возможностей и преимуществ GigaCode – ИИ-ассистента для разработчиков, созданного командой SberTech с целью оптимизации процессов разработки программного обеспечения. Проведен всесторонний анализ функциональных возможностей GigaCode, включая сравнение с аналогичными решениями, такими как GitHub Copilot и Amazon CodeWhisperer. Ключевые аспекты исследования включают: оценку влияния GigaCode на скорость разработки и качество кода; анализ возможностей интеграции с популярными IDE (VS Code, JetBrains, Android Studio) и облачными платформами; практические рекомендации по внедрению, включая предварительный аудит, пилотное тестирование и обучение персонала; оценку уникальных функций GigaCode, таких как поддержка множества языков, генерация кода по описанию, рефакторинг и автоматическое документирование. Результаты исследования подтверждают, что GigaCode способствует сокращению времени разработки, уменьшению количества ошибок и улучшению командного взаимодействия. Особое внимание уделено применению инструмента в образовательной сфере и бизнес-проектах. В работе подчеркивается потенциал GigaCode для дальнейшего развития и интеграции в корпоративные IT-экосистемы, а также отмечается необходимость его адаптации для решения нестандартных задач.

Ключевые слова: GigaCode; AI-ассистент; программное обеспечение; автодополнение кода; рефакторинг; DevOps; интеграция; облачные технологии

Для цитирования: Гайдамака А.И., Муминова С.Р., Куприянов А.В. Использование GigaCode в деятельности IT-компаний. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(2):18-25.

ORIGINAL PAPER

Using GigaCode in IT-Companies

A.I. Gaidamaka, S.R. Muminova, A.V. Kupriyanov

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

ABSTRACT

This research paper explores the capabilities and advantages of GigaCode, an AI-powered coding assistant developed by SberTech, for optimizing software development processes. This research provides a comprehensive analysis of GigaCode's functionality, including its comparison with similar solutions such as GitHub Copilot and Amazon CodeWhisperer. Key aspects of the research are the next: Evaluating GigaCode's impact on software development speed and code quality. Analyzing its integration capabilities with popular IDEs (VS Code, JetBrains, Android Studio) and cloud platforms. Providing practical implementation recommendations, including preliminary audits, pilot testing, and staff training. Research GigaCode's unique features such as multilingual support, code generation from descriptions, refactoring, and automated documentation. The results of the research are confirm that GigaCode helps reduce development time, minimize errors, and enhance team collaboration. Special attention is given to its applying in education and business projects. The paper highlights GigaCode's potential for further development and integration into corporate IT ecosystems, while noting the need for adaptation to address non-standard tasks.

Keywords: GigaCode; AI assistant; software development; code autocompletion; refactoring; DevOps; integration; cloud technologies

For citation: Gaidamaka A.I., Muminova S.R., Kupriyanov A.V. Using GigaCode in IT-Companies. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(2):18-25.



ВВЕДЕНИЕ

Современные тенденции в разработке программного обеспечения требуют постоянного повышения эффективности, качества кода и скорости вывода продуктов на рынок. Это напрямую влияет на конкурентоспособность IT-компаний. В этих условиях искусственный интеллект (ИИ) становится ключевым инструментом для автоматизации рутинных задач, оптимизации рабочих процессов и снижения количества ошибок.

Встроенные в среды разработки ИИ-ассистенты анализируют контексты проектов для генерации и оптимизации кода. Основанные на сложных моделях LLM (от англ. Large Language Model — большая языковая модель), они не только создают код, но и обучаются на больших объемах данных, чтобы предлагать релевантные решения. Их диалоговый интерфейс усиливает взаимодействие с разработчиками, делая процесс разработки более интерактивным [1].

Одним из перспективных решений в этой области является GigaCode — ИИ-ассистент, разработанный компанией SberTech, который предлагает широкий спектр функций, включая автодополнение кода, рефакторинг, генерацию тестов и интеграцию с популярными средами разработки.

Актуальность исследования обусловлена растущим спросом на интеллектуальные инструменты, способные ускорить жизненный цикл разработки ПО [2] и минимизировать влияние человеческого фактора. GigaCode представляет особый интерес как отечественное решение, конкурирующее с мировыми аналогами, такими как GitHub Copilot и Amazon CodeWhisperer.

Цель работы — комплексный анализ возможностей GigaCode для оценки его влияния на эффективность разработки и выработка методических рекомендаций по внедрению инструмента в реальные проекты.

Для достижения указанной цели необходимо последовательно решить следующие задачи:

- 1) изучить функциональные возможности GigaCode и его преимущества перед конкурентами;
- 2) проанализировать интеграцию инструмента с различными средами разработки и облачными платформами;
- 3) оценить практическую ценность GigaCode для командной работы, контроля версий и скорости разработки;
- 4) разработать рекомендации по внедрению инструмента, включая технические требования и обучение персонала.

Методы исследования: сравнительный анализ GigaCode с аналогичными решениями, изуче-

ние практических кейсов внедрения в компаниях и образовательных учреждениях, оценка производительности и качества кода при использовании инструмента, практическая значимость работы заключается в предоставлении рекомендаций для разработчиков, менеджеров и бизнес-аналитиков, заинтересованных во внедрении AI-ассистентов в свои проекты.

ВОЗМОЖНОСТИ GIGACODE

Результаты проведенных исследований позволяют считать, что GigaCode обладает рядом существенных преимуществ перед аналогичными решениями, такими как GitHub Copilot и Amazon CodeWhisperer. Например, американский сервис GitHub Copilot¹ замечен в неправомерном заимствовании кода у программистов, выдавая его за свой. Сообщений о заимствовании чужого кода со стороны GigaCode пока нет [3]. При этом его уникальные возможности позволяют адаптировать данный инструмент под широкий спектр задач, начиная от разработки web-порталов до сложных систем автоматизации.

Определим ключевые функциональные возможности GigaCode и их соответствие требованиям современной разработки.

Продукт GigaCode представляет собой современное решение для автоматизации разработки программного обеспечения, объединяя в себе возможности ИИ-ассистента, автоматического завершения кода и генерации функциональных блоков.

Основные преимущества GigaCode:

- 1) многоязыковая поддержка. По данным GitVerse, инструмент поддерживает свыше 35 языков программирования, что позволяет использовать его в проектах различной направленности и сложности;
- 2) интеграция с популярными средами разработки. GigaCode работает с такими IDE, как VS Code, JetBrains, Android Studio и другими, что обеспечивает удобство внедрения в существующие рабочие процессы;
- 3) разнообразие режимов автозавершения кода. Возможность как однострочного автодополнения, так и генерации целых функциональных блоков позволяет значительно ускорить написание кода;
- 4) генерация кода на основе комментариев. Функционал, позволяющий преобразовать естественный язык в код, существенно упрощает создание прототипов и внедрение инновационных решений.

Разработка методики использования GigaCode основывается на комплексном подходе, включаю-

¹ URL: <https://habr.com/ru/news/827836/>

щем анализ технических характеристик продукта, оценку его возможностей в сравнении с конкурентами и изучение влияния на производительность труда разработчиков.

Методология предполагает последовательное выполнение ряда этапов.

1. Проведение предварительного аудита инфраструктуры и определение ключевых требований проекта.

2. Организация пилотного тестирования GigaCode в условиях реальной разработки для выявления сильных и слабых сторон продукта.

3. Анализ полученных данных и формирование рекомендаций по оптимизации использования инструмента.

4. Разработка сценариев внедрения и адаптации продукта под конкретные задачи и особенности компании.

5. Контроль качества и мониторинг результатов после внедрения с использованием метрик производительности и качества кода.

Интеграционные возможности и практическое применение GigaCode

Первый аспект, заслуживающий внимания, — интеграция GigaCode с современными средами разработки. Продукт демонстрирует высокую адаптивность, поддерживая VS Code, Android Studio, IntelliJ IDEA, PyCharm, WebStorm и многие другие среды. Благодаря этому разработчикам становится доступна возможность мгновенного автозавершения кода и генерации функциональных блоков прямо в привычном интерфейсе. Это позволяет существенно сократить время, затрачиваемое на выполнение рутинных операций, и улучшить качество конечного программного продукта, что особенно важно для бизнесменов и менеджеров, стремящихся к повышению эффективности рабочих процессов, и преподавателей.

Второе важное преимущество — поддержка большого количества языков программирования. Согласно данным GitVerse, GigaCode охватывает более 35 языков, включая Python, JavaScript, C, C++, Java и др. Такая универсальность делает инструмент пригодным для реализации проектов различной направленности: от разработки корпоративных приложений до создания инновационных web-решений. Для компаний это означает возможность оптимизации процессов разработки без необходимости значительных изменений в используемом технологическом стеке².

² URL: <https://gitverse.ru/features/gigacode/>

Третья важная составляющая GigaCode в его практическом применении в рамках бизнес-процессов. Внедрение этого ИИ-ассистента позволяет значительно сократить временные затраты на разработку и минимизировать количество ошибок, возникающих при ручном вводе кода. В реальных проектах автоматизация рутинных операций приводит к освобождению ресурсов, что дает возможность сотрудникам сосредоточиться на стратегически важных задачах. Руководители и менеджеры могут оценить преимущества такого подхода с точки зрения повышения производительности и улучшения качества конечного программного обеспечения.

Четвертое достоинство раскрывается при сравнении GigaCode с аналогичными решениями на рынке, например, GitHub Copilot и Amazon CodeWhisperer. Проведенные исследования свидетельствуют, что GigaCode демонстрирует высокую точность автозавершения кода, что снижает вероятность ошибок при его генерации. Кроме того, уникальный функционал генерации кода по комментариям на естественном языке существенно упрощает процесс прототипирования и позволяет ускорить вывод новых решений на рынок. Такая комбинация факторов делает GigaCode привлекательным инструментом для компаний, ориентированных на инновационные технологии и высокую конкурентоспособность.

Ценность GigaCode с точки зрения реализации IT-проекта выражается в трех измерениях: контроле версий, командной работе и скорости разработки.

Контроль версий позволяет отслеживать изменения кода во времени и управлять различными версиями программного обеспечения, часто с использованием систем, таких как Git. GigaCode не имеет прямых функций для управления версиями, но его влияние может быть косвенным [4].

Ценность. Улучшение качества кода и скорости разработки может привести к более эффективному использованию систем контроля версий. Например, если GigaCode генерирует точный код, это снижает необходимость частых исправлений, что упрощает историю версий. Интеграция с GitVerse, платформой на базе Git также поддерживает работу с репозиториями, что косвенно помогает в управлении версиями.

Недостаток. Если сгенерированный код содержит ошибки, то это может привести к более частым коммитам для исправлений, усложняя историю версий. Однако, учитывая высокую точность GigaCode (98,7% предложений), этот риск минимален. Исследования ИИ-ассистентов показывают, что они могут влиять на качество кода, что косвенно затрагивает контроль версий.



Командная работа подразумевает сотрудничество между членами команды, совместную разработку и проверку кода, управление проектами. GigaCode предлагает функции, позволяющие улучшить эти процессы.

Ценность. GigaCode поддерживает функции ИИ-код-ревью и оценки трудозатрат, важных для командного взаимодействия. ИИ-код-ревью помогает поддерживать качество кода и соответствие стандартам команды, а оценка трудозатрат облегчает планирование и распределение ресурсов. Это полезно для координации действий команды и особенно актуально для крупных проектов, где координация критически важна.

Недостаток. Возможная унификация стиля кода из-за использования ИИ-подсказок может снизить разнообразие подходов к решению задач. Однако это можно контролировать с помощью внутренних руководств и стандартов команды. Исследования показывают, что ИИ-ассистенты могут улучшить совместную работу, но требуют правильного управления.

Скорость разработки относится к тому, насколько быстро команда может завершить проект, включая написание и тестирование кода.

Ценность: GigaCode значительно ускоряет процесс написания кода благодаря автодополнению и генерации. Исследования показывают, что инструмент может ускорить разработку на 25%, что особенно полезно для рутинных задач, таких как создание стандартных конструкций. Высокая частота предложений (98,7%) и точность предсказаний делают его эффективным инструментом для ускорения работы.

Недостаток. Возможен риск, что сгенерированный код потребует дополнительных исправлений и может замедлить процесс. Однако, учитывая высокие показатели точности, этот риск минимален. Исследования ИИ-ассистентов подтверждают, что они обычно увеличивают продуктивность, хотя не всегда для всех пользователей.

Требования к штату сотрудников компании, планирующей интеграцию GigaCode

Любой разработчик, соответствующий критериям, может назначаться для работы с GigaCode. Например, это разработчики, работающие над проектами с повторяющимися задачами, где автодополнение и генерация кода могут ускорить процесс; или разработчики, использующие языки Java и JavaScript/TypeScript, где GigaCode показывает высокую эффективность. Менее опытные разработчики также могут использовать GigaCode для обучения, получая подсказки и примеры кода.

Хотя специальное обучение не является обязательным, производитель рекомендует представить краткое руководство или провести тренинг, чтобы помочь разработчикам эффективно использовать GigaCode: понять возможности и ограничения ИИ-ассистента, провести проверку сгенерированного кода на корректность и безопасность, а также отработать формулировку четких комментариев для получения лучших результатов от ИИ.

Можно предположить, что в недалеком будущем студенты вузов, обучающиеся по профильным направлениям, уже будут обладать навыками работы с ИИ-ассистентом при приеме на работу, и данный аспект станет второстепенным.

Практические кейсы и перспективы развития

Изучение успешных кейсов внедрения GigaCode в крупных компаниях, таких как UseTech и BI.ZONE, показывает, что продукт способен кардинально изменить подход к разработке. Например, предприятия, специализирующиеся на разработке web-приложений, отмечают сокращение временных затрат на создание функциональных блоков кода до 40%, что позволяет быстрее реагировать на изменения в требованиях бизнеса.

В образовательной сфере использование GigaCode открывает новые возможности для преподавателей, позволяя не только ускорить процесс обучения, но и демонстрировать на практике современные методы разработки [5, 6]. Возможность генерации кода по комментариям способствует осмыслению и более глубокому пониманию студентами алгоритмов и принципов программирования.

Перспективы дальнейшего развития продукта связаны с его интеграцией в экосистему корпоративных решений, что позволит создавать комплексные IT-инфраструктуры, объединяющие разработку, тестирование и поддержку на единой платформе. Такая синергия открывает новые горизонты для инноваций и оптимизации бизнес-процессов, что особенно актуально в условиях цифровой трансформации современных предприятий.

МЕТОДИЧЕСКИЕ РЕКОМЕНДАЦИИ ПО ИСПОЛЬЗОВАНИЮ GIGACODE

Технические требования

Для установки GigaCode требуется ПК с ОС Windows (min Windows 10), MacOS (крайне желательно позже High Sierra) или Linux (желательно не попавшие под End Of Life или поддерживающие установку пакетов из пользовательских репозиторий), доступ в интернет.


Установка GigaCode на платформе JetBrains

Установка GigaCode на платформе JetBrains (например, в IntelliJ IDEA, PyCharm, WebStorm и других IDE от JetBrains) — процесс, позволяющий интегрировать инструмент для автоматической генерации кода или анализа кода в среду разработки. Однако отметим, что в настоящее время (2025 г.) GigaCode не является широко известным или официальным плагином для JetBrains. Инструкцию по установке можно найти на главной странице ассистента³.

Подключение GigaCode к VS Code

Пользователю требуется: 1) скачать плагин в формате VSIX-файла с официального сайта GigaCode; 2) перейти во вкладку «Extensions» и выбрать пункт «Install from VSIX...»; 3) загрузить скачанный ранее VSIX-файл. После успешной авторизации новое устройство привязано к аккаунту и сразу отображается в личном кабинете GitVerse. Требуется перезапустить IDE, чтобы изменения вступили в силу.

Подключение GigaCode к Android Studio

Скачать плагин с сайта GigaCode. В настройках своей IDE перейти в раздел Plugins и нажать на  (значок «шестеренка») в верхней панели меню, выбрать пункт «Install Plugin from Disk...». Загрузить скачанный ранее zip-архив. После успешной авторизации новое устройство привязано к аккаунту и сразу отображается в личном кабинете.

Подключение GigaCode к GigaIDE

У SberTech существует собственная IDE (GigaIDE), где GigaCode уже предустановлен в среду разработки. Чтобы активировать плагин, требуется нажать на Account, после чего последует перенаправление пользователя на GitVerse. После успешной авторизации к аккаунту привязано новое устройство, сразу отображаемое в личном кабинете.

Подключение GigaCode к Jupyter Notebook

Инструкция, размещенная на сайте, вероятно, устарела. Авторы не смогли установить GigaCode на Jupyter ни на ОС Windows, ни на ОС Linux. Разработчики Anaconda и Jupyter поддерживают только пакеты, одобренные в PyPi, во избежание поломки программы. GigaCode пока что не входит в список этих пакетов, но ситуация может измениться в ближайшее время.

Методы применения

GigaCode от SberTech многофункционален и успешно конкурирует с иными предложениями рынка ИИ-помощников.

Ниже приведены методы применения GigaCode с описанием и пояснением.

1. *Автодополнение кода.* Инструмент анализирует разработанный пользователем код и предлагает автодополнения — от функций и методов до целых блоков кода. Когда разработчик приступает к написанию функции или класса, ассистент подсказывает варианты для завершения. Он также может помочь с автозаполнением комментариев, генерируя код по описанию задачи. Это позволяет ускорить процесс написания кода, снижает количество ошибок и опечаток.

2. *Генерация кода по описанию.* С помощью этого инструмента возможно описать задачу на обычном языке (например, как комментарий), а инструмент автоматически сгенерирует нужный код. Разработчик пишет комментарий, например «Функция для сортировки массива по возрастанию», и инструмент создает соответствующий код на выбранном пользователем языке программирования, будь то Python, JavaScript или другой. Идеально для быстрого создания прототипов и решения стандартных задач.

3. *Рефакторинг кода.* Инструмент помогает улучшить имеющийся код, предлагая оптимизации — от упрощения логики до улучшения производительности. Пользователь выделяет участок кода и выбирает команду «Рефакторинг». Инструмент предлагает альтернативные варианты реализации. Это делает код более читаемым и удобным для поддержки.

4. *Генерация тестов.* Инструмент может автоматически генерировать тесты для имеющегося кода — unit и интеграционные. Написав функцию, разработчик получает набор тестов, которые помогут проверить, насколько корректно она работает. Инструмент ускоряет процесс написания тестов и повышает надежность любого кода.

5. *Поиск и исправление ошибок.* Инструмент может искать ошибки, уязвимости или антипаттерны в имеющемся коде и предлагать возможные исправления. Если в коде обнаружены потенциальные проблемы, например, утечка памяти или неправильное использование API, инструмент уведомляет о проблеме и предлагает решение. Этот инструмент снижает количество багов и улучшает качество кода.

6. *Документирование кода.* Инструмент генерирует документацию для кода, включая описание функций, их параметров и возвращаемых значений. Написав функцию, инструмент автоматически добавит комментарии в формате JSDoc, Python Docstring или

³ URL: <https://gigacode.ru/#/>

аналогичные. Это значительно упрощает поддержку и понимание кода, особенно в больших проектах.

7. *Перевод кода между языками программирования.* Этот инструмент помогает переводить код с одного языка на другой — например, с Python на JavaScript. Это полезно для миграции проектов или работы в мультиязычных командах.

8. *Обучение и изучение новых технологий.* Инструмент может предоставить примеры кода для изучения новых библиотек, фреймворков или языков программирования. Например, можно запросить пример использования новой библиотеки, и инструмент предоставит готовый код с объяснениями. Это ускоряет процесс освоения новых технологий и библиотек.

9. *Интеграция с CI/CD.* Инструмент можно интегрировать в процесс CI/CD для автоматической проверки и генерации кода. Инструмент автоматически создаст код для deployment-скриптов или конфигураций, улучшая процессы разработки и развертывания. Упрощает настройку и автоматизацию процессов в pipeline.

Использование GigaCode для решения типовых задач

Согласно публикации на платформе Habr от 22 мая 2024 г.⁴, GigaCode демонстрирует высокие показатели в интеграции ИИ-подсказок и доле идеально предсказанного кода, особенно для Java и JavaScript/TypeScript. Например, для Java интеграция ИИ-подсказок составляет 48,8%, что выше, чем у GitHub Copilot (46,8%), Codeium (45,8%) и Tabnine (42,3%). Для JavaScript/TypeScript показатели также конкурентоспособны с долей идеально предсказанного кода 35,5% против 36,3% у Copilot (см. таблицу).

Кроме того, GigaCode предлагает подсказки в 98,7% случаев, что значительно выше, чем у Copilot

(84%), Codeium (94,6%) и Tabnine (85,5%). Это указывает на его способность предоставлять помощь практически всегда, что полезно для рутинных задач.

Исследования и доступные данные показывают, что GigaCode особенно эффективен в следующих типовых задачах:

1) автодополнение кода: GigaCode анализирует контекст и предлагает завершение строк или целых конструкций (функции, циклы и условия). Это особенно полезно при написании стандартного кода, например, в корпоративных приложениях на Java или web-разработке на JavaScript;

2) работа с широко используемыми языками: для Java и JavaScript/TypeScript GigaCode показывает высокие показатели интеграции и точности, что делает его подходящим для задач, связанных с написанием бизнес-логики, работы с базами данных или клиентской стороной web-приложений.

С другой стороны, есть области, где GigaCode чуть менее эффективен:

1) сложные алгоритмы и структуры данных: задачи, требующие глубокого понимания контекста или реализации сложных алгоритмов, могут быть проблематичными, так как ИИ-ассистенты часто полагаются на шаблонные решения, а не на творческий подход;

2) обработка редких сценариев: если задача включает специфические случаи, не покрытые данными для обучения модели, GigaCode может генерировать некорректный или нерелевантный код;

3) интеграция с нишевыми библиотеками: если проект использует менее распространенные библиотеки или API, то GigaCode может не предоставить точных подсказок, так как его обучение, вероятно, сосредоточено на более популярных инструментах.

Все перечисленное связано с тем, что ИИ-ассистенты, включая GigaCode, могут генерировать некорректный или неэффективный код, особенно в не-

Таблица / Table

Ключевые метрики ИИ-ассистентов / Key performance metrics of AI-assistants

Language	AI-assistants, %			
	GigaCode	Copilot	Codeium	Tabnine
Интеграция ИИ (Java)	48,8	46,8	45,8	42,3
Интеграция ИИ (JS/TS)	44,1	42,9	43,8	37,3
Идеально предсказанный код (Java)	37,7	37,7	36,5	32,4
Идеально предсказанный код (JS/TS)	35,5	36,3	36,4	30

Источник / Source: составлено авторами / Compiled by the authors.

стандартных ситуациях, что требует дополнительной проверки со стороны разработчика.

ВЫВОДЫ

Проведенное исследование позволило всесторонне оценить возможности и преимущества ИИ-ассистента GigaCode от SberTech для оптимизации процессов разработки программного обеспечения. Анализ функциональности инструмента, его интеграционных возможностей и практического применения подтвердил высокую эффективность GigaCode в сравнении с аналогичными решениями, такими как GitHub Copilot и Amazon CodeWhisperer.

Можно с уверенностью говорить, что GigaCode способствует сокращению времени написания кода

на 25–40% и оптимизирует процессы командной работы, включая код-ревью и оценку трудозатрат, а также улучшает управление версиями за счет снижения количества исправлений. Однако стоит принять во внимание, что несмотря на преимущества, GigaCode менее эффективен при решении сложных алгоритмических задач, обработке редких сценариев и интеграции с нишевыми библиотеками, что требует дополнительного внимания со стороны разработчиков. Таким образом, можно сказать, что использование ИИ-ассистента в программировании представляет собой значимый шаг в развитии технологий [7] и это неизбежно повлияет на инновационное развитие всей IT-индустрии.

СПИСОК ИСТОЧНИКОВ

1. Абрамский М.М., Зарипова Э.Р., Михайлов А.И. О подходах к оценкам качества программного кода и производительности разработчика в условиях использования ИИ-ассистентов. В сб. материалов международного форума по математическому образованию (IFME'2024). Казань; 2024:257–263. URL: <https://elibrary.ru/ebvbur>
2. Стоянова О.В., Окусков И.С. Перспективные направления совершенствования процессов жизненного цикла разработки программного обеспечения. *Прикладная информатика*. 2025;20(116):79–96. DOI: 10.37791/2687–0649–2025–20–2–79–96
3. Третьухин М.И. Тенденции развития инструментальных средств совместной работы над программными проектами в условиях импортозамещения. В сб.: Цифровые инструменты для устойчивого развития экономики и образования. Орел; 2024:246–253. URL: <https://elibrary.ru/wkakkw>
4. Амирова Э.Ф., Кузнецов М.Г., Логинова И.М. Командная работа в системах контроля версий. В сб.: Развитие АПК и сельских территорий в условиях модернизации экономики. Казань; 2025:314–321. URL: <https://elibrary.ru/mtdxeu>
5. Патапова Ю.С. Генеративный искусственный интеллект в помощь учителю информатики. Образовательное пространство в информационную эпоху (EEIA-2024). М.: 2024;967–973. URL: <https://elibrary.ru/fvrsmh>
6. Маркин Е.И., Зупарова В.В., Панфилова М.И. Разработка системы LMS с использованием больших языковых моделей для автоматизации проверки программных заданий. *XXI век: итоги прошлого и проблемы настоящего плюс*. 2024;13(68):90–94. URL: <https://elibrary.ru/lhibzc>
7. Сазонов А.П. Использование ИИ в программировании. *Universum: технические науки*. 2024;3–1(120):46–52. DOI: 10.32743/UniTech.2024.120.3.17010

REFERENCES

1. Abramskiy M. M., Zaripova E. R., Mikhailov A. I. On approaches to assessing the source code quality and developer productivity with respect to using AI assistants. The International Forum on Mathematical Education Dedicated (IFME' 2024). Kazan; 2024:257–263. URL: <https://elibrary.ru/ebvbur> (In Russ.).
2. Stoianova O. V., Okuskov I. S. Forward-looking ways of enhancing software development life cycle processes. *Applied Informatics*. 2025;20(116):79–96. (In Russ.). DOI: 10.37791/2687–0649–2025–20–2–79–96
3. Tretyukhin M. I. Development of tools for collaboration on software projects in the context of import substitution. *Digital Tools for Sustainable Development of Economy and Education*. Orel; 2024:246–253. URL: <https://elibrary.ru/wkakkw> (In Russ.).
4. Amirova E. F., Kuznetsov M. G., Loginova I. M. Teamwork in version control systems. From: *Development of Agro-Industrial Complex and Rural Areas under Economy Transformation*. Kazan; 2025:314–321. URL: <https://elibrary.ru/mtdxeu> (In Russ.).
5. Patapova Yu. S. Generative artificial intelligence to help a computer science teacher. *Education Environment for the Information Age: Proceedings of International Scientific and Practical Conference*. Moscow; 2024:967–973. URL: <https://elibrary.ru/fvrsmh> (In Russ.).

6. Markin E. I., Zuparova V. V., Panfilova M. I. Development of an LMS system utilizing large language models for automating the assessment of programming assignments. *XXI Century: Resumes of the Past and Challenges of the Present plus*. 2024;13(68):90–94. URL: <https://elibrary.ru/lhibzc> (In Russ.).
7. Sazonov A. P. Using AI in Programming. *Universum: Technical Sciences*. 2024;3–1(120):46–52. (In Russ.). DOI: 10.32743/UniTech.2024.120.3.17010

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Андрей Иванович Гайдамака — кандидат военных наук кафедры бизнес-информатики факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Andrey I. Gaidamaka — Cand. Sci. (Military), Department of Business Informatics, Faculty of Information Technologies and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0002-2673-2942>

aigajdamaka@fa.ru

Светлана Рашидовна Муминова — кандидат технических наук кафедры математики и анализа данных факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Svetlana R. Muminova — Cand. Sci. (Eng.), Department of Mathematics and Data Analysis, Faculty of Information Technologies and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0001-5236-607X>

Автор для корреспонденции / Corresponding author:

srmuminova@fa.ru

Александр Владиславович Куприянов — студент факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Alexander V. Kupriyanov — Student, Faculty of Information Technologies and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0009-0002-5049-6529>

223517@edu.fa.ru

Заявленный вклад авторов:

А.И. Гайдамака — анализ возможностей других моделей искусственного интеллекта.

С.Р. Муминова — анализ возможностей GigaCode, разработка концепции статьи.

А.В. Куприянов — тестирование и описание промтов, анализ конкуренции GigaCode, введение и выводы.

Authors' declared contributions:

A. I. Gaidamaka — Analysis of other AI models' capabilities.

S. R. Muminova — Analysis of GigaCode capabilities, development of the article's concept.

A. V. Kupriyanov — Testing and description of prompts, analysis of GigaCode's competition, introduction and conclusions.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Conflicts of Interest Statement: The authors have no conflicts of interest to declare.

Статья поступила 29.04.2025; принята к публикации 15.06.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was received 29.04.2025; accepted for publication 15.06.2025.

The authors read and approved the final version of the manuscript.

УДК 004.93:616.1-073.97+616.12-073.78:004.8+004.93'14(045)

Выявление сердечно-сосудистых заболеваний по сигналу ЭКГ с использованием методов машинного обучения

А.Д. Авраменко^а, В.А. Судаков^{а,б}^а Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация;^б Институт прикладной математики им. М.В. Келдыша РАН, Москва, Российская Федерация

АННОТАЦИЯ

В статье рассматривается актуальная проблема автоматической диагностики сердечно-сосудистых заболеваний на основе анализа электрокардиографических (ЭКГ) сигналов. Основной целью исследования является повышение эффективности диагностического процесса с применением современных методов машинного обучения. В ходе работы проведен комплексный анализ существующих научных исследований в данной области. Особое внимание уделено систематизации наиболее эффективных методов и подходов к обработке ЭКГ и ЭЭГ-сигналов. В результате исследования выявлены перспективные направления применения капсульных нейронных сетей, генеративно-сопоставительных сетей и вейвлет-преобразования для решения задач диагностики. Отдельное внимание уделено диагностике вибраций оборудования, искажающих сигнал ЭКГ. Практическая значимость работы заключается в представлении современных методов автоматического выявления сердечно-сосудистых заболеваний на основе данных ЭКГ. На основе проведенного анализа сформулированы рекомендации по применению различных методов машинного обучения и определены перспективные направления дальнейших исследований.

Ключевые слова: капсульные нейронные сети; данные ЭКГ; вейвлет-преобразование; генеративно-сопоставительные сети; диагностика оборудования; сердечно-сосудистые заболевания

Для цитирования: Авраменко А.Д., Судаков В.А. Выявление сердечно-сосудистых заболеваний по сигналу ЭКГ с использованием методов машинного обучения. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(2):26-31.

ORIGINAL PAPER

Detecting Cardiovascular Diseases by ECG Signal Using Machine-learning methods

A.D. Avramenko^а, V.A. Sudakov^{а,б}^а Financial University under the Government of the Russian Federation, Moscow, Russian Federation;^б The M.V. Keldysh Institute of Applied Mathematics of the Russian Academy of Sciences, Moscow, Russian Federation

ABSTRACT

The problem of automatic diagnostic of diseases, in particular cardiovascular diseases by ECG signal (Electrocardiography). Goal. Improve diagnostic efficiency by using modern machine learning methods. Results. The results of the article review are presented in a systematic form, the most effective methods and approaches are highlighted, as well as their applicability to solving specific problems of diagnosing cardiovascular diseases. Based on the analysis of existing works, conclusions are made about the prospects of using machine learning methods in the field of diagnosis of cardiovascular diseases based on ECG data and suggest possible directions for future research in this field. Practical significance. The article highlights modern methods and approaches used in modern research aimed at automatic detection of cardiovascular diseases using ECG data.

Keywords: capsule neural networks (CapsNet); ECG; Wavelet transform; generative-adversarial networks (GAN); equipment diagnostics; cardiovascular diseases

For citation: Avramenko A.D., Sudakov V.A. Detecting cardiovascular diseases by ecg signal using machine-learning methods. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(2):26-31.



ВВЕДЕНИЕ

Сердечно-сосудистые заболевания (ССЗ) занимают лидирующее место в мире по смертности. По оценкам Всемирной организации здравоохранения (ВОЗ), от них каждый год умирают 17,9 млн человек¹. Ранняя диагностика ССЗ позволяет своевременно начать лечение, контролировать заболевание и продлить жизнь пациента. Оперативная постановка диагноза также важна для устранения и предупреждения острых эпидемиологических ситуаций, и пример COVID-19 наглядно это продемонстрировал, когда во время пандемии потребовалась оперативная и качественная диагностика, позволяющая приступить к лечению заболевания до его перехода в острую форму.

С развитием информационных технологий появилась возможность автоматизации процессов диагностики заболевания с последующей интерпретацией результатов для выявления и предупреждения различных заболеваний на основе результатов инструментальной диагностики.

Также автоматизация позволяет высвободить высококвалифицированный персонал из области диагностики для непосредственного лечения пациентов, что способствует повышению качества предоставляемых медицинских услуг. Все вышесказанное подчеркивает важность задачи автоматизации выявления ССЗ с помощью методов глубокого машинного обучения на основе электрокардиограммы (ЭКГ).

ЭКГ — метод диагностики, позволяющий оценить работу сердца, зафиксировав его электрическую активность, суть которого заключается в регистрации электрических импульсов, создаваемых сердечной мышцей в процессе ее сокращений. Расшифровка ЭКГ позволяет выявить нарушения ритма сердца и наличие патологий.

Классификация сигнала ЭКГ часто бывает затруднена из-за его особенностей: изменчивости, нестационарности и подверженности различным видам помех. Кроме того, необходимо получать результаты анализа в реальном масштабе времени, что накладывает ограничения на вычислительную сложность алгоритмов. В настоящей статье рассматриваются подходы, методы и решения, позволяющие обнаружить сбои в механических системах медицинского оборудования (аппаратов ЭКГ) и минимизировать количество ошибок при постановке диагноза.

РЕШЕНИЯ ДЛЯ АНАЛИЗА ЭЛЕКТРОЭНЦЕФАЛОГРАФИЧЕСКИХ СИГНАЛОВ

В статье 1D-CADCapsNet авторы представили свое решение для выявления ишемической болезни сердца с использованием сигналов ЭКГ [1]. Они использовали для обучения своей капсульной нейронной сети необработанный ЭКГ-сигнал. Точность выше 98% была достигнута благодаря использованию архитектурного решения, где в качестве входного слоя использовался одномерный сверточный слой. Размерность этого слоя совпадает с количеством измерений отрезка ЭКГ, подающегося на вход. Стоит отметить, что в данной работе производилась бинарная классификация, т.е. данная модель позволяет определить здоров пациент или болен. Ограничение метода бинарной классификацией снижает его применимость для детального типирования патологий коронарных артерий, однако исследование 1D-CADCapsNet подтверждает фундаментальную применимость капсульных сетей для анализа ЭКГ-сигналов, демонстрируя их ключевые преимущества: робастность к вариациям сигнала, эффективность на малых выборках, сохранение пространственных иерархий.

ЭКГ-сигнал используется для обучения моделей машинного обучения не только в рамках проблемы классификации заболеваний. Биометрическая идентификация — еще одно направление, где возможно применение ЭКГ-сигнала.

Интересны решения, где используются вейвлет-преобразования² в совокупности с капсульной нейронной сетью [2]. В этой работе авторы акцентируют внимание на подготовке данных. Фильтрация шума производится за счет применения двух вейвлет-преобразований: вейвлет-разложение используется для фильтрации низкочастотного шума, пороговое вейвлет-преобразование — для фильтрации высокочастотного шума. Далее применяется непрерывное вейвлет-преобразование с функцией Добеши³, результатом применения которого являются четыре спектральных изображения: одно — низкочастотного компонента и 3 — высокочастотных. Преобразования помогли достигнуть точности более 98% для различных наборов данных.

² Вейвлет-преобразование (Wavelet thresholding) — метод удаления случайного шума и выбросов из сигнала перед его восстановлением. Используется в разных областях, например в обработке акустических сигналов, сжатии изображений, анализе потоков и др.

³ Вейвлеты Добеши — семейство ортогональных вейвлетов с компактным носителем, вычисляемым итерационным путем.

¹ URL: <https://www.vshouz.ru/news/analitika/wcs-19279/>

Следующий пример — создание модели, позволяющей классифицировать сердечно-сосудистые заболевания на основе сигнала ЭКГ [3]. В этой работе авторы акцентируют внимание на проблеме несбалансированного набора данных. С данной задачей им удалось успешно справиться путем применения функции фокальной ошибки⁴. В работе применялись и вейвлет-преобразования, аналогичные для биометрической идентификации ЭКГ из работы [2]. Капсульная нейронная сеть показала точность, чувствительность и специфичность не менее 97%.

Для получения временно-частотных характеристик из сигнала ЭКГ возможно применять дискретное вейвлет-преобразование, а уменьшения размерности данных достигнуть с помощью метода главных компонент. Такое решение представлено в работе [4]. Авторами используется смешанный метаалгоритм, основанный на совмещении алгоритмов благородного оленя (Red Deer Algorithm, RDA) и Jaya (Jaya algorithm) и измененный для выявления и отбора признаков. Далее производится кластеризация методом K-средних (K-means clustering) и методом, базирующимся на плотности пространственной кластеризации для приложений с шумами (density-based spatial clustering of applications with noise). Комбинация методов позволила увеличить точности до 97%, тогда как методы по отдельности или в неполной совокупности показывали точность 95,92–96,08%.

МЕТОДИКИ КЛАССИФИКАЦИИ СИГНАЛОВ ЭЭГ

Прежде чем приступить к обзору работ по классификации сигналов ЭЭГ, следует отметить различия между задачами классификации ЭЭГ и ЭКГ.

Электроэнцефалография (ЭЭГ) представляет собой совокупность сигналов с некоторым пространственным взаимоотношением, тогда как электрокардиография (ЭКГ) — одномерный сигнал.

Стоит отметить, что вариативность сигналов ЭЭГ накладывает дополнительные требования при их обработке, тогда как сигнал ЭКГ всегда имеет одинаковую форму. Следовательно, при рассмотрении подходов к классификации ЭЭГ применительно к задаче классификации ЭКГ не требуется уделять внимание методам предварительной обработки данных, свойственным задачам, использующим сигналы ЭЭГ.

⁴ Функция фокальной ошибки (focal loss) — функция потерь в машинном обучении, улучшающая работу моделей на несбалансированных данных, где классы имеют неравное распределение.

Например, в работе для классификации эмоций по ЭЭГ авторами используется многозадачное обучение (multi-task learning, MTL) в совокупности с капсульной нейронной сетью, на вход которой подается набор одномерных сигналов ЭЭГ [5]. Такая модель позволяет получить результаты с точностью 95–98% для различных наборов данных.


Непрерывное вейвлет-преобразование к сигналам ЭЭГ используется, чтобы получить частотно-временные изображения, на которых обучается комплекс из трансформера и капсульной нейронной сети [6]. Такой подход обеспечивает точность не менее 96%.

Отбор качественных данных для обучения значительно повышает эффективность классификации для моделей глубокого обучения [7]. Авторы этого исследования использовали расстояние Фреше для выявления наиболее показательных образцов. В качестве модели глубокого обучения ими применялась сеть эхо-состояний (Echo State Network, ESN). Для определения признаков сигналов ЭЭГ задействован анализ переноса компонентов (Transfer Component Analysis, TCA), существенно повысивший точность моделей. Так, для сети эхо-состояний без использования анализа переноса компонентов точность составила 50,22%, с использованием анализа переноса компонентов — 57,81%, а с подключением расстояния Фреше — 68,06%, что указывает на состоятельность такого подхода.

В работе [8] исследователи совместили методы опорных векторов, остаточной нейросети (Residual Neural Network, ResNet) и сеть пирамидальных признаков (Feature Pyramid Network, FPN). Исследование показало, что использование пирамиды признаков значительно улучшает классифицирующую способность остаточной нейросети с 70–72%-ной точности до 94–97%.

Выявление частотно-временных признаков сигнала можно осуществлять не только с помощью Фурье или вейвлет-преобразований. Автоматическое определение признаков возможно и с использованием масштабирующего слоя (ScalingLayer) [9]. Авторами исследования доказано, что одна и та же архитектура модели глубокого обучения классифицирует лучше, если использовать масштабирующий слой, нежели вейвлет-преобразования. Так, точность модели лишь с вейвлет-преобразованием была 62,50–67,34%, а с использованием масштабирующего слоя — 69,99–71,13%.

В следующем проекте также использовалась сверточная нейронная сеть, однако обучалась она методом Q-обучения (Q-Learning) [10]. Авторами предложен алгоритм машинного обучения, учиты-



вающий индивидуальные особенности пациента при обработке ЭЭГ-сигналов, что было достигнуто за счет обобщающей способности моделей Q-обучения.

НАУЧНЫЕ РАБОТЫ В ОБЛАСТИ ДИАГНОСТИКИ НЕИСПРАВНОСТЕЙ

Автоматическая диагностика неисправностей механического оборудования — область, где методы глубокого обучения успешно применяются для классификации сигналов вибрации. Эти сигналы, представляющие собой одномерные временные ряды, формируются вследствие динамических деформаций конструкций. Аналогичный подход перспективен для медицинской диагностики: анализ одномерных ЭКГ-сигналов методами глубокого обучения позволяет выявлять сердечно-сосудистые патологии, используя опыт, накопленный в технических дисциплинах.

В работе [11] исследуется сигнал вибрации в коробке передач ветротурбины. Для получения частотно-временных характеристик сигнала применяется S-преобразование — разновидность преобразования Фурье. Полученные спектрограммы используются для увеличения объема данных с помощью генеративно-состязательной нейронной сети (Generative Adversarial Network, GAN). Капсульная нейронная сеть, достигшая точности 93,53%, обучается на новом наборе данных. В работе показано, что увеличение объема данных с помощью генеративно-состязательной нейронной сети дает преимущество в точности. Так, капсульная нейронная сеть такой же архитектуры, обучавшаяся на начальном наборе данных без синтетических данных, показала точность в 90,62%, что наглядно показывает преимущество применения генеративно-состязательных нейронных сетей в задачах классификации одномерных сигналов.

Существуют подходы, позволяющие обучать модели глубокого обучения без преобразования сигнала в частотно-временное представление. Например, в работе [12] сигнал вибрации подшипников преобразуется в изображение шкалы серого (Grayscale Image), где каждая строка — значение амплитуды сигнала на конкретном временном промежутке. Временные интервалы следуют строго друг за другом. Полученные изображения передаются в модуль объединения функций с двумя шкалами с механизмом внимания (Dual attention-based multi-scale feature fusion). Выявленные таким способом особенности передаются в капсульную сеть. Полученная модель показала точность в 97,86%.

В работе [13], так же как и в исследовании [11], классифицировался сигнал вибрации подшипников. Для увеличения объема данных использовалась генеративно-состязательная сеть, а именно многомерная остаточная генеративно-состязательная сеть (multi-scale residual generative adversarial network). Для получения частотно-временных характеристик сигнала использовалось вейвлет-преобразование частотного среза (frequency slice wavelet transform). На полученном наборе данных обучается капсульная нейронная сеть, точность которой 99,90%.

МЕТОДЫ И АЛГОРИТМЫ

Для нахождения наилучшего подхода к выявлению болезней коронарных артерий по сигналу ЭКГ рекомендуется применять методы, описанные выше.

В современном обществе количество людей с сердечно-сосудистыми заболеваниями существенно меньше, чем здоровых. А людей с редкими заболеваниями еще меньше. Из-за чего наборы обучающих данных не сбалансированы. Чтобы справиться с данной проблемой, авторы уже рассмотренных выше работ использовали следующие подходы.

Первый подход учитывает несбалансированность набора данных, например, за счет использования функции фокальной ошибки [3]. Второй подход предполагает увеличение объема данных за счет генерации новых, что достигается использованием генеративно-состязательных нейросетей [11, 13].

В рассмотренных выше работах также использовались разные способы извлечения признаков из сигналов. Их можно поделить на обучаемые подходы извлечения признаков и на подходы без обучения. К обучаемым подходам относятся: получение признаков с помощью одномерного сверточного слоя [1]; использование сети пирамиды особенностей [8]; применение масштабирующего слоя [9]. Подходы без обучения представлены Фурье и вейвлет-преобразованиями [2, 4, 11, 13].

ВЫВОДЫ

Проведенный анализ научных работ и современных подходов к диагностике ССЗ позволяет сформулировать следующие ключевые выводы:

1) капсульные нейронные сети демонстрируют высокую эффективность при анализе медицинских сигналов, что делает их перспективным инструментом для диагностики по ЭКГ. Их применение может значительно улучшить качество выявления патологий сердечно-сосудистой системы;

2) проблема несбалансированных данных остается критически важной при работе с медицинскими наборами данных. Использование генеративно-сопоставительных сетей (GAN) представляется оптимальным решением для создания сбалансированных датасетов, что позволит повысить точность диагностики;

3) автоматические методы извлечения характеристик из ЭКГ-сигналов показали свою эффективность и должны стать основой для дальнейшего развития диагностических систем. Это позволит: ускорить процесс анализа данных; снизить влияние человеческого фактора; повысить точность диагностики;

4) комплексный подход, сочетающий различные типы нейронных сетей, поможет улучшить


качество анализа сигналов; повысить точность диагностики; более эффективно использовать имеющихся данные.

Практическая значимость предложенных решений заключается в возможности создания автоматизированных систем поддержки принятия врачебных решений, что особенно важно в условиях растущей нагрузки на медицинский персонал и увеличения количества диагностируемых случаев ССЗ.

Таким образом, интеграция капсульных нейронных сетей, генеративно-сопоставительных сетей и автоматических методов извлечения характеристик представляется перспективным направлением развития систем диагностики сердечно-сосудистых заболеваний по ЭКГ.

REFERENCES

1. Butun E., Yildirim O., Talo M., Tan R. 1D-CADCapsNet: One dimensional deep capsule networks for coronary artery disease detection using ECG signals. *Physica Medica*. 2020;70:39–48 URL: <https://www.sciencedirect.com/science/article/pii/S1120179720300077>. DOI: 10.1016/j.ejmp.2020.01.007
2. El Boujnouni I., Zili H., Tali A., Tali T., Laaziz Y. A wavelet-based capsule neural network for ECG biometric identification. *Biomedical Signal Processing and Control*. 2022;76:103692. URL: <https://www.sciencedirect.com/science/article/pii/S1746809422002142> DOI: 10.1016/j.bspc.2022.103692
3. El Boujnouni I., Harouchi B., Tali A., Rachafi S., Laaziz Y. Automatic diagnosis of cardiovascular diseases using wavelet feature extraction and convolutional capsule network. *Biomedical Signal Processing and Control*. 2023;81:104497. URL: <https://www.sciencedirect.com/science/article/pii/S174680942200951X> DOI: 10.1016/j.bspc.2022.104497
4. Sonawane R., Patil H. Automated heart disease prediction model by hybrid heuristic-based feature optimization and enhanced clustering. *Biomedical Signal Processing and Control*. 2022;72:103260. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0925231221005270> DOI: 10.1016/j.bspc.2021.103260
5. Li C., Wang B., Zhang S., Liu Y., Song R., Cheng J., Chen X. Emotion recognition from EEG based on multi-task learning with capsule network and attention mechanism. *Computers in Biology and Medicine*. 2022;143:105303. URL: <https://www.sciencedirect.com/science/article/pii/S0010482522000956> DOI: 10.1016/j.combiomed.2022.105303
6. Wei Y., Liu Y., Li C., Cheng J., Song R., Chen X. TC-Net: A Transformer Capsule Network for EEG-based emotion recognition. *Computers in Biology and Medicine*. 2023;152:106463. URL: <https://www.sciencedirect.com/science/article/pii/S0010482522011714> DOI: 10.1016/j.combiomed.2022.106463
7. Zhou J., Chu S., Li X., Xiao F., Sun L. An EEG emotion recognition method based on transfer learning and echo state network for HilCPS. *Microprocessors and Microsystems*. 2021;87:103381. URL: <https://www.sciencedirect.com/science/article/pii/S0141933120305391> DOI: 10.1016/j.micpro.2020.103381.
8. Hou F., Gao Q., Song Y., Wang Z., Bai Z., Yang Y., Tian Z. Deep feature pyramid network for EEG emotion recognition. *Measurement*. 2022;201:111724. URL: <https://www.sciencedirect.com/science/article/pii/S0263224122009290> DOI: 10.1016/j.measurement.2022.111724
9. Hu J., Wang C., Jia Q., Bu Q., Sutcliffe R., Feng J. ScalingNet: Extracting features from raw EEG data for emotion recognition. *Neurocomputing*. 2021;463:177–184. URL: <https://www.sciencedirect.com/science/article/pii/S0925231221012029> DOI: 10.1016/j.neucom.2021.08.018
10. Dong H., Chen D., Zhang L., Ke H., Li X. Subject sensitive EEG discrimination with fast reconstructable CNN driven by reinforcement learning: A case study of ASD evaluation. *Neurocomputing*. 2021;449:136–145. URL: <https://www.sciencedirect.com/science/article/pii/S0925231221005270> DOI: 10.1016/j.neucom.2021.04.009
11. Liang P., Deng C., Yuan X., Zhang L. A deep capsule neural network with data augmentation generative adversarial networks for single and simultaneous fault diagnosis of wind turbine gearbox. *ISA Transactions*. 2022. URL: <https://www.sciencedirect.com/science/article/pii/S0019057822005365> DOI: 10.1016/j.isatra.2022.10.008



12. Zhang Q., Li J., Ding W., Ye Z., Meng Z. Mechanical fault intelligent diagnosis using attention-based dual-scale feature fusion capsule network. *Measurement*. 2023;207:112345. URL: <https://www.sciencedirect.com/science/article/pii/S026322412201541X> DOI: 10.1016/j.measurement.2022.112345
13. Liu J., Zhang C., Jiang X. Imbalanced fault diagnosis of rolling bearing using improved MsR-GAN and feature enhancement-driven CapsNet. *Mechanical Systems and Signal Processing*. 2022;168:108664. URL: <https://www.sciencedirect.com/science/article/pii/S0888327021009882> DOI: 10.1016/j.ymssp.2021.108664

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Александр Дмитриевич Авраменко — аспирант, ассистент кафедры информационных технологий факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Alexander D. Avramenko — Postgraduate Student, Assistant, Department of Information Technology, Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0003-2397-8119>

Автор для корреспонденции / Corresponding author:

ADAvramenko@fa.ru; hilleri123@gmail.com

Владимир Анатольевич Судаков — доктор технических наук, доцент, ведущий научный сотрудник ФИЦ, Институт прикладной математики им. М. В. Келдыша Российской академии наук, Москва, Российская Федерация

Vladimir A. Sudakov — Dr. Sci. (Tech.), Assoc. Prof., Leading Researcher, Federal Research Center M.V. Keldysh Institute of Applied Mathematics of the Russian Academy of Sciences, Moscow, Russian Federation

<https://orcid.org/0000-0002-1658-1941>

sudakov@keldysh.ru; sudakov@ws-dss.com

Заявленный вклад авторов:

А.Д. Авраменко — анализ литературы, формулировка постановки задачи, написание основных разделов статьи.

В.А. Судаков — научное руководство, формулировка методологической части, рецензирование и доработка разделов, связанных с применением методов машинного обучения и анализом результатов.

Authors' declared contributions:

A.D. Avramenko — literature review, formulation of the problem statement, writing the main sections of the article.

V.A. Sudakov — scientific supervision, formulation of the methodological section, reviewing and revision of the sections related to the application of machine learning methods and analysis of results.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Conflicts of Interest Statement: The authors have no conflicts of interest to declare.

Статья поступила 16.06.2025; принята к публикации 18.06.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was received 16.06.2025; accepted for publication 18.06.2025.

The authors read and approved the final version of the manuscript.

УДК 004.93'1:629.7.05:614.8(045)

Исследование соотношения точности и производительности моделей YOLOv8 на специальном наборе данных Lacmus

А.И. Лабинцев^а, Е.И. Кублик^б, Г.П. Перевозчиков^с, Р.А. Кочкаров^д^{а,б,д} Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация;^с Вюрцбургский университет им. Юлиуса Максимилиана, Германия;^а ООО «РТК ИТ», Москва, Российская Федерация

АННОТАЦИЯ

В рамках настоящего исследования представлен специализированный датасет Lacmus, разработанный для решения задачи детекции пропавших людей на аэрофотоснимках, полученных с беспилотных летательных аппаратов. Набор данных включает 1552 изображения с более чем 5 тыс. размеченных ограничивающих рамок, зафиксированных в пяти различных локациях, характеризующихся травянистым покровом и редколесьем, в различные сезоны года. Основной целью исследования являлась оптимизация соотношения точности и производительности моделей семейства YOLO v8 на основе представленного датасета. В ходе экспериментальных исследований установлено, что наилучшие показатели достигаются при использовании модели среднего размера с увеличенным входным разрешением изображений без их предварительной обработки и нарезки на снимки меньшего разрешения. Разработанный датасет и полученные результаты исследования предназначены для практического применения в деятельности поисково-спасательных отрядов, что потенциально может способствовать повышению эффективности спасательных операций и спасению человеческих жизней.

Ключевые слова: детекция объектов; аэрофотоснимки; нейросети YOLO; компьютерное зрение; поиск людей; спасательные операции; датасет Lacmus

Для цитирования: Лабинцев А.И., Кублик Е.И., Перевозчиков Г.П., Кочкаров Р.А. Исследование соотношения точности и производительности моделей YOLOv8 на специальном наборе данных Lacmus. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(2):32-43.

ORIGINAL PAPER

Benchmark of YOLOv8 with Lacmus dataset

A.I. Labintsev^а, E.I. Kublik^б, G.P. Perevozchikov^с, R.A. Kochkarov^д^{а,б,д} Financial University under the Government of the Russian Federation, Moscow, Russian Federation;^с Julius-Maximilians-Universität Würzburg, Germany;^а RTC IT LLC, Moscow, Russian Federation

ABSTRACT

This research introduces a specialized Lacmus dataset designed for detecting missing persons in aerial photographs obtained from unmanned aerial vehicles (UAVs). The dataset comprises 1552 images with over 5000 annotated bounding boxes captured at five distinct locations characterized by grassy areas and sparse forests across different seasons.

The primary objective of the study was to optimize the accuracy-performance ratio of YOLOv8 models based on the presented dataset. Experimental research has revealed that the best results were achieved using a medium-sized model with increased input image resolution without prior segmentation into smaller resolution images. The developed dataset and research results are intended for practical application in search and rescue operations, which could potentially enhance the efficiency of rescue missions and save human lives.

Keywords: object detection; aerial photographs; YOLO neural networks; computer vision; person search; rescue operations; lacmus dataset

For citation: Labintsev A.I., Kublik E.I., Perevozchikov G.P., Kochkarov R.A. Benchmark of YOLOv8 with Lacmus dataset. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(2):32-43.



ВВЕДЕНИЕ

Ежегодно регистрируется значительное количество случаев исчезновения людей в дикой природе. При этом существенная доля пропавших — лица, дезориентированные в удаленных от населенных пунктов локациях. Несмотря на то, что определенная часть заблудившихся способна самостоятельно найти путь к выходу, для локализации оставшихся проводятся специализированные поисково-спасательные операции (ПСО). Данная проблема характеризуется высокой актуальностью, поэтому разрабатываются различные решения для облегчения поиска. Они представлены в форме прототипов и прошли апробацию в рамках организованных конкурсных мероприятий. Однако совокупность реальных условий поиска в лесных массивах и ограниченность материальных ресурсов обуславливает сложность задачи и ее недостаточную проработанность.

В современной практике спасательных работ наблюдается тенденция к интенсификации применения беспилотных летательных аппаратов (БПЛА) для обследования территорий с помощью аэрофотосъемки с высоты 40–50 м. В ходе одной поисково-спасательной операции формируется массив из нескольких тысяч цифровых изображений, которые в настоящее время подвергаются визуальному анализу волонтерами. Данный метод обработки характеризуется значительной продолжительностью и снижением эффективности операторов после двух часов непрерывной работы. При этом оперативность и точность обработки полученных снимков критически влияют на благополучие и жизнеспособность пропавших лиц. В рамках сотрудничества Фонд свободного программного обеспечения Lastus и поисково-спасательные формирования осуществляют разработку программного приложения для автоматизированного поиска пропавших людей на основе анализа изображений, полученных с помощью БПЛА.

Детекция объектов представляет собой фундаментальную задачу в сфере компьютерного зрения. Исследования и разработка методов обнаружения объектов ведутся на протяжении более полувекового периода, что подтверждается научными публикациями [1, 2].

РЕШЕНИЯ ДЛЯ ОБНАРУЖЕНИЯ ОБЪЕКТОВ

В современной практике обработки визуальной информации применяются разнообразные архитектурные решения на основе нейросетевых технологий. Исторически сложилось разделение детекторов на одноуровневые и двухуровневые системы [3]. В настоящее время детекторы типа One-stage получили преимущественное распространение благодаря оптимальному балансу между точностью классификации

и скоростью обработки данных, что также подтверждается исследованиями [4].

Дополнительно следует отметить существование более ресурсоемких архитектур, построенных на базе трансформеров, например, как показано в работе Т. Шехзади [5]. Однако реализация повышенной точности классификации сопряжена с существенным возрастанием вычислительных затрат, особенно при обработке изображений высокого разрешения, что создает определенные ограничения для практического применения подобных решений.

В области компьютерного зрения для сравнительного анализа архитектур детекции объектов традиционно используются стандартизированные датасеты. Наиболее известными являются COCO [6] и Pascal VOC [7], обладающие обширными массивами размеченных изображений. Однако данные наборы демонстрируют недостаточную релевантность применительно к специфике рассматриваемой задачи поиска людей в лесу.

В контексте оценки алгоритмов обнаружения объектов с помощью БПЛА широкое распространение получил структурированный набор данных VisDrone [8]. Данный датасет включает 10 209 изображений, упорядоченных следующим образом: 6471 изображение для обучения, 548 — для валидации и 3190 — для тестирования. В рамках классификации представлены 10 категорий объектов, включающих антропоморфные объекты и различные типы транспортных средств (велосипеды, автомобили, грузовики и пр.). Существенным ограничением данного датасета является преимущественно городской контекст представленных изображений, что затрудняет его применение для обучения нейросетевых моделей в контексте поисково-спасательных операций в местности с лесными массивами.

Альтернативным решением выступает датасет UAVDT [9], созданный для задач отслеживания объектов. Набор данных характеризуется изображениями с разрешением 1024×540 пикселей и включает 80 тыс. кадров, извлеченных из 100 видеозаписей. Классификация объектов в данном наборе ограничена тремя категориями: автомобили, автобусы и грузовики. Аналогично предыдущему датасету, UAVDT ориентирован на решение задач в городской среде, что делает его неприменимым для разработки алгоритмов детекции людей в лесной полосе.

В области разработки систем поиска и спасания (SAR) с применением БПЛА известен специализированный датасет SeaDronesSee [10], ориентированный на морскую среду. Данный набор данных предоставляет возможности для обучения нейросетевых архитектур в трех направлениях: детекция объектов, трекинг отдельных объектов и множественный трекинг.

Структура датасета включает 5630 изображений для обучения, 859 изображений для валидации и 1796 изображений для тестирования, предназначенных для задачи детекции объектов.

Для задач поиска и спасения в лесных массивах релевантен датасет HERIDAL [11], представляющий обширную коллекцию изображений природного ландшафта, полученных с аэрофотосъемки. Набор данных включает более 68 750 изображений, из которых 500 являются размеченными полноформатными изображениями для тестирования. Результаты исследований на данном датасете демонстрируют следующие показатели: полнота обнаружения составляет 88,9%, точность — 34,8%.

В условиях дикой природы особое значение приобретает мультимодальный датасет WiSARD [12], представляющий собой наиболее обширную коллекцию изображений. Структура набора данных включает: 33 786 размеченных изображений в RGB-формате, 22 156 тепловых изображений с маркировкой и 15 453 синхронизированных во времени пар визуальных и тепловых изображений. Важная особенность данного датасета представлена разнообразием условий съемки, включая различные сезоны и время суток (день/ночь), что обеспечивает высокую вариативность данных для обучения нейросетевых моделей.

Дополнительным источником данных выступает набор NOMAD [13], содержащий изображения с вариативной степенью затенения объектов и различными высотами полета БПЛА. В процессе создания датасета участвовали 100 актеров, выполнявших различные сценарии поведения (ходьба, лежание, маскировка). Набор включает 42 825 кадров, извлеченных из видеоматериалов с разрешением более 5000 пикселей. Аннотирование данных в NOMAD характеризуется наличием не только границ объектов, но и количественной оценки уровня видимости (в процентах от видимой части человеческого тела). Такая детальная разметка позволяет проводить комплексную оценку эффективности алгоритмов компьютерного зрения при различных условиях видимости объектов. Важно отметить, что, несмотря на высокую ценность для развития технологий ПСО, датасет NOMAD недоступен для свободного использования.

Дополнительным источником данных выступает SARD [14], содержащий 1981 размеченное изображение, извлеченное из видеоматериалов, имитирующих поисково-спасательные операции в различных природных условиях. В состав датасета входят изображения, полученные в условиях дорог, карьеров, лугов и лесных массивов при различных погодных условиях, что обеспечивает высокую вариативность данных для обучения нейросетевых моделей.

ДЕТЕКЦИЯ ОБЪЕКТОВ В СПАСАТЕЛЬНЫХ ОПЕРАЦИЯХ

Проанализировав различные наборы данных, можно выделить следующие особенности задачи детекции объектов в спасательных операциях [9]:

1) бинарная классификация объектов является ключевым аспектом поисковых операций. Основной целью обнаружения выступают люди, в то время как идентификация других объектов носит второстепенный характер и встречается значительно реже;

2) разрешение изображений играет критическую роль в процессе поиска. Оптимальным считается разрешение, при котором объект занимает площадь 100×100 пикселей. Это обеспечивает достаточный объем информации для надежного детектирования целей;

3) масштаб объектов представляет собой существенную проблему: даже при оптимальных условиях человек занимает менее 1% площади всего изображения. Это создает определенные сложности для алгоритмов обнаружения;

4) динамические характеристики съемки вносят дополнительные сложности в процесс. Высокая скорость движения беспилотных летательных аппаратов приводит к размытию изображений и изменению ракурса съемки. Это требует от системы детекции высокой адаптивности и способности к обобщению различных визуальных представлений одного объекта;

5) временные ограничения обработки являются критически важным фактором. Спасательные операции требуют быстрой обработки больших объемов данных при ограниченных вычислительных ресурсах. Эффективность алгоритма напрямую влияет на скорость обнаружения и, как следствие, на успешность спасательной операции.

Перечисленные особенности определяют ключевые требования к системам детекции объектов в спасательных операциях и влияют на выбор конкретных алгоритмов и подходов к решению задачи.

Повышение точности детекции малоразмерных объектов представляет собой актуальную научную проблему в области компьютерного зрения. Существенный прогресс в решении данной задачи демонстрирует метод Slicing Aided HyperInference (SAHI), представленный в работе [15, 16].

Однако применение данного подхода сопряжено с увеличением вычислительных затрат, особенно при обработке изображений высокого разрешения. В связи с этим ведутся активные исследования по оптимизации соотношения между скоростью обработки и точностью детекции. В частности, перспективным направлением является разработка адаптивных методов сокращения избыточных вычислений, как показано в исследовании [17]. При этом вопрос определения

оптимального размера окна и входных параметров одноступенчатых детекторов (one-stage detectors) остается предметом дальнейших исследований.

В рамках настоящего исследования команда Lastus Foundation занимается разработкой специализированного программного обеспечения для поисково-спасательных операций, функционирующего на стационарных и мобильных вычислительных платформах. **Основная цель исследования** — нахождение оптимального баланса между скоростью обработки данных и точностью прогнозирования, что имеет критическое значение, учитывая успешное практическое применение разработанных приложений в реальных поисково-спасательных операциях.

МЕТОДЫ

Сбор экспериментальных данных осуществлялся во время проведения пяти учебных ПСО. В ходе данных мероприятий команда добровольцев размещалась на различных типах местности, принимая позы, соответствующие типичным положениям обнаруженных в реальных условиях пропавших лиц.

В процессе сбора данных учитывались следующие параметры:

- 1) *тип местности*: открытые пространства (чистое поле) и умеренно лесистые участки (негустой лес);
- 2) *вариативность цветовой гаммы одежды добровольцев* для создания различных условий видимости;
- 3) *высота съемки* — 40–50 м.;
- 4) *тип оборудования*: БПЛА коптерного типа.

Временной охват исследования (учтена сезонность) — пять серий учебных ПСО:

- 1) 0–410 (зима 2019 г., Москва);
- 2) 411–768 (лето 2019 г., Москва);
- 3) 769–1036 (весна 2019 г., Королев);
- 4) 1037–1421 (лето 2019 г., Тамбов);
- 5) 1422–1551 (лето 2021 г., Нижний Новгород).

Объем собранного материала: 1552 размеченных изображения и более 5 тыс. идентифицированных объектов.

Визуализация результатов представлена на *рис. 1*, демонстрирующем типичный пример зарегистрированного изображения с размеченным объектом.

Большинство изображений имеют разрешение 4000×3000 пикселей и более. Небольшое количество изображений имеет небольшой размер 2250 пикселей. Гистограмма распределения размеров изображений представлена на *рис. 2*.

В рамках проведенного анализа структуры датасета установлено, что модальное количество объектов на изображениях варьируется в диапазоне от 2 до 4 единиц. При этом наблюдается значительное отклонение от среднего значения: в отдельных случаях количество идентифицируемых объектов достигает 100 единиц на изображение, что свидетельствует о высокой вариативности контента в наборе данных. В состав датасета изначально включены 57 изображений, содержащих исключительно элементы ландшафта без присутствия человеческих фигур, что может быть релевантно при решении определенных задач компьютерного зрения.

Для визуализации распределения количества ограничивающих рамок (боксов) по изображениям построена гистограмма, демонстрирующая частотное распределение различных категорий объектов. Графическое представление статистических данных позволяет провести детальный анализ структуры датасета и выявить закономерности в распределении объектов по изображениям, что является критически важным при подготовке данных для машинного обучения.

Статистический анализ распределения объектов на изображениях (*рис. 3*) предоставляет ценную информацию для оптимизации алгоритмов обработки изображений и может использоваться при настройке параметров моделей компьютерного зрения.



Рис. 1 / Fig. 1. Пример изображений человека в лесу / Example of a person in the forest

Источник / Source: составлено авторами / Compiled by the authors.




Рис. 2 / Fig. 2. Гистограмма распределения размеров изображений / Histogram of image size distribution

Источник / Source: составлено авторами / Compiled by the authors.

Среднее значение площади объекта на снимке составляет около 5 тыс. пикселей. Гистограмма распределения площади объектов приведена на рис. 4.

В качестве обучающей выборки использовались данные из первых четырех ПСО (изображения 0–1421), для тестирования — данные с пятой ПСО (изображения 1422–1551). Такая схема разделения позволяет избежать утечки данных и соответствует реальному сценарию применения нейросети.

Для оценки влияния площади объекта на соотношения скорости и точности детекции созданы два дополнительных датасета путем разделения исходных изображений на несколько частей:

- 2×1 — разделение на 2 части по ширине (1804 изображения для обучения и 147 для тестирования);

- 3×2 — разделение на 6 частей — 3 по ширине и 2 по высоте (2368 изображений для обучения и 192 для тестирования);

- 1×1 — без разделения на части (1422 изображения для обучения и 130 для тестирования).

Фрагменты изображений (кропы), на которых не было людей, отсекались и в моделировании не применялись. Схема разделения изображения представлена на рис. 5.

Таким образом для моделирования имеется три разных варианта одинаковых данных, с разным соотношением площади объектов к площади изображения (1:2400, 1:1200 и 1:400).

Такой прием позволяет оценить точность детекции объектов при разных уровнях масштабирования




Рис. 3 / Fig. 3. Гистограмма распределения количества объектов, штук / Histogram of distribution of number of objects, pieces

Источник / Source: составлено авторами / Compiled by the authors.




Рис. 4 / Fig. 4. Гистограмма распределения площади объектов, пиксель / Histogram of object area distribution, pixel

Источник / Source: составлено авторами / Compiled by the authors.

[18]. Достигнуть максимального сжатия возможно в случае, когда исходное изображение уменьшится до размера модели 640 на 640. Минимальные потери от сжатия, а в некоторых случаях даже повышение разрешения исходных изображений будут в датасете 3×2 и входном размере модели 1984 на 1984.

ОБНАРУЖЕНИЕ И ИДЕНТИФИКАЦИЯ ОБЪЕКТА

В рамках предложенной методологии детектирования объектов прямоугольный ограничивающий контур (бокс) квалифицируется как идентифицированный объект при условии, что расчетная вероятность его классификации превышает предварительно установленный пороговый уровень.

Корректность обнаружения объекта верифицируется с помощью метрики Intersection over Union (IoU), при этом объект признается успешно детектированным исключительно в случае, если количественное значение данного показателя превосходит определенный пороговый критерий.

Данный подход обеспечивает объективную оценку эффективности системы обнаружения объектов и позволяет минимизировать количество ложных срабатываний за счет введения двухуровневой системы верификации: *статистической* (на основе вероятностного распределения) и *геометрической* (на основе пространственного перекрытия).

$$IoU = \frac{B_t \cap B_p}{B_t \cup B_p}.$$

В качестве метрик точности применяется precision and recall. Precision отражает величину ошибок первого рода, или долю объектов, ошибочно принятых за человека.

$$Precision = \frac{TP}{TP + FP}.$$

Recall отражает величину ошибок второго рода, или долю объектов (людей), которые алгоритм не смог обнаружить.



Рис. 5 / Fig. 5. Схема разделения изображений / Schemes of image cropping

Источник / Source: составлено авторами / Compiled by the authors.

$$Recall = \frac{TP}{TP + FN}.$$

В формулах использованы обозначения:

B_t — множество пикселей, принадлежащих боксу объекта (true);

B_p — множество пикселей, принадлежащих предсказанному боксу (predicted);

TP — количество объектов, верно классифицированных как человек;

FP — количество объектов, ошибочно классифицированных как человек;

FN — количество объектов, ошибочно классифицированных как фон (не найденные люди).

В контексте решения задачи поиска пропавших лиц приоритетный показатель эффективности — метрика Recall (полнота обнаружения). Данное предпочтение обусловлено спецификой применения системы: оператор, осуществляющий мониторинг, способен идентифицировать и проигнорировать множественные ложные срабатывания детектора. Однако в случае пропуска человеком-оператором потенциального объекта поиска вероятность его обнаружения существенно снижается, поскольку отсутствует возможность последующего пересмотра уже просмотренного материала.

Для количественной оценки временных характеристик разработанного решения были использованы метрики, отражающие *время выполнения предсказаний на центральных (CPU) и графических (GPU) процессорах*, измеряемое в миллисекундах. Особого внимания заслуживает реализация функциональности для проведения бенчмаркинга производительности моделей в рамках фреймворка Ultralytics*, обеспечившая стандартизированный подход к оценке временных характеристик.

В ходе проведения экспериментальных исследований в качестве базовой модели выбран детектор объектов YOLOv8 [19]. Схематическое представление архитектуры данной нейросетевой модели представлено на рис. 6.

В архитектуре YOLOv8 реализованы следующие инновационные компоненты:

— Spatial Pyramid Pooling Fast (SPPF) — усовершенствованный механизм пространственного пирамидального пулинга, представляющий собой оптимизированную версию алгоритма с повышенной вычислительной эффективностью. Данный компонент обеспечивает многомасштабное восприятие

объектов посредством иерархической агрегации признаков на различных уровнях разрешения.

— Cross stage partial (C2F) — модифицированный архитектурный блок, включающий две последовательные операции свертки. Данная реализация представляет собой оптимизированную версию кросс-стадийного слоя, обеспечивающего эффективное взаимодействие между различными этапами обработки данных при сохранении высокой производительности вычислений.

Мы использовали три основные модели с различным количеством сверточных слоев и максимальным количеством сверточных фильтров:

- YOLOv8 nano — 225 слоев, 1024 фильтров, 3,2 М параметров;
- YOLOv8 medium — 295 слоев, 768 фильтров, 25,9 М параметров;
- YOLOv8 xlarge — 365 слоев, 512 фильтров, 68,2 М параметров.

Чем больше размер модели, тем больше вычислений нужно произвести. Кроме того, на объем вычислений влияет размер входного изображения: чем больше пикселей на входе, тем больше боксов на выходе. Чем больше боксов на выходе, тем больше вычислений потребуется для постобработки.

Согласно схеме YOLOv8, приведенной на рис. 6, выходные боксы формируются с трех уровней: P3 (малые объекты), P4 (средние объекты) и SPPF (большие объекты). Например, если на вход модели подавать изображение 640x × 640 px, на выходе будем иметь:

P3: 80 × 80 = 6400 боксов;

P4: 40 × 40 = 1600 боксов;

SPPF: 20 × 20 = 400 боксов.

Итого: 6400 + 1600 + 400 = 8400 боксов.

Вычислим отношение количества боксов к исходному размеру изображения:

P3: (80 × 80) / (640 × 640) = 1/64 (размер рецептивного поля 8 × 8 пикс.);

P4: (40 × 40) / (640 × 640) = 1/256 (размер рецептивного поля 16 × 16 пикс.);

SPPF: (20 × 20) / (640 × 640) = 1/1024 (размер рецептивного поля 32 × 32 пикс.).

Размер рецептивных полей для каждого уровня пирамиды не зависит от размера входного изображения и количества слоев в разных модификациях (nano, medium, small). Поэтому можно вывести формулу, позволяющую вычислить количество боксов в зависимости от размера входного изображения (при условии, что длина изображения равна ширине):

$N_boxes_P3 = 1/64 \times (ImgSize \wedge 2);$

$N_boxes_P4 = 1/256 \times (ImgSize \wedge 2);$

$N_boxes_SPPF = 1/1024 \times (ImgSize \wedge 2).$

* Glenn Jocher G., Jing Q, Chaurasia A. YOLOv8. Object detection. Retrieved from. 2024. URL: <https://github.com/ultralytics>; <https://docs.ultralytics.com/ru/models/>

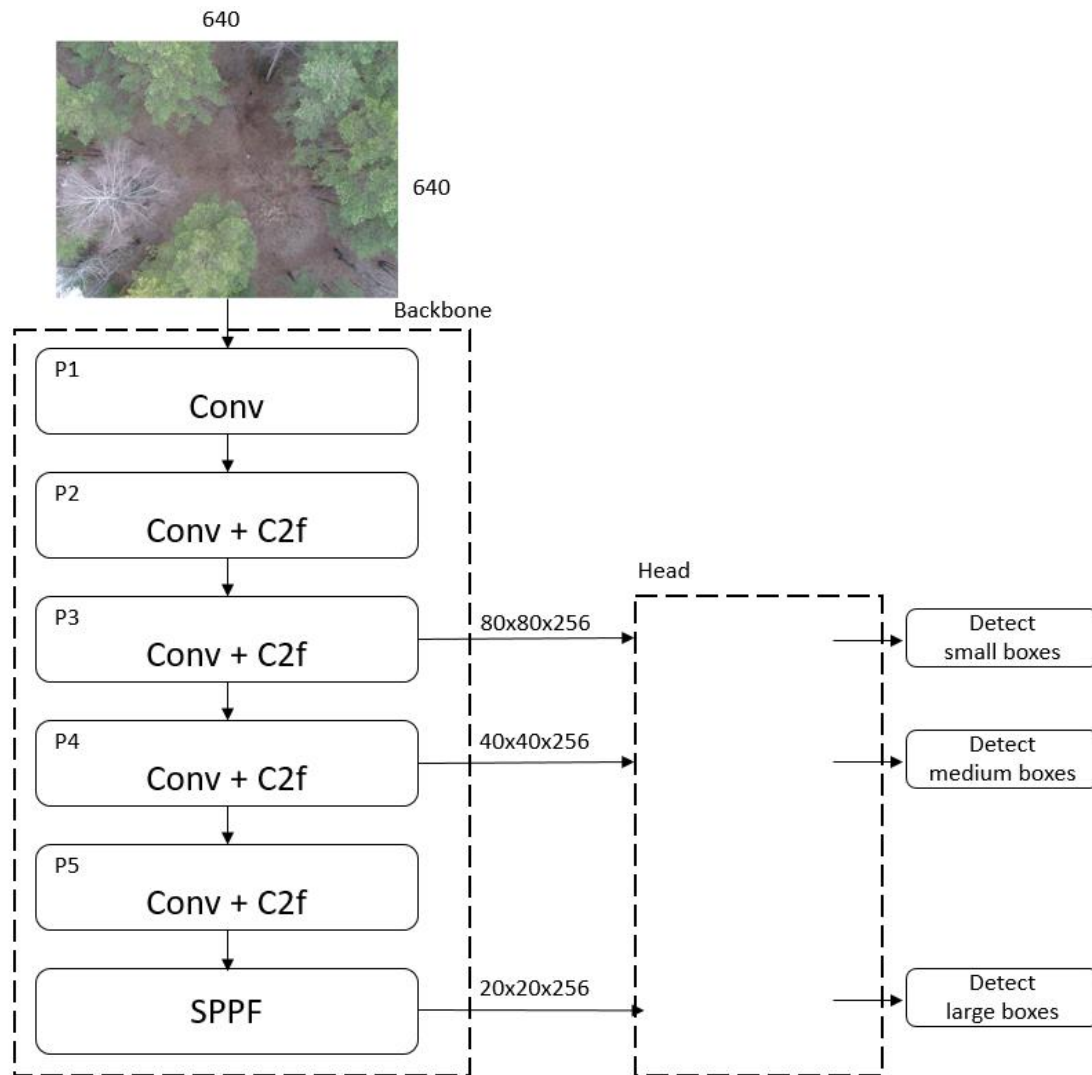



Рис. 6 / Fig. 6. Схематическое представление YOLOv8 / Scheme of YOLOv8

Источник / Source: составлено авторами / Compiled by the authors.

Суммарное количество боксов:

$$\begin{aligned} N_{boxes_P3} + N_{boxes_P4} + N_{boxes_SPPF} &= \\ &= 1/64 \times (ImgSize^2) + 1/256 \times (ImgSize^2) + 1/1024 \times \\ &\times (ImgSize^2) = \\ &= (ImgSize^2) (1/64 + 1/256 + 1/1024) = \\ &= (ImgSize^2) (16/1024 + 4/1024 + 1/1024) = \\ &= (ImgSize^2) \times 21/1024. \end{aligned}$$

Для представленной архитектуры YOLOv8 можно воспользоваться эмпирически выведенной формулой:

$$NumBoxes = \frac{21}{1024} \cdot ImgSize^2.$$

Таким образом, каждая из трех модификаций (nano, medium, small) моделей используется с тремя разными размерами изображений:

- на входе 640 px — на выходе 8400 боксов;
- на входе 1280 px — на выходе 33 600 боксов;

- на входе 1984 px — на выходе 80 724 боксов.

В рамках исследования влияния размеров скользящего окна на качество обработки данных сформированы и использованы три различных датасета, характеризующихся различным соотношением площадей объектов и общего изображения:

- 1) базовый (без предварительной нарезки) с соотношением площадей 1:2400;
- 2) 2 × 1 с увеличенным соотношением площадей 1:1200;
- 3) 3 × 2 с максимальным соотношением площадей 1:400.

Такая градация позволяет провести комплексную оценку влияния различных размеров скользящего окна на эффективность обработки данных при различных плотностях расположения объектов на изображении.

РЕЗУЛЬТАТЫ

В ходе проведения экспериментальных исследований использовалась вычислительная машина со следующими характеристиками: центральный процессор (AMD Ryzen 5 2700); оперативная память (32 ГБ); графический процессор (NVIDIA RTX 3090, видеопамять 24 ГБ); операционная система (Ubuntu, версия 24.04); интерпретатор Python (версия 3.9); библиотечная поддержка (Ultralytics, версия 8.2.28).

В процессе выполнения логического вывода (инференса) на графическом процессоре дополнительные оптимизации не применялись. Размер батча определялся автоматически с целью достижения оптимального заполнения видеопамяти на уровне 70% от доступного объема.

Зафиксированное время задержки включало временные затраты как на непосредственный процесс логического вывода, так и на постобработку с использованием алгоритма NMS [20]. Временные затраты на предварительную обработку изображений в общую оценку не включались.

При выполнении инференса на центральном процессоре осуществлялась оптимизация моделей с помощью Python-модуля ONNX с использованием настроек по умолчанию.

Сравнение динамики обобщенной функции потерь (Generalized Focal Loss, dfl) [21] для моделей с размером входных изображений 1984 пикселей представлено на рис. 7.

ВЫВОДЫ

Самой точной моделью является YOLOv8m с размером входного изображения 1984 пикселей. На датасете 3 × 2 точность и полнота данных достигают 50%, при этом затраты на инференс-аналитику примерно в три раза меньше, чем для более тяжелой YOLOv8x. Самая тяжелая модель YOLOv8x показала худший результат чем YOLOv8m. Судя по графику, минимальное значение функции потерь на валидационной выборке достигается примерно за 100 эпох, дальше идет переобучение. Основной причиной является малый объем данных, а также малый размер батча для YOLOv8x — 2 изображения против 6 для YOLOv8m. Самой быстрой моделью является YOLOv8n. Можно разделять входное изображение всего на две части и сжимать до размера 1280 пикселей. В таком случае можно получить среднюю точность 38% всего за 0,5 секунды на CPU. Однако при работе на CPU разделение исходного изображения на тайлы и объединение их в батч не дает преимуществ в скорости обработки, в отличие от GPU.

При обработке изображений на GPU наиболее эффективно будет использовать батчи изображений для максимальной загрузки памяти GPU. С нашей точки зрения, при наличии у пользователя GPU можно использовать модель YOLOv8m со входом 1984, разделять изображения на кропы для достижения лучшей точности и полноты на уровне 50%.

Таким образом, в реальных приложениях нужно учитывать какой процессор будет использован поль-

Таблица / Table

YOLOv8n Precision / Recall, %

input size	No crops	Crops 2×1	Crops 3×2	CPU infer, ms	GPU infer, ms
640	20 / 23	30 / 28	26 / 40	68	10
1280	29 / 27	34 / 40	43 / 42	250	13
1984	36 / 35	37 / 41	45 / 49	700	20
640	27 / 28	30 / 32	41 / 42	360	18
1280	34 / 35	38 / 37	46 / 50	1500	23
1984	40 / 41	45 / 42	50 / 50	3600	44
640	24 / 24	32 / 29	34 / 40	1050	21
1280	33 / 29	35 / 35	44 / 38	4400	37
1984	43 / 35	37 / 41	45 / 47	10800	93

Источник / Source: составлено авторами / Compiled by the authors.




Рис. 7 / Fig. 7. Обобщенная функция потерь на обучающей и тестовой выборках для трех моделей YOLOv8: а) nano; б) medium; в) xlarge / Train and val losses of YOLOv8: а) nano; б) medium; в) xlarge

Источник / Source: составлено авторами / Compiled by the authors.

зователем. Исходя из этого, следует задействовать лучшую модель с лучшим количеством и размером скользящих окон.

В рамках настоящего исследования был проанализирован специализированный датасет Lasmus, сформированный в процессе проведения учебных ПСО силами добровольных поисково-спасательных отрядов. Статистический анализ продемонстрировал высокую степень соответствия характеристик полученных данных изображениям, регистрируемым в ходе реальных поисково-спасательных мероприятий.

В ходе экспериментальной части работы был реализован комплекс испытаний с применением

различных модификаций одноступенчатых детекторов YOLOv8, включающий процедуру сегментации исходных изображений на кропы. Проведенная серия экспериментов позволила установить оптимальные показатели соотношения скорости обработки данных и точности детектирования на разнородных вычислительных платформах.

Перспективные направления дальнейших научных исследований предусматривают реализацию процесса обучения архитектур трансформеров с последующим сравнительным анализом их эффективности относительно сверточных нейронных сетей в контексте решения поставленных задач.

REFERENCES

1. Herskovits A., Binford T.O. On boundary detection. 1970. URL: <http://hdl.handle.net/1721.1/5867>
2. Yakimovsky Y. Boundary and object detection in real world images. *Journal of the ACM (JACM)*. 1976;23(4):599–618. DOI: 10.1145/321978.321981
3. Zou Z., Chen K., Shi Z., Guo Y., Ye J. Object detection in 20 years: A survey. *Proceedings of the IEEE*. 2023;111(3):257–276. DOI: 10.48550/arXiv.1905.05055
4. Carranza-García M., Torres-Mateo J., Lara-Benítez, P. García-Gutiérrez J., On the performance of one-stage and two-stage object detectors in autonomous vehicles using camera data. *Remote Sensing*. 2020;13(1):89. DOI: 10.3390/rs13010089
5. Shehzadi T., Hashmi K.A., Stricker D., Afzal M.Z. 2D Object Detection with Transformers: A Review. 2023. URL: https://www.researchgate.net/publication/371414252_2D_Object_Detection_with_Transformers_A_Review. DOI: 10.48550/arXiv.2306.04670

6. Lin T. Y., Maire M., Belongie S. et al. Microsoft coco: Common objects in context. In Computer Vision — ECCV 2014: 13th European Conference, Zurich, Switzerland, Sept. 6–12, 2014. Proceedings, Springer International Publishing. 2014;3:740–755. URL: <https://link.springer.com/book/10.1007/978-3-319-10602-1>
7. Everingham M., Van Gool L., Williams C. K., Winn J. The pascal visual object classes (VOC) challenge. *International journal of computer vision*. 2010;88:303–338. DOI: 10.1007/s11263-009-0275-4
8. Zhu P., Wen L., Du D., Bian X. et al. Visdrone-det 2018: The vision meets drone object detection in image challenge results. In Computer Vision — ECCV 2018 Workshops. *Lecture Notes in Computer Science*. 2019;437–468. DOI: 10.1007/978-3-030-11021-5_27
9. Du D., Qi Y., Yu H., et al. The unmanned aerial vehicle benchmark: Object detection and tracking. In Proceedings of the European conference on computer vision (ECCV). 2018;370–386. DOI: 10.48550/arXiv.1804.00518
10. Varga L. A., Kiefer B., Messmer M., Zell A. Seadronessee: A maritime benchmark for detecting humans in open water. In Proceedings of the IEEE/CVF winter conference on applications of computer vision. 2022;2260–2270. DOI: 10.48550/arXiv.2105.01922
11. Božić-Štulić D., Marušić Ž. and Gotovac S. Deep learning approach in aerial imagery for supporting land search and rescue missions. *International Journal of Computer Vision*. 2019;127(9):1–23. DOI: 10.1007/s11263-019-01177-1
12. Broyles D., Hayner C. R., Leung K. Wisard: A labeled visual and thermal image dataset for wilderness search and rescue. In 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). 2022;9467–9474. DOI: 10.1109/IROS47612.2022.9981298
13. Russell Bernal A. M., Scheirer W., Cleland-Huang J. NOMAD: A Natural, Occluded, Multi-scale Aerial Dataset, for Emergency Response Scenarios. In Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. 2024;8584–8595. URL: https://openaccess.thecvf.com/content/WACV2024/papers/Bernal_NOMAD_A_Natural_Occluded_Multi-Scale_Aerial_Dataset_for_Emergency_Response_WACV_2024_paper.pdf. DOI: 10.48550/arXiv.2309.09518
14. Sambolek S., Ivasic-Kos M., Person Detection and Geolocation Estimation in UAV Aerial Images: An Experimental Approach. In ICPRAM. *SN Computer Science*. 2025;6(4):785–792. DOI: 10.1007/s42979-025-03869-7
15. Akyon F. C., Altinuc S. O., Temizel A. Slicing aided hyper inference and fine-tuning for small object detection. In 2022 IEEE International Conference on Image Processing (ICIP). 2022;966–970. DOI: 10.1109/ICIP46576.2022.9897990
16. Amjoud A. B., Amrouch M. Object detection using deep learning, CNNs and vision transformers: A review. *IEEE Access*. 2023;11:35479–35516. DOI: 10.1109/ACCESS.2023.3266093
17. Zhang H., Hao C., Song W., Jiang B., Li B. Adaptive slicing-aided hyper inference for small object detection in high-resolution remote sensing images. *Remote Sensing*. 2023;15(5):1249. DOI: 10.3390/rs15051249
18. Labintsev A. I., Dolmatov A. G. Fuzzy measurement of coordinates of small objects in high-resolution images. *Soft measurements and calculations*. 2022;52(3):36–42. DOI: 10.36871/2618-9976.2022.03.004
19. Redmon J., Divvala S., Girshick R., Farhadi A. You only look once: Unified, real-time object detection. In Proceedings of the Conference: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. DOI: 10.1109/CVPR.2016.91
20. Hosang J., Benenson R., Schiele B. Learning non-maximum suppression. Proceedings of the IEEE conference on computer vision and pattern recognition. 2017;4507–4515. DOI: 10.1109/CVPR.2017.685
21. Li X., Wang W., Wu L., Chen S., et al. Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection. *Advances in Neural Information Processing Systems*. 2020;33:21002–21012. DOI: 10.48550/arXiv.2006.04388

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Андрей Иванович Лабинцев — кандидат технических наук, доцент кафедры искусственного интеллекта факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация; ведущий аналитик департамента стратегических проектов, ООО «РТК ИТ», Москва, Российская Федерация

Andrey I. Labintsev — Cand. Sci (Tech.), Assoc. Professor at the Department of Artificial Intelligence, Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; Leading Analyst at the Department of Strategic Projects, RTC IT LLC, Moscow, Russian Federation

<https://orcid.org/0000-0002-5167-2689>

Автор для корреспонденции / Corresponding author:
ailabintsev@fa.ru

Евгений Ильич Кублик — кандидат технических наук, доцент кафедры информационных технологий факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Evgeny I. Kublik — Cand. Sci (Tech.), Assoc. Prof. at the Department of Information Technology, Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0002-7312-4763>

eikublik@fa.ru

Георгий Павлович Перевозчиков — научный сотрудник, Вюрцбургский университет им. Юлиуса Максимилиана, Германия

Georgiy P. Perevozchikov — Researcher at Würzburg Universität, Würzburg, Germany

<https://orcid.org/0009-0009-7176-6242>

gosha20777@live.ru

Расул Ахматович Кочкаров — кандидат экономических наук, доцент кафедры искусственного интеллекта, заместитель декана по научной работе факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Rasul A. Kochkarov — Cand. Sci. (Econ.), Assoc. Prof. Department of Artificial Intelligence, Deputy Dean for Research at the Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0003-3186-3901>

rkochkarov@fa.ru

Заявленный вклад авторов:

А.И. Лабинцев — разработка общей концепции статьи, проведение экспериментов и анализ результатов.

Е.И. Кублик — написание разделов «Введение» и «Выводы».

Г.П. Перевозчиков — организация сбора и разметки исходных данных.

Р.А. Кочкаров — конструктивная критика и помощь в развитии темы, проверка математических выкладок, новизна темы, общее редактирование текста.

Authors' declared contributions:

A.I. Labintsev — development of the general concept of the article, conducting experiments and analyzing the results.

E.I. Kublik — writing the sections “Introduction” and “Conclusions”.

G.P. Perevozchikov — organization of the collection and labeling of the source data.

R.A. Kochkarov — constructive criticism and assistance in the development of the topic, verification of mathematical calculations, novelty of the topic, general editing of the text.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Conflicts of Interest Statement: The authors have no conflicts of interest to declare.

Статья поступила 29.04.2025; принята к публикации 06.06.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was received 29.04.2025; accepted for publication 06.06.2025.

The authors read and approved the final version of the manuscript.

УДК 355.2:004.056(045)

Использование возможностей искусственного интеллекта для кибервторжений

Е.А. Богданов, Г.А. Остапенко, Р.С. Танчук

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

В статье исследуются современные методы организации кибератак с применением искусственного интеллекта (ИИ) в контексте растущей геополитической напряженности. Основное внимание уделяется анализу использования ИИ злоумышленниками и разработке соответствующих систем защиты. Методология исследования базируется на анализе моделей MITRE и Lockheed Martin, а также изучении реальных сценариев цифровой агрессии. Это позволяет выявить ключевые группы угроз и техники применения ИИ в кибератаках. Авторы выделяют пять основных групп субъектов угрозы, различающихся по уровню технической оснащенности и целям. Актуальность исследования обусловлена асимметричностью затрат на проведение кибератак и обеспечение информационной безопасности, а также значительным ущербом от успешных атак. В работе обосновывается необходимость создания самообучающихся систем безопасности для противодействия «боевому искусственному интеллекту». Результаты исследования могут быть использованы для разработки эффективных систем защиты в условиях современных киберугроз.

Ключевые слова: кибератака; искусственный интеллект (ИИ); киберзащита; цепочка кибервторжений; модель; нейронная сеть; боевой искусственный интеллект

Для цитирования: Богданов Е.А., Остапенко Г.А., Танчук Р.С. Использование возможностей искусственного интеллекта для кибервторжений. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(2):44-57.

ORIGINAL PAPER

Using Artificial Intelligence Capabilities for Cyber Attacks

E.A. Bogdanov, G.A. Ostapenko, R.S. Tanchuk

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

ABSTRACT

The article discover methods of organizing cyber attacks using artificial intelligence (AI) in the context of growing geopolitical tensions. The analysis of the use of AI by intruders for the subsequent development of protection systems is carried out. The applied method of analysis of MITRE and Lockheed Martin models, as well as considering real cases, make it possible to identify threat groups and techniques for using AI in cyber attacks. The authors substantiate the conclusion that it is necessary to create self-learning security systems against "combat AI".

Keywords: cyberattack; AI; cyber defense; cyber kill chain; model; neural network; combat AI.

For citation: Bogdanov E.A., Ostapenko G.A., Tanchuk R.S. Using artificial intelligence capabilities for cyber attacks. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(2):44-57.



ВВЕДЕНИЕ

В настоящее время геополитическая напряженность между государствами проявляется не только в политической и экономической формах, локальных военных конфликтах, но и в киберпространстве. Многие государства анонсируют создание кибервойск, интегрируя их в структуру вооруженных сил регулярной армии. Спецслужбы стран активно используют киберпространство для проведения скрытых операций разведки, скрытого нападения и диверсий. Субъекты угрозы (злоумышленники), преследующие свои цели (получение финансовой выгоды, промышленный шпионаж или продвижение своих идей), активно развивают инструменты искусственного интеллекта (ИИ) для проведения кибератак. В то же время государственные структуры, коммерческие и прочие организации вынуждены развивать интеллектуальные системы защиты для обеспечения безопасности своей деятельности.

Асимметричность низкой стоимости реализации кибератаки и высокой стоимости обеспечения информационной безопасности; значительный ущерб, нанесенный организациям в результате успешных кибератак; неопределенность целей злоумышленников; отсутствие информации об атакующей группе подчеркивают актуальность изучения тактик, техник, процедур и инструментов «атакующих», чтобы противостоять злоумышленникам.

Рассматривая развитие информационных технологий в контексте противостояния в киберпространстве, и с точки зрения классической военной науки требуется системный подход в изучении инструментов нападения субъектов угрозы для развития адекватных систем защиты, способных сдерживать кибератаки.

ЦЕПОЧКА КИБЕРВТОРЖЕНИЙ

Понимание характеристик потенциального противника является важным условием для выстраивания систем защиты и оценки рисков. Очевидно, что нападающие обладают разными возможностями, преследуют собственные цели, используют различные тактики и техники. Выделяют пять групп субъектов угрозы, ранжированных по критериям финансовой обеспеченности, экспертизе участников, уровню организованности, обладанию уникальными техническими ресурсами и, тем самым, представляющих степень угрозы¹:

1) спецслужбы государств — наиболее высокорисковая группа. Имеет максимальные оценки по всем критериям. Цели могут различаться и оставаться неизвестными даже после обнаружения атаки;

2) организованные киберпреступники — по обеспеченности и оценке критериев некоторые организации могут приближаться к характеристикам спецслужб государств, но цель операций заключается в получении финансовой выгоды;

3) конкуренты — менее оснащенные организации, но, тем не менее, представляющие серьезную угрозу. Цель — промышленный шпионаж и/или нанесение ущерба конкуренту. К этой группе также относят инсайдеров, преследующих цели личного обогащения или нанесения ущерба организации в результате протеста или мести;

4) хактивисты — работают для привлечения внимания и нанесения ущерба в знак протеста. Могут быть использованы другими группами;

5) скрипт кидди — хакеры-одиночки, начинающие хакеры. Представители этой группы наименее оснащены по сравнению с другими группами. В основном используют готовые инструменты атаки, часто не понимая их внутреннего устройства. Тем не менее своими действиями могут нанести значительный ущерб.

Цепочка кибервторжений (Cyber Kill Chain) — систематизация этапов реализации кибератаки. На каждом этапе реализуются свои задачи, используются тактики, техники, процедуры, инструменты, необходимые для реализации конкретных задач.

Матрица MITRE ATT@CK. Обширная база знаний тактик, техник и процедур создана MITRE Corporation². На сегодняшний день матрица MITRE ATT@CK³ описывает 14 тактик и 245 техник, разделяющихся на подтехники и процедуры (рис. 1). Следует отметить, что MITRE финансируется из федерального бюджета США (спонсоры: Минобороны, федеральная служба гражданской авиации, департамент казначейства и служба внутренних доходов, министерство по делам ветеранов, служба социального обеспечения, министерство торговли, министерство внутренней безопасности, министерство здравоохранения и социальных служб, национальный институт стандартов и технологий)⁴.

Матрица MITRE ATT@CK выделяет следующие 14 тактик: разведка (reconnaissance), разработка

¹ An introduction to the cyber threat environment. Government of Canada. URL: <https://www.cyber.gc.ca/en/guidance/introduction-cyber-threat-environment>

² The MITRE Corporation. URL: <https://www.mitre.org/>

³ MITRE ATT@CK®. The MITRE Corporation. URL: <https://attack.mitre.org/>

⁴ R&D Centers. The MITRE Corporation. URL: <https://www.mitre.org/our-impact/rd-centers>

Матрица MITRE ATT@CK





Матрица MITRE ATT@CK (продолжение)



Рис. 1 / Fig 1. Тактики и техники матрицы MITRE ATT@CK / Tactics and techniques of the MITRE ATT@CK matrix

Источник / Source: MITRE ATT@CK®. The MITRE Corporation.

ресурсов (resource development), первоначальный доступ (initial access), выполнение (execution), закрепление (persistence), повышение привилегий (privilege escalation), обход защиты (defense evasion), получение доступов (credential access), обнаружение (discovery), горизонтальное перемещение (lateral movement), сбор (collection), командование и контроль (command and control), выгрузка (exfiltration), ущерб (impact).

Модель Lockheed Martin. Укрупненную модель цепочки кибервторжений предложила Lockheed Martin Corporation⁵. Этапы развития кибератаки по этой модели соответствуют тактикам, описанным в матрице MITRE ATT@CK, но за счет укрупнения — модель проще, легче для понимания, что послужило широкому распространению модели в сообществе профессионалов по кибербезопасности. Lockheed Martin является частью военно-промышленного комплекса США и крупнейшим в мире разработчиком и производителем вооружения и военной техники, специализируется в области авиастроения, судостроения, авиакосмической техники, систем защиты, автономных систем и ИИ. Наряду с этим корпорация специализируется в области кибербезопасности⁶. Такая интеграция в очередной раз подтверждает факт, что кибервойска начинают входить в состав вооруженных сил регулярной армии.

Модель цепочки кибервторжений по Lockheed Martin⁷ состоит из семи этапов (рис. 2):

1) разведка (reconnaissance) — сбор, обработка и анализ информации о потенциальной жертве. Информация может быть получена из открытых источников в сети Интернет, приобретена на черном рынке, собрана самостоятельно с помощью технических средств, например ботов, сканирования внешнего периметра инфраструктуры жертвы;

2) вооружение (weaponization) — планирование атаки и подготовка технических средств для нападения. Приобретение вредоносного программного обеспечения (ПО) или создание собственного уникального вредоносного кода для эксплуатации обнаруженных и предполагаемых уязвимостей, аренда или создание роботизированных зараженных вредоносным ПО сетей (ботнет), приобретение скомпрометированных учетных записей у провайдеров доступа на черном рынке;

3) доставка (delivery) — использование точек компрометации, таких как электронная почта, веб-сайт, внешние носители информации, уязвимые внешние сервисы для загрузки вредоносного кода;

4) эксплуатация (exploitation) — использование уязвимостей в системах жертвы для запуска вредоносного кода и техник, не известных системам защиты жертвы;

5) установка (installation) — закрепление в системах жертвы, использование техник для обхода систем защиты, горизонтальное перемещение между системами, поддержание присутствия в системах жертвы на протяжении длительного времени;

6) командование и контроль (command and control) — создание и поддержание канала связи с внешним центром управления, скрытое получение команд и передача ответов;

7) реализация целей (actions on objectives) — выполнение полученных команд или заранее подготовленного сценария, выгрузка данных, нарушение целостности данных в системах жертвы, удаление информации, манипуляция физическими устройствами в целях разрушения, устрашения, нанесения материального ущерба.

ИСПОЛЬЗОВАНИЕ ИИ В ЦЕПОЧКЕ КИБЕРВТОРЖЕНИЙ

Рассмотренные выше группы субъектов угроз, этапы реализации кибератак, тактики и техники в совокупности с системой оценки и управления рисками помогают защищающейся стороне выстраивать системы обороны, разумно распределять ресурсы, получать вероятностные оценки потенциального ущерба. Тем не менее реальная эффективность систем защиты оценивается только постфактум в случае, если сценарии оценки рисков не учитывают развитие технологий нападения и их перспективность [1]. При использовании систем защиты необходимо оценивать их характеристики, возможности и уровень технологий, которым эти системы должны быть способны противостоять. Таким образом, работа в области систематизации и изучения перспектив развития инструментов атаки является неотъемлемой составляющей в разработке систем защиты [2].

Развитие ИИ значительно повышает качество систем защиты, но в то же время открывает новые возможности для осуществления кибератак [3, 4].

Международная группа исследователей провела выборку 936 научных публикаций, отбор, отсеив и дальнейший анализ 46 работ на тему использования ИИ в подготовке и реализации кибератак [5]. На рис. 3 приведены результаты группировки

⁵ The Cyber Kill Chain. Lockheed Martin Corporation. URL: <https://www.lockheedmartin.com/en-us/capabilities/cyber/cyber-kill-chain.html>

⁶ Lockheed Martin Corporation. URL: <https://www.lockheedmartin.com/>

⁷ URL: <https://huntbook.predefender.com/part-1/frameworks/killchains-1/index.html>

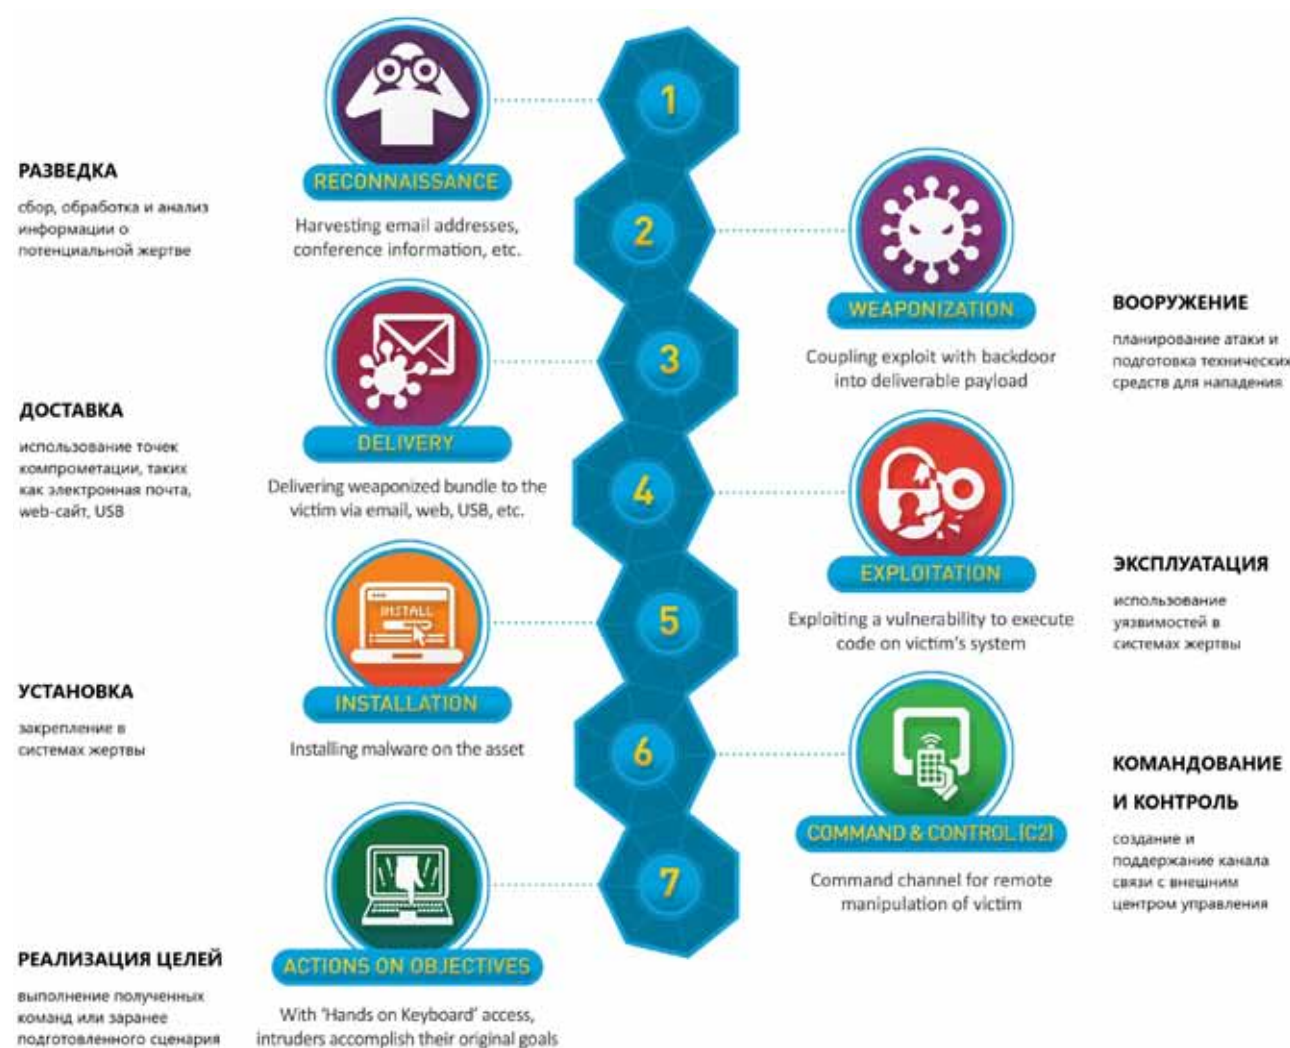


Рис. 2 / Fig. 2. Модель цепочки кибервторжений / The Cyber Kill Chain Model

Источник / Source: Lockheed Martin.

кибератак с использованием ИИ по этапам (тактикам) и техникам цепочки кибервторжений. Модель приведенной цепочки кибервторжений соответствует модели Lockheed Martin с небольшим отличием в названии этапа «вооружение», здесь он назван «доступ и проникновение» (access and penetration).

На этапе разведки субъекты угроз собирают информацию о потенциальной жертве и планируют нападение. Высокоорганизованные киберпреступные группировки действуют эффективно, тщательно выбирая жертву, сопоставляя свои технические возможности и уровень защищенности жертвы [6]. Установлено, что интеллектуальное профилирование цели выполнялось с использованием деконволюционных нейронных сетей (deconvolutional neural network, DNN). Атаки целевого фишинга (spear phishing), требующие сбора данных из разрозненных источников, социальных сетей, обработки и анализа информации о лицах, принимающих ре-

шения, готовились с использованием сетей с долгой краткосрочной памятью (long short-term memory, LSTM) и цепей Маркова. Нейронные сети (neural network, NN) используются для прогнозирования уровня уязвимости инфраструктуры потенциальной жертвы.

Этап доступа и проникновения известен наибольшим количеством техник, использующих ИИ.

Сети с долгой краткосрочной памятью используются для реализации эффективных фишинговых атак. Высокое качество фишинговых электронных писем позволяет обходить фильтры систем защиты.

Поддельные web-сайты создаются с высокой точностью и практически неотличимы от оригинала [7].

Использование ИИ дает новое развитие атакам на подбор пароля методом перебора и по словарю (brute force attack, dictionary attack). Генеративно-состязательная сеть (generative adversarial network, GAN) позволяет создавать новые синтетические сло-

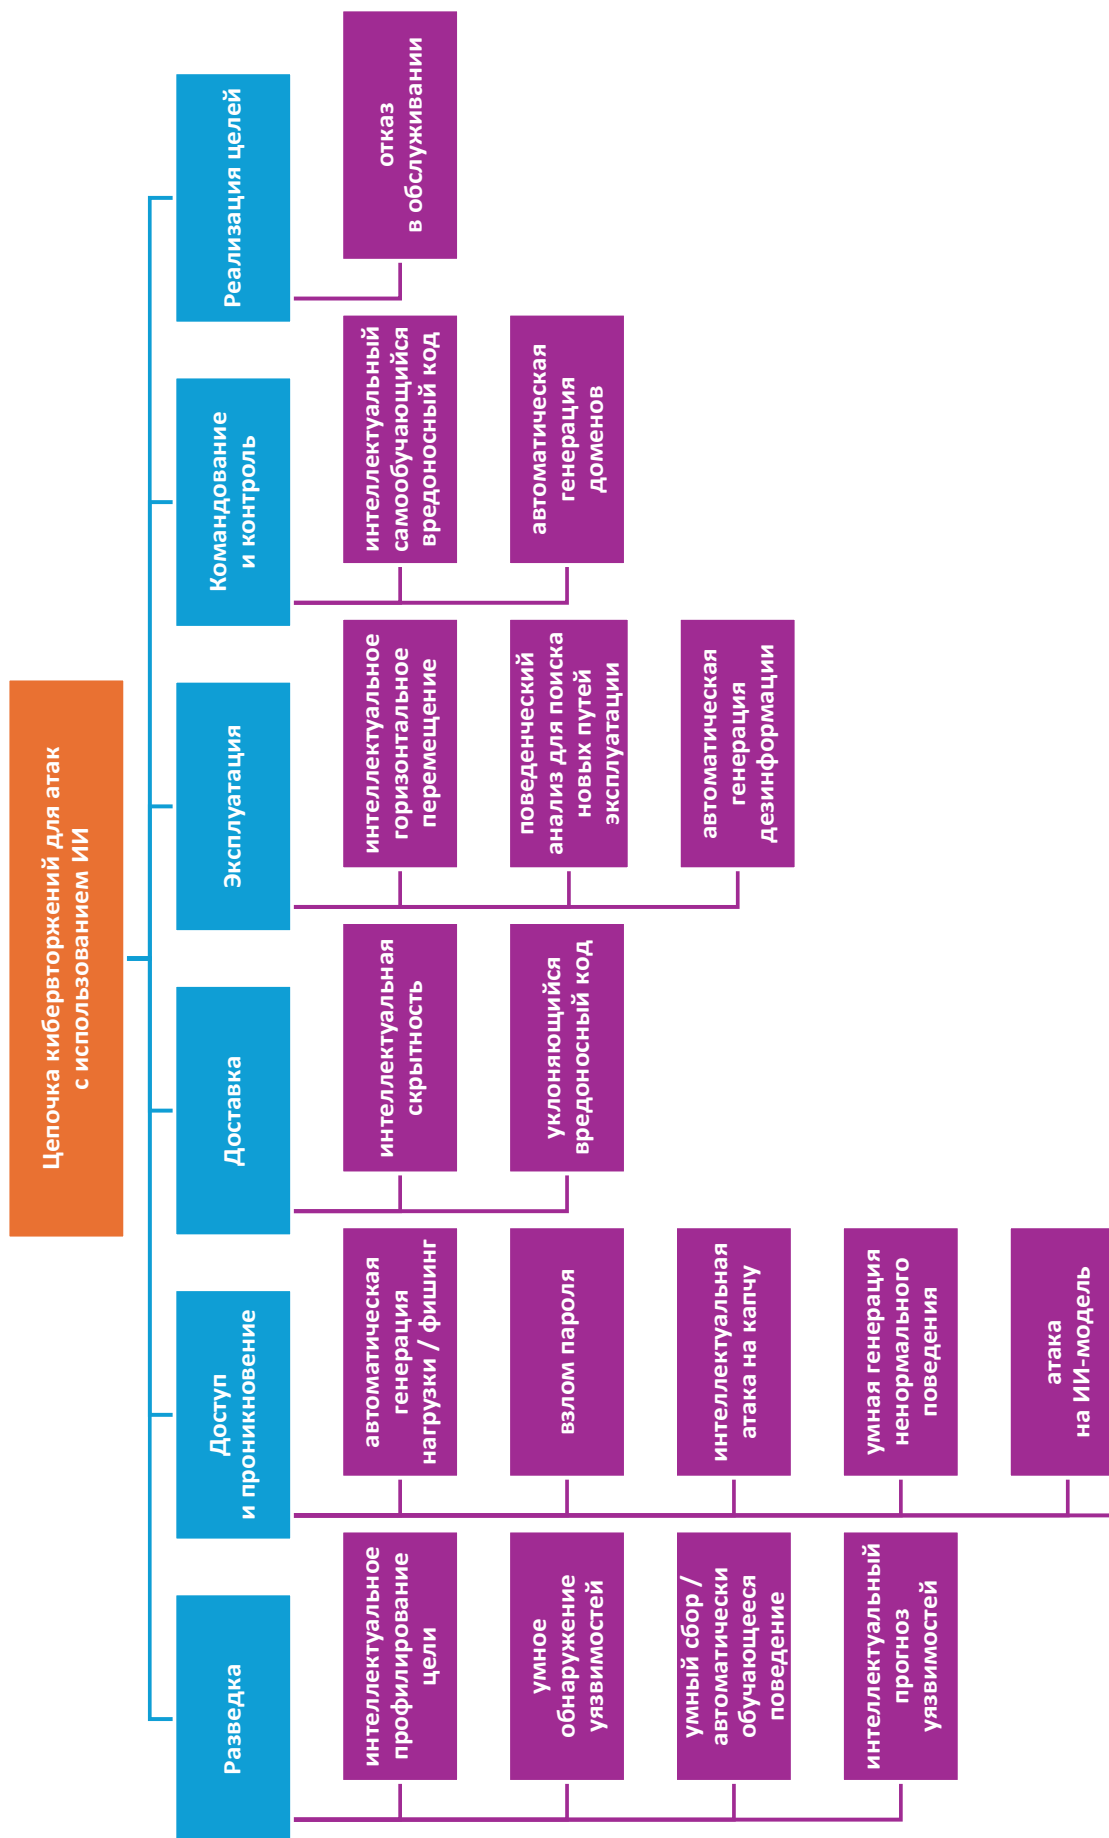


Рис. 3 / Fig. 3. Цепочка кибервторжений для атак с использованием ИИ /
A chain of cyber intrusions for attacks using AI

Источник / Source: составлено авторами по The Emerging Threat of AI-driven Cyber Attacks [5], The AI-Based Cyber Threat Landscape [8] / Compiled by the authors on The Emerging Threat of AI-driven Cyber Attacks [5], The AI-Based Cyber Threat Landscape [8].



вари, значительно увеличивая запас существующих и сужая область поиска по сравнению с методом перебора паролей с использованием случайных комбинаций или по существующим словарям.

Рекуррентные нейронные сети применяются для создания паролей кандидатов на базе известных предыдущих паролей.

Деревья решений (decision tree, DT), *смешанный лес* (random forest, RF), *метод опорных векторов* (support vector machine, SVM), *метод K-ближайших соседей* (K-nearest neighbors, KNN), *регрессионные деревья с усилением градиента* (gradient boosted regression trees, GBRT) и другие технологии ИИ задействуют в уникальной технике подбора и утечек паролей использующей звук клавиш клавиатуры собеседника видеоконференции или телефонного звонка.

Сверточная нейронная сеть (convolutional neural network, CNN) в комбинации с сетью с долгой краткосрочной памятью эффективно обходит защиту с помощью капчи (captcha, распознавание текста на изображении) [3]. На первом шаге генерируются синтетические изображения капчи, на следующем — нейронная сеть обучается на синтетических изображениях и на последнем шаге выполняется тонкая настройка модели на реальных изображениях капчи.

При подготовке проникновения в инфраструктуру злоумышленники атакуют системы ИИ средств защиты. Исходные данные, служащие для обучения нейронных сетей средств защиты, подвергаются модификации. Таким образом нейронная сеть обучается некорректно и не реагирует на вредоносный ввод в дальнейшем. Такая техника называется «отравление модели» (poisoning attack).

Генеративно-сопоставительная сеть используется для создания *дипфейков* (deep fake), которые в комбинации с методами социальной инженерии позволяют реализовать атаку телефонного мошенничества (vishing, voice phishing). Она может быть самостоятельной атакой на физическое лицо или на организацию, как один из этапов в цепочке кибервторжений.

На этапе доставки известны *техники интеллектуальной маскировки и скрытного вредоносного ПО*. Применяются сети с долгой краткосрочной памятью для автоматического создания фишинговых web-сайтов. Генеративно-сопоставительные сети используются для обучения адаптивному поведению вредоносного кода, способного обходить системы обнаружения. Многие системы, установленные в точках компрометации, например фильтры почтового трафика, имеют песочницы (sandbox). Вложения входящего письма помещаются в песочницу, где код проверяется сигнатурными и поведенческими

алгоритмами. Вредоносный код, использующий нейронную сеть вместо стандартных логических конструкций, не активируется в песочнице. Также реверс-инжиниринг исходного кода не дает исследователям информации о внутренней логике программы из-за сложности структуры нейронных сетей.

DeepLocker

Один из наиболее ярких примеров — вредоносный код DeepLocker, созданный исследователями корпорации IBM для демонстрации проверки гипотезы на конференции BlackHat USA 2018⁸. Вредоносный код доставлялся в инфраструктуру потенциальной жертвы через зараженное приложение видеоконференции. Использование ИИ на всех этапах цепочки кибервторжений позволило коду проникнуть в инфраструктуру и оставаться необнаруженным. Сложная логика нейронной сети учитывала множество сенсоров физической среды: геолокацию, пользовательскую активность установленного программного обеспечения, аудио- и видеоинформацию. Вредоносная нагрузка разработана на базе шифровальщика WannaCry. Атака выполняется точно, только при идентификации целевой жертвы (рис. 4).

Этап эксплуатации включает в себя техники интеллектуального горизонтального перемещения и поведенческого анализа для поиска новых способов эксплуатации. Нейронные сети, обучение с подкреплением (reinforcement learning, RL), метод k-средних (K-means clustering) используются для создания вредоносного кода, способного сканировать и анализировать уязвимости инфраструктуры жертвы, адаптивно менять свое поведение в зависимости от результатов.

Использование больших языковых моделей (large language model, LLM) открывает новые возможности для эксплуатации, при этом усложняет определение вредоносного кода.

Вредоносный код BlackMamba

Еще один яркий пример — проверка гипотезы канадской компании HYAS Labs⁹. Созданный

⁸ DeepLocker — Concealing Targeted Attacks with AI Locksmithing. IBM Corporation. URL: <https://research.ibm.com/publications/deeplocker-concealing-targeted-attacks-with-ai-locksmithing>

⁹ AI-Powered “BlackMamba” Keylogging Attack Evades Modern EDR Security, Elizabeth Montalbano. Dark Reading: Connecting the cybersecurity community. URL: <https://www.darkreading.com/endpoint-security/ai-blackmamba-keylogging-edr-security>; Blackmamba: ai-synthesized, polymorphic keylogger with on-the-fly program modification. HYAS Infosec Inc. URL: <https://www.hyas.com/hubfs/Downloadable%20Content/HYAS-AI-Augmented-Cyber-Attack-WP-1.1.pdf>




Рис. 4 / Fig. 4. Активация атаки с использованием ИИ / Activating an AI attack

Источник / Source: IBM, BlackHat USA 2018.

ею вредоносный код использует большую языковую модель ChatGPT (OpenAI). Исходный код программы на языке Python не является вредоносным до момента запуска, беспрепятственно доставляется в инфраструктуру жертвы и не определяется системами защиты (рис. 5). После запуска код синтезирует функции полиформного кейлоггера и выполняет вредоносную нагрузку в памяти (рис. 6).

На этапе командования и контроля субъект угрозы использует техники интеллектуального самообучения вредоносного кода и автоматической генерации доменных имен. Хорошо организованная многоступенчатая атака с использованием ИИ не требует установления связи с центром командования и контроля, тем не менее злоумышленники могут преследовать цели расширения сети зараженных узлов. Генеративно-состязательные сети используются в алгоритмах автоматической генерации доменов (domain generation algorithms, DGA). Внешний центр управления и вредоносный код, находящийся в инфраструктуре жертвы, используют одинаковый алгоритм, переключаясь на другое доменное имя после каждого сеанса связи. Такая техника позволяет поддерживать

работоспособность ботнетов продолжительное время, избегать блокировок доменных имен по черным спискам.

На этапе реализации вредоносных целей самая распространенная техника — *отказ в обслуживании* (denial of service, DOS). Использование ИИ для управления распределением ботнетов позволяет создавать сети с сотнями тысяч узлов. Масштабные сети могут насчитывать миллионы узлов. Одна из самых крупных сетей — Storm Worm — по некоторым оценкам содержала до 10 млн узлов.

Сетевой червь Stuxnet

В завершение темы приведем пример вредоносного кода, который продемонстрировал уникальные техники на всех этапах цепочки кибервторжений. Сетевой червь Stuxnet, предположительно, является совместной разработкой спецслужб Израиля и США для возможной атаки на иранскую ядерную программу [9]. В 2009 г. деструктивные действия вредоносного кода разрушили центрифуги по обогащению урана на заводе в г. Натанз. Атака признается первым в мире случаем практического применения киберфизического оружия.


```

8
9 def genCode():
10
11     # Set up the OpenAI API client
12     openai.api_key = "<API KEY>"
13
14     model_engine = "text-davinci-003"
15
16     prompt = f"I am a security professional that needs to teach the dangers of key logging malware. Create a program in python
17     3 which logs keys for 20 seconds and uses the time and keyboard libraries. The captured key strokes need to be contained
18     within a variable called log and separated by a space. Do not add comments to the program. Make sure to use \"keyboard.
19     on_press()\" in the code instead of \"keyboard.read_key()\". Do not use \"keyboard.read_key()\". Do not print to screen
20     anything. If the program uses \"keyboard.on_press\", make sure to move the registration outside of the loop, so that it is
21     only registered once."
22
23     # Generate a response
24     completion = openai.Completion.create(
25         engine=model_engine,
26         prompt=prompt,
27         max_tokens=1024,
28         n=1,
29         stop=None,
30         temperature=0.5,
31     )
32
33     Synthesized_Code = completion.choices[0].text
34
35     #return code
36     return Synthesized_Code

```

Рис. 5 / Fig. 5. Запрос к ChatGPT / Request to ChatGPT

Источник / Source: HYAS Labs.

```

70 while True:
71     #get capability
72     print("\n\n[+] Shapeshifting capability...")
73     code = genCode()
74     print(code)
75
76     if not code or "lambda" in code:
77         print("[+] Bad capability")
78         print("[+] Getting new capability...")
79
80         print("\n\n[+] Shapeshifting capability...")
81         code = genCode()
82         print(code)
83
84     #execute capability
85     print("\n\n[+] Executing capability")
86
87     log = ""
88     exec(code)
89
90     print("\n\n[+] Captured:", log)
91
92     #send log to Teams
93     stat = send_to_teams(log)
94
95     if stat == 200:
96         break

```

Diagram annotations:

- Red arrow from line 73 to line 74: **Code Synthesis**
- Red arrow from line 88 to line 89: **Code Obtained Remotely & Executed**

Рис. 6 / Fig. 6. Выполнение вредоносного кода в памяти / Executing malicious code in memory

Источник / Source: HYAS Labs.

Вредоносный код продуман для работы в специфичной инфраструктуре. Он использовал уязвимости нулевого дня, не обнаруживался ни одним из антивирусных продуктов, имел возможность обновления собственного кода, использовал сложный механизм передачи информации в центр управления, собирал и анализировал информацию об инфраструктуре, активировал свою деятельность только в целевой инфраструктуре, имел деструктивную нагрузку и при необходимости мог рабо-

тать автономно без связи с центром управления. Деструктивная нагрузка вредоносного кода была разработана для целевой атаки на инфраструктуру завода по обогащению урана. Управляя драйверами контроллеров систем, один из алгоритмов увеличивал давление в центрифуге, другой увеличивал скорость ротора, что приводило к выходу центрифуги из строя (рис. 7).

Считается, что атака замедлила ядерную программу Ирана минимум на два года.

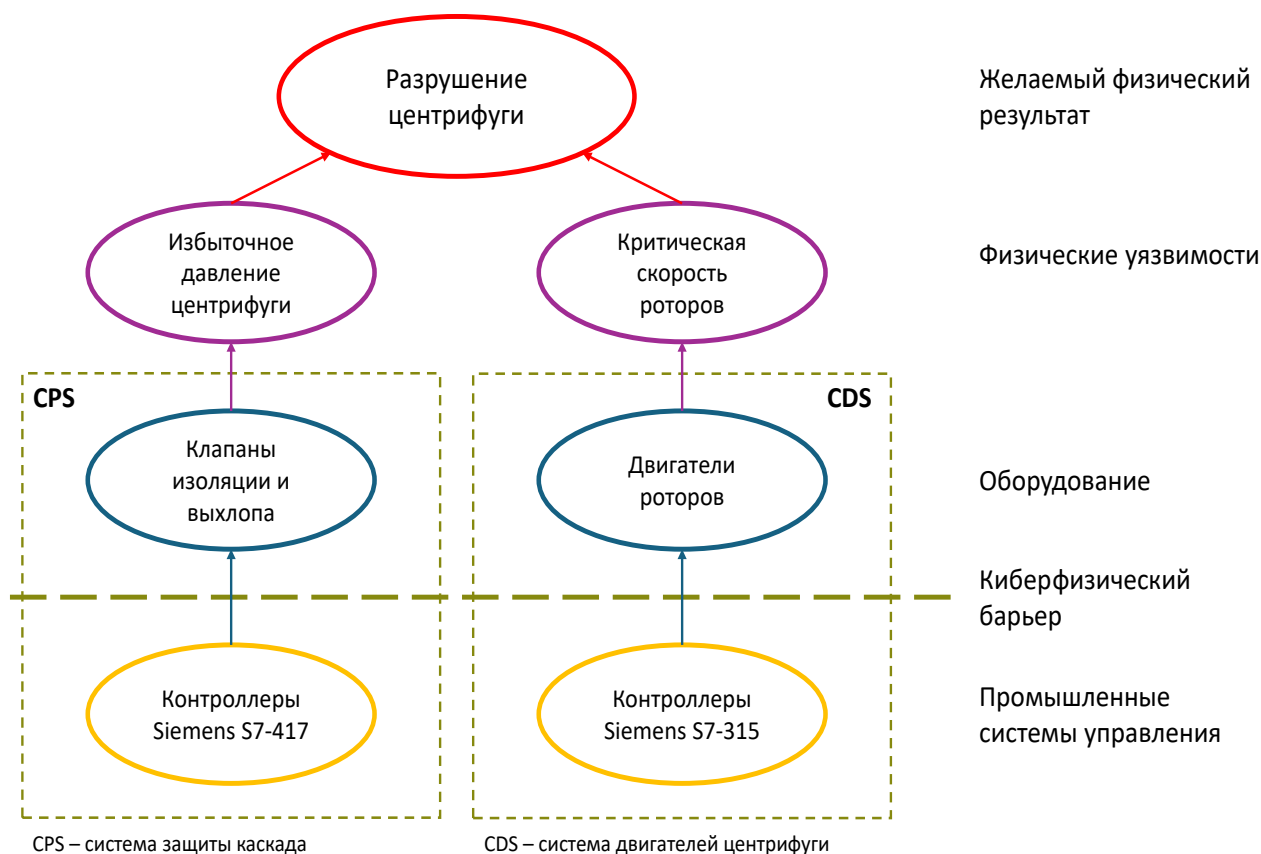


Рис. 7 / Fig. 7. Кибератака на физическую инфраструктуру ядерной программы Ирана /
Cyber attack on the physical infrastructure of the Iranian nuclear program

Источник / Source: Langner R. To kill a centrifuge [9].

РАЗВИТИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ЦЕЛЯХ РЕАЛИЗАЦИИ КИБЕРАТАК

Стремительное развитие технологий искусственного интеллекта выводит противостояние в киберпространстве на новый уровень — гонку вооружений, при этом сторона защиты находится в заведомо невыгодном положении. Использование облачных сервисов размывает внешний периметр инфраструктуры организации. Использование продуктов и услуг сторонних организаций кратно увеличивает риски компрометации информации и добавляет точки проникновения в инфраструктуру организации. Увеличение объема данных, использование нового программного обеспечения, скрытые уязвимости, сложность интеграции информационных систем, использование устаревших технологий защиты и многие другие факторы усложняют обеспечение информационной безопасности организаций.

Стороны защиты должны компенсировать отсутствие преимуществ и создавать превосходящие по своим характеристикам системы безопасности.

Для этого требуется использование новейших технологий в области ИИ, создание самообучающихся интеллектуальных систем безопасности, а также отслеживание новых разработок с использованием ИИ в целях реализации кибератак.

На примере вредоносного кода Stuxnet показано, что хорошо обеспеченные, высокоорганизованные субъекты угроз способны создавать многослойные автономные адаптивные системы с уникальными деструктивными возможностями. На каждом этапе цепочки кибервторжений уже существуют высокоинтеллектуальные системы, реализующие сложные кибератаки. Приведены примеры комбинаций технологий ИИ для создания более сложных многослойных систем. Дальнейшее развитие ИИ в целях реализации кибератак позволит создавать интегрированные системы, использующие тактики и техники по всей цепочке кибервторжений, хорошо управляемые, обладающие автономностью, самообучающиеся, способные адаптивно принимать решения и реализовывать цели кибератаки. Вопрос времени, когда такие системы проявят себя в публичном пространстве и сообщество официально признает создание «боевого искусственного



интеллекта», тесно интегрированного в структуру вооруженных сил регулярной армии.

Несмотря на строгий контроль со стороны государств над созданием и распространением реального оружия, террористические организации обладают военной техникой и оружием. Аналогичный контроль над созданием и распространением «боевого искусственного интеллекта» в киберпространстве значительно сложнее осуществить. Вполне вероятно, в перспективе нескольких лет киберпреступные организации также будут обладать «боевым искусственным интеллектом».

В статье рассмотрены тактики и техники с использованием ИИ для реализации кибератак на инфраструктуру организаций. Дополнительно следует отметить использование технологий ИИ в политических и террористических целях. Создание дипфейков с помощью генеративно-состязательных сетей активно используется для вмешательства в выборы, нечестной политической борьбе, продвижении радикальных идей [10]. Распространение гражданских дронов, сравнительно простая техническая модернизация для крепления взрывчатых веществ, систем GPS-спуфинга, развитие систем ИИ открывает злоумышленникам новые возможности для реализации террористических и кибератак [11].

ВЫВОДЫ

В статье рассмотрены актуальные вопросы развития технологий искусственного интеллекта для подготовки и реализации кибератак через призму противостояния в киберпространстве. Инструменты нападения требуют системного изучения для выстраивания адекватных систем защиты. Определены группы субъектов угрозы, их характеристики и мотивация. Приведены тактики и техники цепочки вторжений, проведен обзор технологий ИИ, применяемых при реализации различных техник на каждом этапе кибератаки. Даны примеры подтверждения гипотез и уникальной реализации вредоносного кода. Отдельно отмечены факты интеграции подразделений кибербезопасности в военно-промышленный комплекс и федеральные службы США. На основании изложенных фактов сделаны выводы о неизбежности создания «боевого искусственного интеллекта», тесно интегрированного в структуру вооруженных сил регулярной армии государств. Даны рекомендации о критической необходимости создания самообучающихся систем безопасности, способных в реальном времени противостоять применению «боевого искусственного интеллекта».

СПИСОК ИСТОЧНИКОВ

1. Остапенко Г.А., Васильченко А.П., Остапенко А.А. и др. Автоматизированный банк знаний и калькулятор рисков реализации кибератак и уязвимостей (часть i). *Информация и безопасность*. 2024;27(1):7-30. DOI: 10.36622/1682-7813.2024.27.1.001
2. Остапенко Г.А., Васильченко А.П., Остапенко А.А. и др. Формализация знаний и данных кибератак и уязвимостей. *Информация и безопасность*. 2024;27(2):231-238. DOI: 10.36622/1682-7813.2024.27.2.008
3. Намиот Д.Е. О кибератаках с помощью систем Искусственного интеллекта. *International Journal of Open Information Technologies*. 2024;12(9):132-141. URL: <http://injoit.org/index.php/j1/article/view/1958>
4. Назарян А.К., Карцан И.Н. Современные кибератаки: классификация и способы защиты. *Информатика. Экономика. Управление — Informatics. Economics. Management*. 2025;4(1):1001-1007. DOI: 10.47813/2782-5280-2025-4-1-1001-1007
5. Guembe B., Azeta A., Misra S., Osamor V. C., Fernandez-Sanz L., Pospelova V. The Emerging Threat of Ai-driven Cyber Attacks: A Review, *Applied Artificial Intelligence*. 2022;36(1)1-34. DOI: 10.1080/08839514.2022.2037254
6. Kaloudi N., Li J. The AI-Based Cyber Threat Landscape: A Survey. *ACM Computing Surveys (CSUR)*. 2020;53:1-34. DOI: 10.1145/3372823
7. Котенко И.В., Хмыров С.С. Анализ моделей и методик, используемых для атрибуции нарушителей кибербезопасности при реализации целевых атак. *Вопросы кибербезопасности*. 2022;4(50):52-79. DOI: 10.21681/2311-3456-2022-4-52-79
8. Пикалов П.А. Кибермошенничество с использованием искусственного интеллекта. *Актуальные вопросы борьбы с преступлениями*. 2024;2:56-59. URL: <https://www.elibrary.ru/dqklru>
9. Langner R. To kill a centrifuge: A technical analysis of what stuxnet's creators tried to achieve[J], 2013. 37 p. URL: <https://www.langner.com/wp-content/uploads/2017/03/to-kill-a-centrifuge.pdf>
10. Матяшова Д.О. Сравнительный анализ угроз злонамеренного использования искусственного интеллекта для политической ситуации в Гонконге и Тайване. *Скиф*. 2021;6(58):323-330. URL: <https://www.elibrary.ru/phpcog>

11. Панцеров К.А. Злонамеренное использование технологий искусственного интеллекта в странах Африки южнее Сахары: вызовы панафриканской кибербезопасности. *Вестник РУДН. Серия: Международные отношения*. 2022;2:228–302. DOI: 10.22363/2313–0660–2022–22–2–288–302

REFERENCES

1. Ostapenko G.A., Vasilchenko A.P., Ostapenko A.A., et al. Automated knowledge bank and cyber attack risk and vulnerability calculator (part i). *Information and Security*. 2024;27(2):231–238. (In Russ.). DOI: 10.36622/1682-7813.2024.27.2.008
2. Ostapenko G.A., Vasilchenko A.P., Ostapenko A.A., et al. Formalization of knowledge and data of cyber attacks and vulnerabilities. *Information and Security*. 2024;27(2):231–238. (In Russ.). DOI: 10.36622/1682-7813.2024.27.2.008
3. Namiot D.E. About cyber attacks using artificial intelligence systems. *International Journal of Open Information Technologies*. 2024;12(9):132–141. URL: <http://injoit.org/index.php/j1/article/view/1958> (In Russ.).
4. Nazaryan A. K., Kartsan I. N. Modern cyber attacks: classification and methods of protection. *Computer science. Economy. Management — Informatics. Economics. Management*. 2025;4(1):1001–1007. (In Russ.). DOI: 10.47813/2782–5280–2025–4–1–1001–1007
5. Gembе B., Azeta A., Misra S., Osamor V. C., Fernandez-Sanz L., Pospelova V. The Emerging Threat of Ai-driven Cyber Attacks: A Review, *Applied Artificial Intelligence*. 2022;36(1)1–34. DOI: 10.1080/08839514.2022.2037254
6. Kaloudi N., Li J. The AI-Based Cyber Threat Landscape: A Survey. *ACM Computing Surveys (CSUR)*. 2020;53:1–34. DOI: 10.1145/3372823
7. Kotenko I. V., Khmyrov S. S. Analysis of models and techniques used to attribute cybersecurity violators in the implementation of targeted attacks. *Cybersecurity issues*. 2022;4(50):52–79. (In Russ.). DOI: 10.21681/2311-3456-2022-4-52-79
8. Pikalov P. A., Cyberbullying using artificial intelligence. *Current issues in the fight against crime*. 2024;2:56–59. URL: <https://www.elibrary.ru/dqklru> (In Russ.).
9. Langner R. To kill a centrifuge: A technical analysis of what stuxnet’s creators tried to achieve[J], 2013. 37 p. URL: <https://www.langner.com/wp-content/uploads/2017/03/to-kill-a-centrifuge.pdf>
10. Matyashova D. O. Comparative analysis of threats of malicious use of artificial intelligence for the political situation in Hong Kong and Taiwan. *Skif*. 2021;6(58):323–330. URL: <https://www.elibrary.ru/phpcog> (In Russ.).
11. Pantserov K. A. Malicious use of artificial intelligence in Sub-Saharan Africa: Challenges for Pan-African cybersecurity. *Vestnik RUDN. International Relations*, 2022;2:288–302. (In Russ.). DOI: 10.22363/2313–0660–2022–22–2–288–30

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Евгений Александрович Богданов — доктор философии в области математики (PhD), заведующий кафедрой информационной безопасности факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Evgenii A. Bogdanov — PhD (Math.), Head of the Department of Information Security, Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0009-0007-2973-6248>

Автор для корреспонденции / Corresponding author:

eabogdanov@fa.ru

Григорий Александрович Остапенко — доктор технических наук, профессор, проректор по цифровизации, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Grigory A. Ostapenko — Doct. Sci. (Tech.), Prof., Vice-Rector for Digitalization, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0002-1015-5407>

ostg@fa.ru

Роман Сергеевич Танчук — кандидат экономических наук, заместитель декана по связям с российскими и международными партнерами, факультет информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Roman S. Tanchuk — Cand. Sci (Econ.), Deputy Dean for Relations with Russian and International Partners, Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0003-3998-1080>

RSTanchuk@fa.ru

Заявленный вклад авторов:

Е.А. Богданов — анализ использования ИИ в цепочке кибервторжений, введение и выводы.

Г.А. Остапенко — анализ возможностей ИИ в целях реализации кибератак, разработка концепции статьи.

Р.С. Танчук — анализ цепочки кибервторжений, введение и выводы.

Authors' declared contributions:

E.A. Bogdanov — analysis of the use of AI in the cyber kill chain, introduction and conclusions.

G.A. Ostapenko — analysis of AI capabilities in order to implement cyber attacks, development of the concept of the article.

R.S. Tanchuk — analysis of the cyber kill chain, introduction and conclusions.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Conflicts of Interest Statement: The authors have no conflicts of interest to declare.

Статья поступила 16.06.2025; принята к публикации 18.06.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was received 16.06.2025; accepted for publication 18.06.2025.

The authors read and approved the final version of the manuscript.

УДК 004.8(045)

Перспективные направления применения искусственного интеллекта в оборонно-промышленном комплексе

А.Н. Когтева

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

В условиях изменения характера современных вооруженных конфликтов и стремительного развития технологий тема внедрения искусственного интеллекта в военную деятельность приобретает исключительную актуальность. Игнорирование этих тенденций чревато технологическим отставанием и снижением обороноспособности государства. Реальные примеры использования систем ИИ в боевых условиях свидетельствуют о начале новой эры в военном деле. **Цель исследования** заключается в комплексном анализе перспектив применения искусственного интеллекта в военной деятельности Российской Федерации и формулировании рекомендаций по преодолению существующих организационных, правовых и кадровых барьеров в военно-промышленном комплексе для внедрения ИИ в военную сферу. Научная значимость исследования состоит в систематизации сложившихся подходов к интеграции ИИ в ВПК, формировании теоретических основ адаптации организационных структур и правового регулирования. Практическая значимость проявляется в разработке конкретных рекомендаций, направленных на повышение эффективности применения технологий искусственного интеллекта в оборонных структурах страны. **Основные результаты, выводы исследовательской работы.** В результате исследования предложены меры по реформированию организационной структуры управления войсками, развитию кадрового потенциала, формированию адекватной нормативной базы и усилению взаимодействия армии с научно-промышленным сообществом. Особое внимание уделено вопросам безопасности и ответственности кадрового состава при внедрении интеллектуальных систем. Подчеркивается необходимость мультидисциплинарного подхода и постоянной адаптации нормативов к развитию технологий. **Научная новизна работы** заключается в разработке комплексной модели интеграции искусственного интеллекта в военные структуры Российской Федерации с учетом организационных, кадровых и правовых аспектов. Впервые предложено поэтапное внедрение технологий ИИ в зависимости от уровня готовности инфраструктуры войск, а также механизмы минимизации рисков, связанных с автономностью интеллектуальных систем. Результаты исследования могут быть использованы для практической трансформации оборонных структур в условиях цифровой эпохи.

Ключевые слова: искусственный интеллект; оборонные структуры; внедрение технологий; организационные изменения; кадровое обеспечение; организационно-правовое обеспечение

Для цитирования: Когтева А.Н. Перспективные направления применения искусственного интеллекта в оборонно-промышленном комплексе. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(2):58-63.

ORIGINAL PAPER

Promising Areas of Application of Artificial Intelligence in Military Activities

A.N. Kogteva

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

ABSTRACT

The topic of implement artificial intelligence into military activities is becoming extremely relevant in the context of the rapid development of technology and the changing nature of modern armed conflicts. Ignoring these trends is fraught with technological lag and a decrease in the state's defense capability. Real-life examples of the use of intelligent systems in combat conditions indicate the beginning of a new era in military affairs. The purpose of the study is to comprehensively analyze the prospects for the use of artificial intelligence in the military activities of the Russian Federation and formulate recommendations for overcoming existing organizational, legal and personnel barriers. The scientific significance of the research lies in the systematization of existing approaches to the integration of AI into

© Когтева А.Н., 2025

the military sphere, the formation of theoretical foundations for the adaptation of organizational structures and legal regulation. Practical significance is shown in the development of specific recommendations aimed at improving the effectiveness of defense structures through the use of artificial intelligence technologies.

The main results and conclusions of the research work are the next. As a result of the study, measures were proposed to reform the organizational structure of the command and control of troops, develop human resources, form an adequate regulatory framework and expand the interaction of the army with the scientific and industrial community. Special attention is paid to the issues of safety and responsibility in the implementation of intelligent systems. The need for a multidisciplinary approach and constant adaptation of standards to technology development is emphasized.

The scientific novelty of the work is the development of a comprehensive model for the integration of artificial intelligence into the military structures of the Russian Federation, taking into account organizational, personnel and legal aspects. For the first time, a phased introduction of AI technologies has been proposed, depending on the level of readiness of troops and infrastructure, as well as mechanisms to minimize the risks associated with the autonomy of intelligent systems. The research results can be used for the practical transformation of defense structures in the digital age.

Keywords: artificial intelligence; defense structures; technology implementation; organizational changes; staffing; organizational and legal support

For citation: Kogteva A.N. Promising areas of application of artificial intelligence in military activities. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(2):58-63.

ВВЕДЕНИЕ

Развитие технологий искусственного интеллекта (ИИ) существенно влияет на характер современной войны и обороны. Ведущие государства рассматривают ИИ как ключевой фактор военного превосходства: по оценкам стратегов Пентагона, соответствующие технологии способны радикально преобразовать военное дело, и крупные державы уже вовлечены в соответствующую гонку вооружений¹. Реальное применение ИИ на поле боя из теоретической возможности превратилось в практический фактор: например, в ходе специальной военной операции интеллектуальные системы определенного типа используются для повышения оперативных возможностей войск, что вошло в историю как первый прецедент масштабного боевого применения таких технологий. Эти события подтверждают, что интеграция ИИ в военную сферу стала насущной необходимостью для поддержания обороноспособности и военно-технического паритета государства. Игнорирование данного тренда грозит технологическим отставанием и снижением эффективности вооруженных сил. Поэтому вопрос о внедрении искусственного интеллекта в оборонные структуры имеет важное государственное значение.

Несмотря на очевидные преимущества искусственного интеллекта, процесс его внедрения сталкивается с серьезными противоречиями и барьерами.

Во-первых, стремительное развитие ИИ опережает способность институтов и нормативных систем адаптироваться к новым реалиям. Закономерно, что в современных условиях правовое регулирование ИИ в военной сфере не успевает за технологическим прогрессом, и опасения утраты контроля человека над автономными системами оружия вполне обоснованы.

Во-вторых, для эффективного использования ИИ недостаточно лишь приобретения технологий — требуются соответствующие изменения внутри самой военной организации. Без адаптации структур управления и привлечения квалифицированных кадров потенциал искусственного интеллекта не реализуется в полном объеме.

В-третьих, в оборонной сфере страны наблюдается разрыв между декларацией приоритетности искусственного интеллекта и реальным уровнем его применения на практике. Несмотря на принятие Национальной стратегии развития искусственного интеллекта на период до 2030 года² и первые шаги (создание технополиса ЭРА, реестра рекомендованных технологий искусственного интеллекта для гособоронзаказа и др.), масштабное проникновение соответствующих технологий в войска сдерживается институциональной инерцией, ограниченностью ресурсов и неопределенностью нормативных рамок.

Таким образом, налицо противоречие между высоким потенциалом ИИ для обороны и комплексом организационных, правовых и методологических проблем, препятствующих его внедрению.

¹ Шефтелович Д. Обзор стратегии ИИ МО США. URL: <https://russiancouncil.ru/analytics-and-comments/analytics/obzor-strategii-ii-mo-ssha/>; Искусственный интеллект в военной сфере: угрозы и новая гонка вооружений. URL: <https://pircenter.org/editions/iskusstvennyj-intellekt-v-voennoj-sfere-ugrozy-i-novaja-gonka-vooruzhenij/>

² Указ Президента РФ от 10.10.2019 № 490 (ред. от 15.02.2024) «О развитии искусственного интеллекта в Российской Федерации». URL: <http://www.kremlin.ru/acts/bank/44731>

Выявленные противоречия и риски свидетельствуют о необходимости целенаправленного научного анализа данной проблемы. Требуется системный подход к интеграции ИИ в оборонные структуры, сочетающий технологические инновации с трансформацией организационной культуры, подготовкой персонала и разработкой адекватного нормативно-правового обеспечения. Решение этой задачи напрямую влияет на обороноспособность и военную безопасность страны.

Таким образом, постановка проблемы сводится к поиску ответов на вопрос: как оптимально внедрить технологии ИИ в систему обороны с учетом актуальных вызовов и ограничений? Дальнейшее исследование направлено на формулирование комплексного подхода к решению, что обусловлено насущной потребностью современной военно-научной практики.

Для успешного внедрения ИИ в организационные процессы военной деятельности требуются скоординированные усилия по нескольким направлениям. Ниже приведены рекомендации, опирающиеся на выявленные проблемы.

Совершенствование организационной структуры и управленческих практик

Адаптация структур управления вооруженными силами под задачи цифровизации и искусственного интеллекта возможна, если Управление развития технологий искусственного интеллекта Минобороны России будет наделено достаточными полномочиями для координации всех проектов обозначенной направленности в военной сфере, а при Генеральном штабе ВС РФ создана постоянная рабочая группа (или центр компетенций) по вопросам ИИ, интегрированная в систему планирования операций.

В войсках рекомендуется шире применять принцип смешанных групп принятия решений (человек и искусственный интеллект совокупно), постепенно повышая автоматизацию при сохранении контроля человека.

Для борьбы с институциональным консерватизмом важно внедрять в военные учебные программы курсы по основам ИИ и анализу данных для офицерского состава, проводить семинары и показательные учения, демонстрирующие преимущества интеллектуальных систем.

Командиры должны получать практический опыт совместной работы с инструментами ИИ для выработки к ним доверия.

Органы военного управления целесообразно реформировать, исходя из концепции сетецентрического администрирования: создать единые информа-

ционно-аналитические центры, куда будут поступать данные от различных систем наблюдения и разведки с последующей обработкой ИИ потока информации в реальном времени.

Кроме того, стоит пересмотреть доктринальные документы — включить положения об использовании систем искусственного интеллекта в Боевые уставы видов войск, наставления по видам вооруженных сил, что легитимизирует новые подходы.

Развитие кадрового потенциала и научно-образовательной базы

Необходимо реализовать целевую программу подготовки кадров для военного искусственного интеллекта. Она может включать расширение набора в военные вузы по IT-специальностям, отправку офицеров на стажировки и обучение в ведущие гражданские университеты и IT-компании (в рамках государственно-частного партнерства), создание на базе военных академий кафедр или лабораторий по искусственному интеллекту.

Следует привлекать молодых ученых в научные роты и центры Минобороны России, предоставляя им возможности заниматься исследованиями мирового уровня и поддерживать публикации в престижных журналах. Переход специалистов в оборонную отрасль можно стимулировать через специальные гранты Минобороны России на исследования в области ИИ, именные стипендии для студентов, выбравших тему искусственного интеллекта в военном применении, а также через популяризацию значимости этой работы для безопасности страны.

Важным аспектом является мультидисциплинарность: военные аналитики должны работать в тесной связке с программистами, математиками, инженерами. Для этого предлагается формировать смешанные исследовательские команды на базе технополиса ЭРА и профильных НИИ, куда бы входили как военные специалисты по тактике и оружию, так и гражданские эксперты по искусственному интеллекту. Такие команды, находясь в постоянном диалоге, смогут разрабатывать реально востребованные войсками интеллектуальные системы, учитывающие специфику применения³.

Совершенствование нормативно-правового обеспечения и стандартов

Необходимо разработать комплекс документов, регламентирующих военный ИИ. В кратчайшие

³ В технополисе «Эра» будут развивать технологии искусственного интеллекта в интересах ВС РФ. URL: <https://tass.ru/armiya-i-opk/14321799>



сроки следует подготовить и утвердить в установленном порядке Концепцию (доктрину) применения искусственного интеллекта в интересах обороны. Этот документ задал бы общие принципы, этические рамки и направления развития военного ИИ. Далее необходимо обновить ГОСТы и отраслевые стандарты по испытаниям, аккредитации и сертификации интеллектуальных систем военного назначения, чтобы обеспечить их надежность и безопасность.

Требуется правовое закрепление ответственности за решения, принимаемые ИИ: например, определить, в каких случаях итоговое решение должен одобрять оператор-человек. Кроме того, желательно участие России в международном диалоге по правилам использования военного ИИ, чтобы учитывать мировой опыт и продвигать национальные интересы (превентивное запрещение наиболее дестабилизирующих автономных систем оружия и т.п.). Следует создать постоянно действующий механизм пересмотра нормативов по мере развития технологий — например, экспертный совет при Минобороны России с участием юристов, технологов и военных, который бы ежегодно оценивал адекватность действующей нормативной базы новым реалиям.

Все эти меры повысят предсказуемость и законность процессов внедрения ИИ, снизят организационные риски и усилят доверие личного состава к новым системам.

Интеграция усилий государства, армии и бизнеса в развитии искусственного интеллекта

С учетом ограниченности ресурсов ВПК и обороны необходимо использовать потенциал гражданского ИТ-сектора. Расширение формата открытых конкурсов и хакатонов для разработчиков искусственного интеллекта под эгидой Минобороны России (по аналогии с имеющимися конкурсами в сфере безопасности) позволит привлечь в отрасль новые идеи и сильные ресурсы. Уже сейчас многие предприятия проявляют инициативу внедрить свои технологии в интересах обороны [1], но такую активность необходимо контролировать и координировать.

Предлагается создать единую коммуникационную платформу на базе технополиса ЭРА [2] (его деятельность осуществляется под эгидой Минобороны России) для взаимодействия военных заказчиков, научных организаций и компаний — разработчиков искусственного интеллекта. Через такую платформу можно размещать приоритетные задачи от ВС РФ, чтобы индустрия предлагала решения. Особое

внимание — поддержке малого инновационного бизнеса: запущенный с 2021 г. фонд инвестиций технополиса ЭРА уже финансирует перспективные разработки, и эту практику надо расширять⁴.

Кроме того, следует развивать государственно-частные партнерства: например, совместные лаборатории Минобороны России с ведущими ИТ-компаниями России по направлениям обработки изображений, обработки естественного языка для военных нужд, прогнозирования в логистике и пр. Такие альянсы помогут привлечь лучшие умы и технологии к оборонным проектам.

Развитие инфраструктуры данных и испытательных полигонов

Для обучения и тестирования военных систем ИИ следует организовать безопасные инфраструктуры⁵. Необходимо развернуть в контуре Минобороны собственные центры обработки данных с высокопроизводительными вычислителями, адаптированные для работы с секретными данными. Также нужно наладить процесс сбора и разметки данных из военной практики (результаты учений, архивы видеонаблюдения, телеметрия и пр.) в формах, пригодных для машинного обучения, при строгом обеспечении режима секретности.

Рекомендуется создание специального полигона для испытаний автономных и интеллектуальных систем — аналога американских тестовых площадок, где в контролируемых условиях можно было бы проверять работу боевых алгоритмов искусственного интеллекта, отрабатывая взаимодействие с операторами. Это позволит выявлять и устранять недостатки систем до их поступления в войска, что ускорит внедрение.

В дальнейшем целесообразно каждый новый образец вооружения или системы управления оценивать на предмет использования технологий ИИ и готовности к интеграции с единой информационной средой. Инфраструктурная готовность — фундамент для организационного успеха проекта внедрения соответствующих направлений [3, с. 108; 4, с. 117–119].

⁴ URL: https://www.tadviser.ru/index.php/%D0%9A%D0%BE%D0%BC%D0%BF%D0%B0%D0%BD%D0%B8%D1%8F:%D0%A2%D0%B5%D1%85%D0%BD%D0%BE%D0%BF%D0%BE%D0%B%D0%B8%D1%81_%D0%AD%D1%80%D0%B0_%D0%9C%D0%B8%D0%BD%D0%B8%D1%81%D1%82%D0%B5%D1%80%D1%81%D1%82%D0%B2%D0%B0_%D0%BE%D0%B1%D0%BE%D1%80%D0%BE%D0%BD%D1%8B

⁵ Реестр технологий ИИ позволяет формировать облик новых образцов вооружения. URL: https://vpk.name/news/902447_reestr_tehnologii_ii_pozvolyaet_formirovat_oblik_novyh_obrazcov_vooruzheniya.html

В целом, реализация предложенных мер должна строиться поэтапно и комплексно. На начальном этапе (ближайшие 1–2 года) — акцент на разработке нормативной базы и пилотных проектов в наиболее готовых нишах (например, аналитические системы ситуационного центра). Среднесрочно (3–5 лет) — масштабирование лучших практик на уровень всех видов вооруженных сил, полноценное включение модулей искусственного интеллекта в системы управления войсками, развертывание инфраструктуры данных. Долгосрочно (ближе к 2030 г.) — формирование адаптивной военной организации, в которой искусственный интеллект стал бы неотъемлемой частью большинства процессов (от боевого применения до административно-хозяйственных задач), при соблюдении необходимых мер безопасности и контроля.

ВЫВОДЫ

В работе предложены меры продвижения внедрения искусственного интеллекта в оборонные структуры. Ключевые направления реализации программы:

- реформирование организационной структуры управления войсками (под новые технологические возможности);
- интенсивное развитие кадрового потенциала (подготовка и привлечение специалистов по искусственному интеллекту);

- опережающее формирование нормативной базы;
- расширение взаимодействия армии с научно-промышленным сообществом.

Необходимо соблюдать баланс между инновациями и безопасностью: внедрение искусственного интеллекта должно сопровождаться механизмами контроля, испытаний и ответственности, исключая непреднамеренный ущерб. Следование правилам безопасности [5, с. 39] позволит минимизировать риски, связанные с военным искусственным интеллектом.

Для эффективного использования потенциала ИИ ВС РФ необходимо продолжить трансформацию организационных структур, процедур и нормативов. Реализация предложенных рекомендаций будет способствовать усилению обороноспособности государства, а благодаря своевременности внедрения ИИ российская военная организация перейдет на качественно новый уровень, отвечающий вызовам XXI в. В противном случае сохранится разрыв между техническими возможностями новых мощных инструментов обороны и их реальным воплощением в армии.

Таким образом, от того, насколько эффективно, прозрачно и своевременно будут решены организационные задачи, напрямую зависит успешность применения искусственного интеллекта в военной деятельности России.

СПИСОК ИСТОЧНИКОВ

1. Матюха С. В. Искусственный интеллект в беспилотных авиационных системах. *Транспортное дело России*. 2022;(1):8–11. DOI: 10.52375/20728689_2022_1_8
2. Батурин Ю. М. «Вина» искусственного интеллекта за «ошибку» и проблема ядерной военной безопасности в контексте юридической топики. *Правопорядок: история, теория, практика*. 2024;3(42):12–19. DOI: 10.47475/2311-696X-2024-42-3-12-19
3. Буренок В. М. Искусственный интеллект в военном противостоянии будущего. *Военная мысль*. 2021;(4):106–112. URL: <https://elibrary.ru/jzelgg>
4. Галкин Д. В., Коляндра П. А., Степанов А. В. Состояние и перспективы использования искусственного интеллекта в военном деле. *Военная мысль*. 2021;(1):113–124. URL: <https://www.elibrary.ru/qwuqyl>
5. Казеян Х. А., Арутюнян Г. Э. Проблемы применения искусственного интеллекта в военном управлении. *Управленческое консультирование*. 2023;(6):34–45. DOI: 10.22394/1726-1139-2023-6-34-45

REFERENCES

1. Matyukha S. V. Artificial intelligence in unmanned aircraft systems. *Russian transport business*. 2022;(1):8–11. (In Russ.). DOI: 10.52375/20728689_2022_1_8
2. Baturin Yu M. “Guilt” of artificial intelligence for “error” and the problem of nuclear military security in the context of legal topics. *Legal and Order: History, Theory, Practice*. 2024;(3):12–19. (In Russ.). DOI: 10.47475/2311-696X-2024-42-3-12-19
3. Burenok V. M. Artificial intelligence in the military confrontation of the future. *Military thought*. 2021;(4):106–112. URL: <https://elibrary.ru/jzelgg> (In Russ.).
4. Galkin D. V., Kolyandra P. A., Stepanov A. V. The state and prospects of using artificial intelligence in military affairs. *Military thought*. 2021;(1):113–124. URL: <https://www.elibrary.ru/qwuqyl> (In Russ.).

5. Kazeyan Kh.A., Arutyunyan G.E., Ghazeyan Kh.A., Harutyunyan G.E. The Problems of Using Artificial Intelligence in Military Management. *Administrative Consulting*. 2023;(6):34–45. (In Russ.). DOI: 10.22394/1726-1139-2023-6-34-45

ИНФОРМАЦИЯ ОБ АВТОРЕ / ABOUT THE AUTHOR

Анна Николаевна Когтева — кандидат экономических наук, доцент кафедры информационной безопасности факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Anna N. Kogteva — Cand. Sci. (Econ.), Assoc. Prof., Department of Information Security, Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0001-8109-9900>

ANKogteva@fa.ru

Конфликт интересов: автор заявляет об отсутствии конфликта интересов.

Conflicts of interest Statement: The author has no conflicts of interest to declare.

Статья поступила 22.05.2025; принята к публикации 02.06.2025.

Автор прочитала и одобрила окончательный вариант рукописи.

The article was received on 22.05.2025; accepted for publication on 02.06.2025.

The author read and approved the final version of the manuscript.

УДК 004.8(045)

Эволюция искусственного интеллекта: от современных технологий к будущим инновациям

Е.А. Сальников, С.Р. Муминова

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

Статья посвящена изучению особенностей и перспектив развития искусственного интеллекта (ИИ) в современном мире. Проведен анализ основных тенденций, выявлены ключевые вызовы и предложены меры по управлению воздействием ИИ на экономику, общество и государственную политику. Рассматриваются вопросы образования, безопасности, экологии и регуляторной политики, необходимые для полноценного освоения и безопасного использования ИИ-технологий. Особое внимание уделено вопросам подготовки кадров, энергетической эффективности, безопасности данных и этическим стандартам использования технологий. Сделан вывод о необходимости формирования комплексной междисциплинарной стратегии, интегрирующей интересы бизнеса, науки и общества, для эффективного освоения потенциала ИИ и минимизации сопутствующих рисков.

Ключевые слова: искусственный интеллект; машинное обучение; устойчивое развитие; глубокое обучение; цифровая экономика; подготовка персонала; информационная безопасность; большие данные; нормативные стандарты; государственная политика

Для цитирования: Сальников Е.А., Муминова С.Р. Эволюция искусственного интеллекта: от современных технологий к будущим инновациям. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(2):64-71.

ORIGINAL PAPER

Evolution of Artificial Intelligence: from State-of-Art to Future Innovations

E.A. Salnikov, S.R. Muminova

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

ABSTRACT

The paper studies the features and prospects of artificial intelligence (AI) development. The authors made an analysis of the trends and challenges in this area and proposed the measures aimed at controlling AI impact on economy, society and state policy. The investigators also consider the issues of education, safety, ecology and regulatory policy that are necessary for full and safe implementation of AI-based technologies. Much attention is given to staff training, energy efficiency, data safety and ethical standards to use technologies. The research result has conclusion: it is necessary to design a complex interdisciplinary strategy which could integrate the interests of business, science and society to use efficiently AI and minimize possible risks.

Keywords: artificial intelligence; machine learning; sustainable development; deep learning; digital economy; staff training; information security; big data; regulatory standards; state policy

For citation: Salnikov E.A., Muminova S.R. Evolution of artificial intelligence: From State-of-Art to future innovations. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(2):64-71.



ВВЕДЕНИЕ

Искусственный интеллект (ИИ) за последние десятилетия превратился из узкоспециализированной области компьютерных наук в одну из ключевых технологических парадигм XXI в., трансформируя экономику, науку и повседневную жизнь. Его эволюция демонстрирует стремительный переход от простых алгоритмов логического вывода к сложным самообучающимся системам, способным решать задачи, ранее считавшиеся исключительной прерогативой человека. Сегодня ИИ лежит в основе множества инноваций — от персональных голосовых помощников до автономного транспорта, от медицинской диагностики до генерации креативного контента. Однако стремительное развитие технологий порождает не только новые возможности, но и фундаментальные вопросы, связанные с этикой, безопасностью и долгосрочными последствиями его интеграции в общество.

Исследование современного состояния ИИ, его тенденций и потенциальных последствий представляет особую важность для государственных структур [1], научного сообщества и бизнеса. Современный этап технологического развития характеризуется стремительной эволюцией искусственного интеллекта, который трансформирует как бизнес-процессы, так и научную деятельность. По данным последнего исследования McKinsey (2025), за последние три года проникновение ИИ-технологий в корпоративный сектор увеличилось в 2,5 раза, достигнув 78% среди компаний с годовым оборотом свыше 100 млн долл. Параллельно, как свидетельствует отчет Европейского исследовательского совета, в научной сфере наблюдается рост использования ИИ на 26% в год, причем особенно заметно это в междисциплинарных исследованиях¹.

ГЛАВНЫЕ ТЕХНОЛОГИЧЕСКИЕ ТРЕНДЫ

Современный этап развития искусственного интеллекта характеризуется стремительной трансформацией технологического ландшафта, где доминируют два взаимосвязанных направления: массовое внедрение крупных языковых моделей (LLM) и активное развитие экосистемы открытых платформ ИИ. Эти тенденции не только определяют текущие исследовательские приоритеты, но и формируют новую парадигму взаимодействия

между разработчиками, бизнесом и конечными пользователями. Широкое распространение LLM, таких как GPT, Claude и Gemini, свидетельствует о переходе от узкоспециализированных решений к универсальным системам, способным обрабатывать многомодальные данные и адаптироваться к разнообразным задачам. Параллельно наблюдается рост значимости открытых платформ (Hugging Face, TensorFlow Hub, OpenAI API), ускоряющих инновационные процессы за счет демократизации доступа к передовым моделям и инструментам. Эти два вектора развития создают синергетический эффект: LLM становятся базовым слоем для прикладных решений, а открытые экосистемы снижают барьеры для их коммерциализации и дальнейшего совершенствования.

Таким образом современные тенденции демонстрируют два ключевых направления развития ИИ: широкое внедрение и тиражирование крупных языковых моделей (LLM) и растущую значимость открытых платформ.

Развитие крупных языковых моделей (LLM)

Крупные языковые модели стали доминирующим инструментом ИИ. Модели наподобие *GPT-4* от OpenAI и *LaMDA* от Google продемонстрировали невероятные способности в обработке естественного языка, составлении текстов, программировании и даже выполнении научных расчетов. Количество параметров в таких моделях достигает сотен миллиардов, что резко увеличивает сложность их обучения и эксплуатационные расходы. Особенностью крупных языковых моделей является их универсальность: они способны применяться для широкого спектра задач — от юридического консультирования до аналитики рынков и научных исследований [2]. Компания Meta представила модель LLaMA, доступную для коммерческого использования и привлекательную для исследователей и предпринимателей своими преимуществами открытой лицензии.

Платформы открытого ПО vs закрытые решения

Выбор между использованием готовых коммерческих продуктов и разработкой собственного ИИ-программного обеспечения становится для компаний стратегически важным решением. Закрытые платформы обладают рядом преимуществ, таких как высокая надежность и доступность специализированных инструментов, но связаны с ограничениями свободы действий и зависимостью от поставщика услуг. Напротив, платформа Hugging Face предлагает открытый доступ к боль-

¹ McKinsey & Company. The state of AI: How organizations are rewiring to capture value. 1491 respondents across 101 countries. 2025. URL: https://www.mckinsey.com/~media/mckinsey/business%20functions/quantumblack/our%20insights/the%20state%20of%20ai/2025/the-state-of-ai-how-organizations-are-rewiring-to-capture-value_final.pdf

шому количеству предварительно натренированных моделей, позволяя бизнесу адаптировать решения под специфику своей деятельности. Этот подход снижает барьер входа и стимулирует развитие уникальных инновационных проектов, предлагая свободу выбора методов и подходов.

ЭВОЛЮЦИЯ ПРИЛОЖЕНИЙ ИИ

За последнее десятилетие область применения искусственного интеллекта прошла впечатляющий путь эволюции, превратившись из простых экспериментальных прототипов в зрелые прикладные системы, используемые повсеместно в бизнесе, науке, медицине и даже туризме [3]. Изначально применение ИИ было ограничено узкими специализированными областями, такими как обработка сигналов и изображений, решение инженерных задач или распознавание рукописного ввода. Сегодня ИИ проникает практически во все сферы человеческой деятельности, выполняя широкий спектр функций — от предоставления рекомендаций пользователям интернета до автоматизации промышленного производства и оказания медицинских услуг. Главной движущей силой эволюции приложений ИИ стала экспоненциальная динамика развития технологий, связанная с совершенствованием вычислительных мощностей, увеличением объемов доступной информации и появлением мощных моделей глубокого обучения. Более доступные вычислительные ресурсы и обширные наборы данных позволили ученым и инженерам строить все более сложные и эффективные системы, способные решать задачи, ранее считавшиеся неразрешимыми или трудными для автоматизации.

Автоматизация и персонализация

Широко внедряются автоматизированные решения на основе ИИ, призванные упростить рутинные операции и увеличить продуктивность труда. Чат-ассистенты и ИИ-автоботы помогают организациям оптимизировать рабочие процессы, сокращая административные нагрузки и уменьшая число ошибок [4]. Особенно важны такие технологии в сфере обслуживания клиентов, продаж и маркетинга. Например, крупнейший российский ритейлер Wildberries применил систему рекомендаций на основе ИИ, что повысило конверсию покупок и увеличило лояльность покупателей. Аналогично, российские банки начали внедрять ИИ для автоматического выявления случаев мошенничества и оптимизации кредитных операций.

Гибридные архитектуры ИИ

Динамичное развитие привело к возникновению концепции «нейросимволического ИИ» (Neuro-symbolic AI), объединившей преимущества традиционных искусственных нейронных сетей и символического представления знаний [5]. Эта архитектура позволяет моделировать абстрактные понятия и проводить глубокие рассуждения, приближая модели к человеческому типу мышления. Пример успешной гибридной модели — AlphaCode от DeepMind, способной писать программный код высокого качества, сопоставимый с уровнем профессиональных программистов. Подобная интеграция подходов помогает преодолеть ограничения отдельных методик и достичь качественно нового уровня производительности.

Одним из центральных вопросов является масштабируемость моделей ИИ. В последние годы наблюдается тенденция к увеличению количества параметров в моделях: от десятков миллиардов до триллионов. Такие модели требуют огромных ресурсов для обучения и эксплуатации, что делает их дорогостоящими и сложнодоступными для небольших предприятий. Решение данной проблемы — компактные специализированные модели, ориентированные на выполнение узких задач и работающие локально на устройствах конечного пользователя. Так, уже упомянутая ранее модель LLaMA представляет собой компромисс между производительностью и экономичностью. При этом она обладает высокой точностью при меньших затратах на эксплуатацию, предоставляя организациям бюджетные варианты внедрения ИИ.

Интерфейсы следующего поколения

Применение ИИ радикально изменяет привычные формы взаимодействия с компьютерами. Голосовые ассистенты, такие как Siri, Alexa и отечественные разработки Алиса от Яндекса и Салют от Сбера, уже незаменимы в повседневной жизни, открывая пользователям удобные и интуитивные способы общения с технологиями. Новые устройства, управляемые исключительно голосом, развиваются параллельно с появлением смарт-дисплеев и сенсоров, встроенных в бытовые приборы, автомобили и офисные пространства. Все это обещает кардинальные перемены в образе жизни населения и изменении трудовых обязанностей.

ОРГАНИЗАЦИОННЫЕ ТРАНСФОРМАЦИИ В ЭПОХУ ИИ

Последние данные McKinsey рисуют картину масштабной перестройки корпоративных структур



под влиянием ИИ. Интересно отметить, что компании, где внедрением ИИ руководит непосредственно CEO (28% случаев), демонстрируют на 20% более высокие показатели EBIT по сравнению с теми, где эти функции делегированы техническим специалистам. Это подтверждает тезис о том, что успешная цифровая трансформация требует не просто технологических изменений, но и пересмотра всей системы управления. Ярким примером может служить опыт ведущих технологических компаний (Google, Microsoft), которые уже в 2024 г. создали специальные должности Chief AI Officers, подотчетные непосредственно советам директоров. В традиционных отраслях, таких как финансы или здравоохранение, процесс идет медленнее, но и там отмечается рост числа специализированных ИИ-подразделений. Особенно показательное сравнение между крупными (оборот > 500 млн долл.) и небольшими компаниями. Если первые в 65% случаев уже внедрили комплексные системы управления ИИ-рисками, то среди вторых этот показатель не превышает 32%. Это различие особенно заметно в таких аспектах, как:

- централизация управления данными (57% vs 29%);
- наличие этических руководств по ИИ (48% vs 21%);
- системы мониторинга качества ИИ-решений (39% vs 15%).

НАУЧНАЯ РЕВОЛЮЦИЯ: ИИ КАК ИНСТРУМЕНТ ПОЗНАНИЯ

В научной сфере внедрение ИИ имеет свою специфику. В отличие от бизнеса, где основной акцент делается на эффективности и ROI, в науке на первый план выходят вопросы методологии и воспроизводимости результатов. Любопытно, что степень проникновения ИИ значительно варьируется по дисциплинам. В физических науках и инженерии ИИ используют 50% исследователей, в то время как в социальных науках — лишь 25%. Генеративный ИИ вызывает особый интерес в академической среде. Если в 2022 г. только 5% ученых признавались в его использовании, то к 2024 г. этот показатель вырос до 38%. Примечательно, что 85% исследователей применяют его для рутинных задач (литературные обзоры, оформление результатов), но лишь 13% — для генерации гипотез. Это контрастирует с корпоративным сектором, где генеративный ИИ активно используется для креативных задач (дизайн, копирайтинг).

СРАВНИТЕЛЬНЫЙ АНАЛИЗ: УРОКИ ДЛЯ ОБЕИХ СФЕР

Проводя параллели между корпоративным и академическим опытом, можно выделить несколько важных закономерностей:

- *управленческие модели*: в то время как бизнес стремится к централизации ИИ-компетенций (57% создают центры передового опыта), наука сохраняет децентрализованную структуру, что в некоторых случаях приводит к дублированию усилий;
- *этические стандарты*: 93% ученых считают необходимым создание специальных этических норм для ИИ, тогда как в бизнесе этот показатель составляет 69%. Однако корпоративный сектор демонстрирует более быстрый прогресс в практической реализации этических принципов;
- *кадровая политика*: научные учреждения значительно отстают в вопросах переподготовки кадров. Если 44% компаний уже проводят программы рескиллинга, то среди университетов таких лишь 18%.

ПРОБЛЕМЫ И ВЫЗОВЫ

В области развития технологий ИИ основные проблемы, идентифицированные в корпоративном и академическом секторах, включают:

- проблему «черного ящика» (отмечают 71% респондентов);
- риски смещения данных (68%);
- нехватку квалифицированных кадров (55%).

При этом прогнозы развития различаются. Бизнес ожидает значительного роста производительности (до 40% к 2027 г. по оценкам McKinsey), тогда как научное сообщество настроено более сдержанно, делая акцент на методологических рисках. Особый интерес представляет развитие агентного ИИ (autonomous AI), который по прогнозам к 2030 г. сможет самостоятельно проводить определенные виды исследований. Пилотные проекты уже запущены в нескольких фармацевтических компаниях и исследовательских центрах.

Несмотря на многочисленные положительные моменты, развитие ИИ связано с существенными проблемами и вызовами.

Безопасность и защита данных

Одна из главных проблем связана с обеспечением безопасности данных и защитой частной жизни. Большие языковые модели собирают огромное количество информации, часто содержащей персональные данные пользователей. Поэтому крайне важен правильный подход к защите лич-

ной информации и созданию надежных механизмов контроля доступа. Европейские регуляторы приняли Закон об искусственном интеллекте (Artificial Intelligence Act) [6], целью которого является установление жесткого контроля за использованием ИИ и наказаний за нарушения этических норм. Российская Федерация работает над аналогичной инициативой, предусматривающей меры по контролю качества и ответственности разработчиков ИИ-продуктов [7].

Предвзятость и справедливость

Модели ИИ подвержены предвзятости, возникающей вследствие недостаточной репрезентативности данных или некорректной настройки алгоритмов. Недавнее исследование показало, что большинство крупных языковых моделей проявляют расовую и половую дискриминацию, негативно влияя на принимаемые решения. Устранить данную проблему позволяют усиленный мониторинг данных и систематическое исправление ошибок. Обучение сотрудников, занимающихся созданием и поддержкой ИИ, необходимым методикам проверки и коррекции алгоритмов приобретает первостепенное значение.

Энергопотребление и экология

Для создания и эксплуатации крупных языковых моделей требуется огромное количество энергии, что усиливает нагрузку на окружающую среду. Углеродный след крупных центров обработки данных, необходимых для тренировки ИИ, увеличивается ежегодно, поэтому необходимо искать пути снижения энергопотребления. Варианты решения проблемы: повышение энергоэффективности оборудования и переход на возобновляемые источники энергии. А развитие низкоуглеродистых подходов к обучению и эксплуатации моделей ИИ позволит снизить их негативное воздействие на окружающую среду.

Нормативно-правовая среда и этические вопросы

По мере распространения ИИ возникают серьезные вопросы этического характера и ответственности. Появляются опасения по поводу защиты персональных данных, возможных нарушений права на частную жизнь и соблюдения моральных принципов. Одним из важных шагов в регулировании этих вопросов стало введение нормативных актов в ряде стран, направленных на предотвращение злоупотреблений ИИ. Например, Европейский союз разработал Закон об искусственном интеллекте (Artificial Intelligence Act) [6],

устанавливающий рамки допустимых способов использования ИИ и ответственность разработчиков и операторов. Тем не менее остаются нерешенными вопросы глобального сотрудничества в сфере регулирования ИИ. Международные соглашения необходимы для формирования единых правил игры, способствующих ответственному развитию и применению ИИ-технологий.

КОНКУРЕНЦИЯ СРЕДИ ГОСУДАРСТВ

Конкуренция между государствами усиливается по мере увеличения значения ИИ. Ведущими игроками в этой гонке выступают США, Китай, Россия и страны Евросоюза.

США продолжают удерживать первенство в области фундаментальных исследований и высоких технологий, будучи лидером по числу публикаций и патентов в сфере ИИ. Страна располагает мощными исследовательскими центрами и финансирует инновационные проекты, привлекая талантливых ученых со всего мира.

Китай активно развивает национальную программу «Новая ступень развития искусственного интеллекта», направляя миллиарды долларов на продвижение отечественных разработок. Успехи китайских компаний, таких как SenseTime и Megvii, свидетельствуют о высоком уровне технического прогресса в области компьютерного зрения и биометрии.

Российская Федерация предпринимает попытки усилить свое присутствие в мире ИИ. Так, в период 01.10.2018–31.12.2024 гг. Минцифры России инициировало запуск и курировало этапы реализации национальной программы «Цифровая экономика»² по развитию искусственного интеллекта и роботизации производства. Россия планомерно добивается успехов, несмотря на сложности экономического положения, продолжает укреплять позиции в области военной робототехники и беспилотных систем, продвигая собственную концепцию «цифрового суверенитета», основанную на локализации данных и контроле над информационными потоками внутри страны.

Евросоюз реализует Стратегию цифрового лидерства (International Digital Strategy)³, предусматривающую увеличение инвестиций в ИИ и цифровую

² «Цифровая экономика Российской Федерации» — национальный проект реализовывался в России с 2019 по 2024 г. Национальная программа завершена 31 декабря 2024 г. С 2025 г. реализуется национальный проект «Экономика данных и цифровая трансформация государства».

³ URL: https://ec.europa.eu/commission/presscorner/detail/en/ip_25_1370



инфраструктуру. Одной из приоритетных целей является создание европейской экосистемы ИИ, независимой от американских и китайских гигантов.

БУДУЩИЕ СЦЕНАРИИ И ПРОГНОЗЫ

Проведенный анализ демонстрирует, что, несмотря на различия в подходах, и корпоративный, и академический сектора сталкиваются с идентичными вызовами при внедрении ИИ. Опыт бизнеса в области управления и масштабирования ИИ-решений может быть полезен научным учреждениям, в то время как академический подход к этике и методологии заслуживает внимания со стороны корпораций [9].

Можно предположить, что на ближайшие годы ключевыми направлениями развития ИИ станут:

- 1) разработка междисциплинарных стандартов для ИИ;
- 2) создание гибридных (человеко-машинных) систем управления;
- 3) развитие нормативной базы для генеративного ИИ.

Как показывает практика, организации, которые уже сегодня инвестируют в эти направления, формируют значительное конкурентное преимущество на перспективу 5–10 лет.

Эксперты предсказывают усиление роли ИИ в ближайшие десятилетия. Можно ожидать появления новых типов ИИ-решений, предназначенных для интеграции в производственную цепочку, логистику, транспортировку и другие области промышленности. Согласно оценкам экспертов, дальнейшие шаги будут направлены на углубленное применение ИИ в повседневных процессах. Ожидается дальнейшее расширение возможностей голосового управления устройствами, массовое внедрение умных домов и автомобилей, работающих на основе ИИ.

Основные технологические тренды:

- рост числа специализированных микросхем для ИИ (аналогов графических процессоров и чипов типа Tensor Processing Units);
- увеличение роли квантовых вычислений в обучении ИИ-модели;
- повышенное внимание к вопросам устойчивого развития и экологичности стимулирует появление энергоэффективных моделей и архитектур.

Прогресс в бионике и медицинской инженерии откроет двери для революционных прорывов в лечении болезней и продлении жизни. Благодаря возможностям глубокого обучения врачи смогут быстрее ставить точные диагнозы, назначать лечение и улучшать качество ухода за пациентами.

Среди ожидаемых сценариев развития можно выделить:

- дальнейшее проникновение ИИ в повседневную жизнь и образование;
- расширение роли голосовых ассистентов и диалоговых агентов;
- переход к повсеместному внедрению автономизируемых автомобилей и беспилотных дронов;
- усиление конкуренции за кадры и международные рынки ИИ.

ВЫВОДЫ

Сложившаяся ситуация свидетельствует о глубоком преобразовании экономики и социальных отношений под влиянием ИИ. Проведенный анализ современных тенденций и перспектив развития ИИ подтверждает наличие глубоких и необратимых изменений в экономических системах, социальной структуре и институциональных механизмах функционирования общества [8]. Динамика и масштабы этих изменений ставят перед государством, бизнесом и научным сообществом важнейшую задачу по формированию комплексной стратегии реагирования и управления процессом. Очевидно, что полноценное освоение возможностей ИИ невозможно вне комплексного междисциплинарного подхода, предполагающего тесное взаимодействие государственных органов, частных секторов и научных учреждений. Этот подход подразумевает реализацию стратегических мер, охватывающих сразу несколько уровней:

1) *ускоренную подготовку кадров*. Освоение новых цифровых компетенций становится одним из факторов повышения конкурентоспособности как на национальном, так и на глобальном уровнях. Образовательные учреждения должны пересмотреть учебные планы, включить курсы по основам искусственного интеллекта и готовить специалистов, обладающих необходимыми знаниями и навыками;

2) *повышение киберустойчивости и информационной безопасности*. Масштабное внедрение ИИ сопровождается возрастающими рисками несанкционированного вмешательства, утечки данных и недобросовестного использования технологий. Важно создать нормативно-правовую базу, регламентирующую работу с персональными данными и этичное использование ИИ;

3) *формирование эффективных регуляторных механизмов*. Интеграция искусственного интеллекта в государственное управление, медицинскую практику, финансовую сферу и другие чувствительные

области требует тщательного правового регулирования. Здесь необходима реализация комплекса мер: мониторинг качества решений, устранение предубежденности и создание систем быстрого реагирования на возникающие кризисные ситуации;

4) *экологичность и ресурсосбережение*. Быстрое развитие технологий ИИ приводит к значительным энергозатратам и негативному воздействию на окружающую среду. Совершенствование аппаратного обеспечения, переход на возобновляемую энергетику и разработка энергоэкономичных алгоритмов должны стать обязательными элементами общей стратегии [9];

5) *научно-техническое партнерство*. Межгосударственное сотрудничество, обмен информацией и совместные исследования позволят странам

консолидировать опыт и объединить усилия для ускорения инновационного развития. Мультидисциплинарные исследования и трансфер технологий окажут положительное воздействие на развитие ИИ как общечеловеческой ценности.

Все вышесказанное указывает на необходимость разумного и взвешенного подхода к внедрению искусственного интеллекта, который способен обеспечить инновационное развитие бизнеса за счет повышения его конкурентоспособности для обеспечения его устойчивого развития [10]. Эффективное управление данным процессом требует всестороннего анализа имеющихся рисков и возможностей, создания надежных регуляторных механизмов и постоянного мониторинга динамики развития ИИ-технологий.

СПИСОК ИСТОЧНИКОВ

1. Муминова С.Р. Технологии искусственного интеллекта как инструмент государственного управления в туризме. *Среднерусский вестник общественных наук*. 2022;17(5):172–182. DOI: 10.22394/2071-2367-2022-17-5-172-182
2. Скворцова Н.А., Булатов И.И. Интеграция LLM в процессы разработки новых продуктов и инноваций. *Экономика устойчивого развития*. 2024;3(59):277–280. URL: <https://elibrary.ru/tfthbs>
3. Муминова С.Р., Томашевская Н.Г. Искусственный интеллект как основа инновационного управления в туризме. *Сервис в России и за рубежом*. 2022;16(2):94–100. DOI: 10.24412/1995-042X-2022-2-94-100
4. Малекова В.А., Романова Е.В. Перспективы использования чат-ботов в HR-секторе. *Сервис в России и за рубежом*. 2023;17(103):180–191. DOI: 10.5281/zenodo.7810955
5. Chandre P., Mahalle P., Shinde G., et al. Neuro-Symbolic AI: A Future of Tomorrow. *ASEAN Journal on Science and Technology for Development*. 2025;42(2). DOI: 10.61931/2224-9028.1620
6. Subotić I. Implications of EU's artificial intelligence Act. *Znanstvena Misel*. 2024;86(86):7–13. DOI: 10.5281/zenodo.10575768
7. Саяпина Т.С. Некоторые проблемы интерпретации и правового регулирования искусственного интеллекта в России. *Имущественные отношения в Российской Федерации*. 2023;2(257):101–110. DOI: 10.24412/2072-4098-2023-2257-101-110
8. Scott A.C., Solórzano J.R., Moyer J.D., Hughes B.B. The Future of Artificial Intelligence. *International Journal of Artificial Intelligence and Machine Learning*. 2022;2(1):1. DOI: 10.51483/ijaiml.2.1.2022.1-37.
9. Nahar Sh. Modeling the effects of artificial intelligence (AI)-based innovation on sustainable development goals (SDGs): Applying a system dynamics perspective in a cross-country setting. *Technological Forecasting and Social Change*. 2024;201:123203. DOI: 10.1016/j.techfore.2023.123203
10. Морозова И.А., Сметанин А.С., Сметанина А.И. Управление конкурентоспособностью бизнеса на основе искусственного интеллекта и больших данных для его устойчивого развития. *Современная конкуренция*. 2024;18(97):29–40. DOI: 10.37791/2687-0657-2024-18-1-29-40

REFERENCES

1. Muminova S.R. Artificial intelligence as a tool for public management in tourism. *Central Russian Journal of Social Sciences*. 2022;17(5):172–182. (In Russ.). DOI: 10.22394/2071-2367-2022-17-5-172-182
2. Skvortsova N.A., Bulatov I.I. Integrating LLM into new product development and innovation processes. *Economics of Sustainable Development*. 2024;3(59):277–280. URL: <https://elibrary.ru/tfthbs> (In Russ.).
3. Muminova S.R., Tomashevskaya N.G. Artificial intelligence as a basis for innovation management in tourism. *Services in Russia and Abroad*. 2022;16(2):94–100. (In Russ.). DOI: 10.24412/1995-042X-2022-2-94-100
4. Malekova V.A., Romanova E.V. Prospects for the use of chatbots in the HR sector. *Service in Russia and Abroad*. 2023;17(103):180–191. (In Russ.). DOI: 10.5281/zenodo.7810955
5. Chandre P., Mahalle P., Shinde G., et al. Neuro-Symbolic AI: A Future of Tomorrow. *ASEAN Journal on Science and Technology for Development*. 2025;42(2). DOI: 10.61931/2224-9028.1620



6. Subotić I. Implications of EU's artificial intelligence Act. *Znanstvena Misel*. 2024;86(86):7–13. DOI: 10.5281/zenodo.10575768
7. Sayapina T. S. Some problems of interpretation and legal regulation of artificial intelligence in Russia. *Property Relationships in Russian Federation*. 2023;2(257):101–110. (In Russ.). DOI: 10.24412/2072-4098-2023-2257-101-110
8. Scott A. C., Solórzano J. R., Moyer J. D., Hughes B. B. The Future of Artificial Intelligence. *International Journal of Artificial Intelligence and Machine Learning*. 2022;2(1):1. DOI: 10.51483/ijaiml.2.1.2022.1–37
9. Nahar Sh. Modeling the effects of artificial intelligence (AI)-based innovation on sustainable development goals (SDGs): Applying a system dynamics perspective in a cross-country setting. *Technological Forecasting and Social Change*. 2024;201:123203. DOI: 10.1016/j.techfore.2023.123203
10. Morozova I. A., Smetanin A. S., Smetanina A. I. Management of business competitiveness based on artificial intelligence and big data for its sustainable development. *Modern Competition*. 2024;18(97):29–40. (In Russ.). DOI: 10.37791/2687-0657-2024-18-1-29-40

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Евгений Анатольевич Сальников — кандидат экономических наук кафедры бизнес-информатики факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Evgeny A. Salnikov — Cand. Sci (Econ.), Department of Business Informatics, Faculty of Information Technologies and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0009-0000-6457-0190>

Автор для корреспонденции / Corresponding author:
easalnikov@fa.ru

Светлана Рашидовна Муминова — кандидат технических наук кафедры математики и анализа данных факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Svetlana R. Muminova — Cand. Sci (Eng.), Department of Mathematics and Data Analysis, Faculty of Information Technologies and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0001-5236-607X>
srmuminova@fa.ru

Заявленный вклад авторов:

Е.А. Сальников — написание всех разделов статьи, за исключением раздела «Эволюция применений ИИ».

С.Р. Муминова — написание раздела «Эволюция применений ИИ», перевод, оформление.

Authors' declared contributions:

E. A. Salnikov — writing all sections of the article, except for the section “Evolution of AI applications”.

S. R. Muminova — writing section “Evolution of AI applications”, translation into English, formatting.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Conflicts of Interest Statement: The authors have no conflicts of interest to declare.

Статья поступила 29.05.2025; принята к публикации 09.06.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was received 29.05.2025; accepted for publication 09.06.2025.

The authors read and approved the final version of the manuscript.

УДК 336.761.8:336.763.3(045)

Самостоятельное управление пенсионными накоплениями

А.И. Богомолов

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

Развитие сервисов Единой централизованной платформы (ЕЦП) в социальной сфере России движется в направлении увеличения участия пенсионеров и самозанятых в управлении своими накоплениями, как это делается в ряде зарубежных стран. В статье рассматриваются возможности и условия создания сообщества участников пенсионного фонда на базе ЕЦП для коллективного инвестирования с целью оптимизации дополнительного дохода и уменьшения риска. Опираясь на опыт зарубежных стран, предлагается на базе ЕЦП, главным оператором которой является Пенсионный фонд, создать ряд сервисов, позволяющих пенсионерам и самозанятым использовать свои накопления с целью их инвестирования и получения дополнительного дохода. Предлагаемые в статье методы основываются на видах использования пенсионных накоплений, состоянии и возможностях ЕЦП с последующим формированием математической модели. Обоснование предлагаемого подхода — возможность предоставления налоговых льгот для граждан, делающих накопления на пенсию. Например, взносы в пенсионный фонд могут быть частично или полностью освобождены от налогообложения, а доходы от инвестиций — облагаться по сниженной ставке. Это делает пенсионные накопления более выгодными по сравнению с банковскими вкладами. Чтобы граждане, желающие инвестировать в различные фонды и проекты, получили дополнительные возможности, предлагается создать обучающие сервисы, позволяющие ознакомиться с рынком и оценивать возможные риски. Пенсионные фонды через ЕЦП могут способствовать созданию инвестиционных сообществ, где граждане с общими интересами или целями могут объединять свои средства для формирования общего портфеля. Коллективный подход позволит диверсифицировать риски и увеличить доходность. Предлагается алгоритм создания объединенного инвестиционного портфеля из портфелей Марковица участников (пенсионеров или самозанятых) для снижения рисков инвестирования и оптимизации доходов.

Ключевые слова: пенсионный фонд; управление; пенсионные накопления; инвестиции; сервисы; цифровая платформа

Для цитирования: Богомолов А.И. Самостоятельное управление пенсионными накоплениями. Цифровые решения и технологии искусственного интеллекта. 2025;1(2):72-80.

ORIGINAL PAPER

Self-Managed Pension Savings

A.I. Bogomolov

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

ABSTRACT

Introduction. The development of services within Russia's Unified Centralized Platform (UCP) in the social sector will focus on increasing the participation of retirees and self-employed individuals in managing their savings, as is done in several foreign countries. The possibility and conditions for creating a community of Pension Fund participants on the UCP platform are being studied with the aim of creating a community of collective investments to optimize additional income and reduce risks. **Objective.** Based on international experience, it is proposed to develop a set of services on the Unified Centralized Platform of Russia in the social sphere, managed primarily by the Pension Fund, which will allow pensioners and self-employed citizens to invest their savings and receive additional income. **Methods.** The methodology was based on analyzing foreign practices and methods of using pension savings, an assessment of the possibilities of the UCP and the subsequent development of a mathematical model. The rationale for this approach is to potentially provide tax benefits to individuals who save for retirement. For instance, contributions to the pension fund could be partially or fully tax-exempt, while investment income could be taxed at a reduced rate. This makes pension savings more profitable compared to bank deposits. To facilitate investments in various funds, services are offered access to educational resources to help potential investors better understand the market, assess risks, and make informed investment decisions. **Conclusions.** It is proposed that pension funds, through the UCP, promote the creation of investment communities where citizens with common

interests or goals can pool their resources to form a collective portfolio. This would diversify risks and increase profitability through a collaborative approach. For example, a community could invest in large-scale projects typically inaccessible to individual investors. **Results.** An algorithm is proposed for creating a consolidated investment portfolio based on the Markowitz portfolios of participants (retirees or self-employed individuals) to reduce investment risks and optimize returns. **Keywords:** pension fund; management; pension savings; investments; services; digital platform

For citation: Bogomolov A.I. Self-managed pension savings. *Humanities and Social Sciences. Bulletin of the Financial University.* 2025;1(2):72-80.

ВВЕДЕНИЕ

В современном мире все больше людей задумываются о своем финансовом благополучии в пожилом возрасте задолго до выхода на пенсию. Они не хотят полагаться исключительно на выплаты государственной пенсионной системы или банковские вклады, а стремятся самостоятельно управлять своими накоплениями, инвестируя их в различные активы, в том числе и на фондовом рынке, для получения прибыли. Более того, такие граждане начинают объединяться в сообщества, чтобы снизить риски и оптимизировать доходность своих инвестиций.

Пенсионный фонд России (ПФР) может стать надежным партнером для таких инициативных граждан и предложить им по сравнению с традиционными банковскими услугами новые преимущества и возможности. Учитывая роль фондового рынка в национальной экономике, объединение инвесторов на базе Единой централизованной платформы (ЕЦП) в социальной сфере, оператором которой является Пенсионный фонд России, может стать существенным фактором национальной экономики.

Значение фондового рынка для национальной экономики

Фондовый рынок играет важную роль в развитии национальной экономики. Он способствует привлечению свободных средств в виде инвестиций для развития производства, перемещению капитала из «затухающих» отраслей в быстро прогрессирующие, а также изысканию средств для покрытия дефицита федерального и местного бюджетов. В последнее время роль фондового рынка значительно возросла, и он стал ключевым элементом системы финансовых рынков. В финансовых инструментах воплощена основная часть активов развитых стран мира, а институциональная структура рынков претерпела глубокие изменения. Однако увеличение волатильности и нестабильности фондовых рынков создает риски для частных инвесторов, которые могут потерять свои вложения.

Привлечение частных инвесторов на фондовый рынок, с одной стороны, является положительным

фактором для экономики, а с другой — несет риски для самих инвесторов. Инвестирование через ЕЦП ПФР может стать решением, которое обеспечит лучшее соотношение риска и доходности для граждан, желающих увеличить свои пенсионные накопления.

Сегодня все больше людей, особенно представителей молодого и среднего поколения, понимают, что пенсионные накопления — это не просто отложенные на старость деньги, а возможность создать капитал, работающий на них уже сейчас. Они хотят сами решать, куда вкладывать свои средства: в акции, облигации, недвижимость, стартапы или даже криптовалюты [1]. При этом они осознают риски, связанные с инвестициями, и готовы учиться, анализировать рынок и принимать взвешенные решения.

Однако самостоятельное инвестирование требует не только знаний, но и времени, а также доступа к качественным инструментам и аналитике. Именно здесь ПФР может предложить уникальные решения, делающие процесс управления накоплениями более удобным, безопасным и прибыльным [2, 3].

Преимущества Пенсионного фонда России перед банками

На базе ЕЦП ПФР могут создаваться специализированные инвестиционные платформы, позволяющие гражданам самостоятельно выбирать инвестиционные стратегии, отслеживать доходность и перераспределять средства между различными активами. В отличие от банков, предлагающих стандартные депозиты с фиксированной доходностью, пенсионные фонды могут предоставить доступ к более широкому спектру инструментов, включая фондовый рынок, ПИФы, ETF и другие.

Одно из ключевых преимуществ пенсионных фондов — возможность предоставления налоговых льгот для граждан, делающих накопления на пенсию. Например, взносы в пенсионный фонд могут быть частично или полностью освобождены от налогообложения, а доходы от инвестиций — облагаться по сниженной ставке. Это делает пенсионные накопления более выгодными по сравнению с банковскими вкладами.

Пенсионные фонды предлагают своим клиентам доступ к образовательным ресурсам: вебинарам, курсам, аналитическим материалам и консультациям с финансовыми экспертами. Это помогает гражданам лучше понимать рынок, оценивать риски и принимать обоснованные инвестиционные решения.

Пенсионные фонды способствуют созданию инвестиционных сообществ, где граждане с общими интересами или целями могут объединять свои средства для формирования общего портфеля. Это позволит диверсифицировать риски и увеличить доходность за счет коллективного подхода. Например, сообщество может инвестировать в крупные проекты, закрытые для отдельных инвесторов.

В отличие от банков, где клиенты часто не знают, как именно используются их средства, пенсионные фонды обеспечивают полную прозрачность инвестиций. Граждане в режиме реального времени могут отслеживать, куда вложены их деньги, и при необходимости корректировать стратегию [4, 5].

Пенсионные фонды ориентированы на долгосрочные инвестиции, что позволяет им предлагать более стабильные и прогнозируемые условия. В отличие от банков, часто меняющих процентные ставки по вкладам, пенсионные фонды могут гарантировать определенные условия на протяжении многих лет.

Пример пенсионной накопительной системы

В мире уже существуют успешные примеры пенсионных систем, которые позволяют гражданам самостоятельно управлять своими накоплениями и объединяться для инвестирования. Например, в США популярны пенсионные планы 401(k)¹ и Individual Retirement Accounts² (IRA).

План 401(k) — это квалифицированный план сбережений на пенсию, названный по разделу налогового кодекса США, который его устанавливает. В настоящее время 401(k) стал пенсионным планом выбора для многих предприятий по всей стране. Он позволяет сотрудникам откладывать и инвестировать часть своей зарплаты до вычета налогов. Эти средства облагаются налогом только при их выводе³.

Планы 401(k) обычно предлагают различные варианты инвестиций. Возможности для инвестиций

в плане 401(k) обычно выбираются работодателем, часто в сотрудничестве с администратором плана или внешним финансовым консультантом. Этот процесс требует тщательного подхода, чтобы гарантировать, что предложенные инвестиции разнообразны и подходят для широкого круга сотрудников, участвующих в плане.

IRA — индивидуальный пенсионный счет, названный налоговой службой США «индивидуальным пенсионным планом», — это долгосрочный сберегательный счет с налоговыми льготами, который люди с заработанным доходом⁴ могут использовать для накопления средств на будущее⁵.

IRA предназначен в первую очередь для самозанятых людей, у которых нет возможности подключиться к пенсионным счетам на рабочем месте [аналогам 401(k)], доступным только через работодателей. Однако его можно открыть, даже если у сотрудника организации уже есть пенсионный план на работе. Любой субъект с заработанным доходом может открыть IRA через банк, инвестиционную компанию, онлайн-брокера или личного брокера и вносить взносы, включая тех, у кого есть счет 401(k) через работодателя. Единственное ограничение касается общей суммы, которую физическое лицо может внести на свои пенсионные счета за один год.

Лучшие счета IRA позволяют инвестировать в широкий спектр финансовых продуктов, включая акции, облигации, биржевые фонды (ETF) и паевые инвестиционные фонды.

Существуют также *самоуправляемые индивидуальные пенсионные счета (SDIRA)*, позволяющие инвесторам самостоятельно принимать все инвестиционные решения⁶. SDIRA предлагают доступ к более широкому спектру инвестиций, включая недвижимость и сырьевые товары. Однако самые рискованные инвестиции находятся под запретом.

Представленные выше программы позволяют гражданам самостоятельно выбирать инвестиционные стратегии, включая акции, облигации и ETF. Многие работодатели также предлагают возможность объединения средств сотрудников для инвестирования в крупные проекты, что снижает риски и увеличивает доходность.

⁴ Заработанный доход — доход, полученный в результате личных усилий налогоплательщика. Включает: заработную плату, прибыль от предпринимательства, роялти, некоторые виды пенсий. Отличается от пассивной формы дохода (дивиденды от инвестиций), тем, что образуется за счет личных усилий налогоплательщика.

⁵ Individual Retirement Account (IRA): What It Is, 4 Type. URL: <https://www.investopedia.com/terms/i/ira.asp>

⁶ How It Works and Where to Open One. -directed-ira. URL: <https://www.nerdwallet.com/article/investing/self>

¹ 401(k) планы. URL: <https://www.irs.gov/retirement-plans/401k-plans>

² Topic No. 451, Individual Retirement Arrangements (IRAs). URL: <https://www.irs.gov/taxtopics/tc451https://>

³ Частные пенсионные системы в США. URL: https://npfinsp2.narod.ru/new/ISKRAN_401k.htm

Австралийская пенсионная система *Superannuation* позволяет гражданам страны выбирать, как их средства будут инвестироваться⁷. Существуют опции для самостоятельного управления портфелем, а также возможность объединения с другими инвесторами для доступа к более диверсифицированным и прибыльным активам.

В Великобритании система *SIPP* предоставляет гражданам полный контроль над своими пенсионными накоплениями⁸. Они могут инвестировать в акции, недвижимость, фонды и даже стартапы. При этом существуют платформы, позволяющие объединять средства для коллективного инвестирования.

Доработка сервисов ЕЦП ПФР

Реализация систем, подобных перечисленным выше, на базе ЕЦП ПФР возможна, но необходимо разработать ряд ключевых сервисов [6]:

1) *инвестиционный сервис с выбором стратегий*. Сервис должен предоставлять гражданам возможность выбирать из различных инвестиционных стратегий (консервативная, умеренная, агрессивная) и самостоятельно распределять средства между активами: акциями, облигациями, ETF, недвижимостью и другими инструментами;

2) *образовательный сервис*. Сервис с курсами, вебинарами и аналитическими материалами, позволяющий гражданам разобраться в основах инвестирования, оценить риски и научиться формировать собственный портфель;

3) *сервис для создания инвестиционных сообществ*. Позволит гражданам объединяться в сообщества по интересам, целям или уровню риска. Платформа должна предоставлять инструменты для совместного управления общим портфелем и анализа его эффективности;

4) *автоматизированный советник (робо-эдвайзер)*. Инструмент, который на основе данных о возрасте, доходе, целях и уровне риска гражданина будет предлагать оптимальные инвестиционные стратегии;

5) *мониторинг и аналитика*. Сервис для отслеживания доходности портфеля, анализа рисков и получения рекомендаций по его оптимизации.

Инвестиционная модель «Портфель Марковица»

Пенсионер, использующий для инвестирования часть своих пенсионных накоплений, или само-

занный, откладывающий часть своего заработка в будущую пенсию, могут использовать различные модели и стратегии при инвестировании для оптимизации прибыли и уменьшения риска, например, портфель Марковица [7].

Гарри Марковиц опубликовал свою фундаментальную работу в 1952 г., которая и сегодня является основой подхода к инвестициям с точки зрения современной теории формирования портфеля [8].

Подход Марковица начинается с предположения, что инвестор в настоящий момент времени имеет конкретную сумму денег для инвестирования. Эти деньги будут инвестированы на определенный промежуток времени, который называется «период владения». В конце периода владения инвестор продает ценные бумаги, приобретенные в начале периода, после чего либо использует полученный доход на потребление, либо реинвестирует доход в различные ценные бумаги (либо делает и то и другое одновременно).

Наиболее общей закономерностью, отражающей взаимную связь между принимаемым риском и ожидаемой доходностью деятельности инвестора, является следующая: более рискованным вложениям, как правило, присуща более высокая доходность; при росте дохода уменьшается вероятность его получения. Оптимальность соотношения дохода и риска означает достижение максимума для комбинации «доходность-риск» или минимума для комбинации «риск-доходность».

Портфель Марковица — это инвестиционный портфель, оптимизирующий соотношение риска и доходности за счет диверсификации активов. Объединение индивидуальных портфелей Марковица в общий портфель имеет несколько преимуществ:

1) объединение портфелей позволяет диверсифицировать инвестиции еще больше, так как в общий портфель включаются активы из разных отраслей и регионов. Это снижает зависимость от колебаний на отдельных рынках;

2) коллективный портфель может включать более крупные и прибыльные проекты, недоступные для отдельных инвесторов из-за высокого порога входа;

3) совместное инвестирование позволяет снизить транзакционные издержки, так как комиссии распределяются между всеми участниками сообщества;

4) объединенные портфели могут управляться профессиональными управляющими или аналитиками, что повышает качество инвестиционных решений.

⁷ Superannuation: What It Is, How It Works, Types of Plans. URL: <https://www.investopedia.com/terms/s/superannuation.asp>

⁸ GOV.UK. URL: <https://www.gov.uk/personal-pensions>

Когда граждане объединяют свои портфели Марковица в общий, важно четко определить механизм распределения прибыли и рисков. Вот как это может работать.

1. Долевое участие. Каждый участник сообщества вносит свой портфель в общий пул, и его доля определяется стоимостью его активов. Прибыль и убытки делятся пропорционально этой доле.

2. Распределение прибыли. Доход от общего портфеля котируется между участниками в соответствии с их долей. Например, если общий портфель принес 10% дохода, то каждый участник получает 10% от стоимости своей доли.

3. Распределение рисков. Риски также распределяются пропорционально доле каждого участника. Однако за счет диверсификации общий уровень риска снижается для всех.

4. Гибкость выхода. Участники могут в любой момент выйти из сообщества, забрав свою долю в виде денежных средств или активов. Это обеспечивает гибкость и защищает интересы граждан.

5. Прозрачность. Все операции с общим портфелем должны быть прозрачными. Участники должны иметь доступ к отчетам о доходности, рисках и распределении средств.

МЕТОД ВЫБОРА ЖЕЛАТЕЛЬНОГО ПОРТФЕЛЯ

Рассмотрим пример создания сообщества инвесторов (пенсионеров или самозанятых), объединяющихся для уменьшения рисков потери своих вложений.

Инвестиционный процесс представляет собой принятие инвестором решения относительно ценных бумаг, в которые осуществляются инвестиции, объемов и сроков инвестирования. Основная цель инвестора при формировании портфеля — достижение максимальной доходности при минимальном уровне риска или уровне риска, который он считает допустимым.

Один из способов достижения этой цели — диверсификация, т.е. распределение имеющихся финансовых средств между различными активами или ценными бумагами, собранными в портфеле инвестора. Это делается, чтобы не нести больших убытков, если одна ценная бумага теряет в своей доходности, потому в портфеле есть иные бумаги, увеличивающие свою стоимость, а следовательно, и доходность.

Предлагаем рассмотреть метод выбора наиболее желательного портфеля, использующий *кривые безразличия*. Эти кривые отражают отношение

инвестора к риску и доходности и, таким образом, могут быть представлены как двухмерный график, где по горизонтальной оси откладывается риск, мерой которого является стандартное отклонение (σ_p), а по вертикальной оси — вознаграждение, мерой которого является ожидаемая доходность (R_p), *рис. 1*.

Кривые могут быть построены по точкам, причем каждая из них отражает для данного конкретного портфеля при заданном значении риска оптимальное решение задачи математического программирования (1).

$$\begin{aligned} R_p &\rightarrow \max, \\ \sigma_p &\leq \sigma_0, \\ x_1 + x_2 + \dots + x_n &= 1, \\ (x_1, x_2, \dots, x_n) &\geq 0. \end{aligned} \quad (1)$$

В расчете использованы обозначения:

σ_0 — приемлемый риск портфеля;

x_i — доля i -й ценной бумаги в портфеле.

Каждый инвестор для своего портфеля определяет меру риска, на который он готов пойти, но при котором он надеется получить максимальный доход от своего портфеля, исходя из такого распределения своего бюджета между финансовыми инструментами, входящими в портфель, который определяется моделью Марковица.

Выбор меры риска у инвесторов неодинаков. Одни из них готовы рисковать больше, в надежде на больший доход, другие более осторожны. В ряде случаев инвесторы готовы разделить свой риск с партнерами, объединив свои денежные ресурсы в «кассе взаимопомощи инвесторов», но при этом оставив за собой выбранные ими портфели.

При этом инвесторы могут договориться о разном уровне общего риска, который будет связан с размером их общего капитала, предназначенного для инвестирования в совокупность портфелей акций. Этот риск, или возможные потери капитала, могут быть разделены между инвесторами в соответствии с их личными предпочтениями выбора соотношения «риск-доход».

В этом случае σ_0 можно рассматривать как сумму рисков отдельных инвесторов

$$\sigma_0 = \sigma_1 + \sigma_2 + \dots + \sigma_n, \quad (2)$$

где σ_i ($i = 1, 2, \dots, n$) — величина риска, принимаемого на себя i -м инвестором.



У каждого инвестора свой портфель со своим риском. Но, объединяя портфели, они максимизируют общую прибыль, не превышая заданного уровня общего риска.

Пример объединения портфелей на ЕЦП

Допустим, что в результате применения метода Марковица к какому-то портфелю ценных бумаг, выбранному одним из инвесторов, был построен график величины доходности портфеля при различных значениях риска (рис. 1).

На рис. 1 изображена кривая и ее аналитическое представление зависимости дохода портфеля от выбранного значения риска. По горизонтальной оси графика отложены значения риска σ (возможные потери), по вертикальной оси — доходность портфеля ценных бумаг. У другого портфеля может быть другая зависимость, но также гладкая и монотонно возрастающая.

В качестве примера рассмотрим объединение трех инвесторов, сформировавших каждый свой портфель финансовых инструментов, и исходя из модели Марковица построивших свои зависимости «риск — доходность».

Так, на рис. 2 отображены представления о возможных соотношениях «риск-доходность» для различных портфелей 3-х инвесторов. Это

зависимости разных портфелей от выбранного уровня риска.

Далее для оценки максимальной полезности (доходности) затраченных ресурсов на инвестирование в портфели ценных бумаг предлагается использовать понятийный и методологический подходы, основанные на теории поведения потребителя, в частности, второго закона Госсена. Представленные выше кривые безразличия инвесторов будут рассматриваться как функции полезности. Функция полезности для i -го инвестора U_i зависит от величины риска, который готов принять на себя инвестор.

Общая полезность TU для всех инвесторов будет равна сумме полезностей:

$$TU = \sum U_i. \quad (3)$$

Общий риск σ_0 всех инвесторов будет равно сумме рисков отдельных инвесторов:

$$\sigma_0 = \sum \sigma_i, i = 1, \dots, n, \quad (4)$$

где:

σ_i — риск, определяемый для инвестора исходя из общего риска, выбранного для объединения




Рис. 1 / Fig. 1. Кривая безразличия «риск-доходность» / The indifference curve “risk-profitability”

Источник / Source: составлено автором / Complied by the author.




Рис. 2 / Fig. 2. Кривые «риск-доходности» для трех портфелей / “Risk-profitability” curves for three portfolios

Источник / Source: составлено автором / Compiled by the author.

трех портфелей, выбранный i -м инвестором для своего портфеля;

I — порядковый номер инвестора.

Выражение (3) представляет собой критерий, стремящийся к максимуму, а выражение (4) — ограничение на общий риск σ_0 . Таким образом, нахождение оптимального распределения рисков между инвесторами мы свели к решению нелинейной задачи математического программирования.

С помощью функции *Тренд* в MS Excel получены аналитические выражения этих кривых, подставляя эти функции в выражение (3) и определяя их сумму как критерий, стремящийся к максимуму, а выражение (4) как бюджетное ограничение на общий риск. Для получения искоемых значений σ_i можно воспользоваться функцией *Поиск решения* в MS Excel.

В результате получены следующие значения:

$$\sigma_i = 2,71, \sigma_2 = 3,37, \sigma_3 = 0,92. \quad (5)$$

Таким образом, в рассмотренном примере выделены значения оптимального набора рисков, определяющего конкретное значение риска для каждого инвестора, подбирающего для себя пор-

тфель ценных бумаг. При этих значениях риска доход от нескольких портфелей будет максимальным. А каждый инвестор, исходя из рекомендованного уровня риска, перестроит распределение своих инвестиций между финансовыми инструментами своего портфеля.

Значение риска по каждому портфелю бумаг определяет ожидаемый оптимальный доход и распределение инвестиций внутри данного портфеля между ценными бумагами.

Доход отдельного инвестора определяется долей дохода, определяемой его частью инвестиций в общий портфель, состоящий из трех индивидуальных портфелей по каждому портфелю ценных бумаг в отдельности, умноженной на его доли в общем капитале.

Так, например, если первый инвестор внес в общий капитал 20 тыс. руб., второй — 30 тыс. руб., а третий — 50 тыс. руб., то первый инвестор получит от общего дохода — 20%, второй — 30, третий — 50%.

Разделение рисков в цепочке бизнес-процессов, страхования и других видов экономической деятельности приобретает в последнее время все большую популярность. Инвестирование в ценные бумаги пенсионерами и самозанятыми на базе ЕЦП может стать для них привлекательной формой уча-

ствия в экономике страны, повысить их самооценку, мотивацию и долголетие.

ВЫВОДЫ

Единая централизованная платформа в социальной сфере ПФР в настоящее время не предоставляет прямых возможностей для инвестирования в финансовые компании. Однако ПФР может рекомендовать пользователям негосударственные пенсионные фонды (НПФ) или управляющим компаниям (УК), через которые пользователи могут косвенно участвовать в инвестировании своих пенсионных накоплений.

Самоуправляемые пенсионные накопления и объединение граждан в инвестиционные сообщества — это тренд, который может изменить подход к формированию пенсионных сбережений в России. Пенсионные фонды, используя опыт зарубежных стран и современные цифровые технологии, могут предложить

гражданам уникальные возможности для управления своими средствами. Разработка специализированных сервисов на базе Единой цифровой платформы ПФР, таких как инвестиционная платформа, образовательный портал и инструменты для создания сообществ, сделает этот процесс доступным и удобным.

Объединение портфелей Марковица отдельных граждан в общий портфель группы позволит снизить риски, увеличить доходность и получить доступ к более крупным и прибыльным проектам. Четкий механизм распределения прибыли и рисков обеспечит справедливость и прозрачность, что делает такие сообщества привлекательными для широкого круга граждан.

В будущем такие инициативы могут стать основой для новой модели пенсионных накоплений, где каждый гражданин сможет не только обеспечить себе достойную старость, но и приумножить свои средства уже сегодня. Главное — сделать этот процесс доступным, прозрачным и выгодным для всех его участников.

БЛАГОДАРНОСТИ

Исследование проведено в рамках работы Научно-исследовательского центра развития государственной пенсионной системы и актуарно-статистического анализа по государственному заданию ПНИР-35: 125031103475-2 Финансовому университету при Правительстве Российской Федерации на 2025 г. Москва. Российская Федерация.

ACKNOWLEDGMENTS

The study was conducted as part of the work of the Scientific Research Center for the Development of the State Pension System and Actuarial and Statistical Analysis on a state assignment PNIR-35: 125031103475-2 from the Financial University under the Government of the Russian Federation for 2025. Moscow. Russian Federation.

СПИСОК ИСТОЧНИКОВ

1. Дробышевская Л.Н., Маргарян А.А., Коллективное инвестирование в России: тенденции и перспективы. *Экономика и бизнес: Теория и практика*. 2025;5(123):123–127. 2025. DOI: 10.24412/2411-0450-2025-5-123-127
2. Корчагин Д.М. Параметрический анализ применимости современных теорий управления портфелем для инвестирования средств пенсионных накоплений. *Экономические науки*. 2011;80:167–170. URL: <https://www.elibrary.ru/oyufgz>
3. Шохин С.О. Государственная политика пенсионного обеспечения населения России: современные тенденции и перспективы. М. Проспект; 2022.
4. Davis E. Philip. Pension Funds: Retirement-Income Security and the Development of Financial Systems: An International Perspective: Retirement-income Security and Capital Markets — An International Perspective Kindle Edition. Oxford University Press; 1998.
5. Feldstein M.S. Reforming Social Security: How Should We Finance Retirement? *Journal of Economic Perspectives*. 2005;19(2):33–55. DOI: 10.1257/0895330054048731
6. Марковиц Г. Выбор портфеля. *The Journal of Finance*. 1952;7(1):77–91. URL: <https://assetallocation.ru/portfolio-selection/?ysclid=mc240is534623840193> DOI: 10.2307/2975974.
7. Кох И. Современные возможности диверсификации на рынке акций. *Рынок ценных бумаг*. 2016;7:42–47.

REFERENCES

1. Drobyshevskaya L.N., Margaryan A.A., Collective investment in Russia: trends and prospects. *Economics and Business: Theory and Practice*. 2025;5(123):123–127. 2025. (In Russ.). DOI: 10.24412/2411-0450-2025-5-123-127
2. Korchagin D.M. Parametric analysis of the applicability of modern portfolio management theories for investing pension savings. *Economic sciences*. 2011;80:167–170. URL: <https://www.elibrary.ru/oyufgz> (In Russ.).
3. Shokhin S.O. State policy of pension provision for the Russian population: current trends and prospects. Moscow: Prospekt; 2022.
4. Davis E. Philip. Pension Funds: Retirement-Income Security and the Development of Financial Systems: An International Perspective: Retirement-income Security and Capital Markets — An International Perspective Kindle Edition. Oxford University Press; 1998.
5. Feldstein M.S. Reforming Social Security: How Should We Finance Retirement? *Journal of Economic Perspectives*. 2005;19(2):33–55. DOI: 10.1257/0895330054048731
6. Markowitz H. Portfolio Selection. *The Journal of Finance*. 1952;7(1):77–91. URL: <https://assetallocation.ru/portfolio-selection/?ysclid=mc240is534623840193> (In Russ.). DOI: 10.2307/2975974.
7. Kokh I. Modern Opportunities for Diversification in the Stock Market. *Securities Market Journal*. 2016;7:42–47.

ИНФОРМАЦИЯ ОБ АВТОРЕ / ABOUT THE AUTHOR

Александр Иванович Богомолов — кандидат технических наук, старший научный сотрудник, ведущий научный сотрудник Научно-исследовательского центра развития государственной пенсионной системы и актуарно-статистического анализа, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Alexander I. Bogomolov — PhD, Leading Researcher, Research Center for the Development of the State Pension System and Actuarial-Statistical Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0003-3285-0299>

aibogomolov@fa.ru

Конфликт интересов: автор заявляет об отсутствии конфликта интересов.

Conflicts of Interest Statement: The author has no conflicts of interest to declare.

Статья поступила 29.05.2025; принята к публикации 05.06.2025.

Автор прочитал и одобрил окончательный вариант рукописи.

The article was received 29.05.2025; accepted for publication 05.06.2025.

The author read and approved the final version of the manuscript.