

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
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 2, № 2, 2026

Издается с 2025 года

Периодичность: 4 раза в год

ISSN 3033-5477 (Print)

ISSN 3033-7097 (Online)

Свидетельство о регистрации:

Эл № ФС77-90338

от 01 ноября 2025 г.

Учредитель и издатель:

Финансовый университет
при Правительстве Российской
Федерации
125167, Российская Федерация,
Москва,

Ленинградский проспект, 49
+7 (499) 553-10-74

<https://www.digitarin.ru/jour-aaizvekova@fa.ru>

Главный редактор

Феклин

Вадим Геннадьевич

«Цифровые решения и технологии искусственного интеллекта» — платформа для публикации оригинальных и актуальных исследований, посвященных современным технологиям в сфере искусственного интеллекта и цифровых решений.

Заведующий редакцией

В.И. Головатенко

Выпускающий редактор

А.А. Извекова

Переводчик **И.М. Евстратов**

Корректор **С.Ф. Михайлова**

Верстальщик **Е.А. Смирнова**

Отпечатано в ООО «Коми
Республиканская типография»,
г. Сыктывкар, ул. Савина, д. 81.

Тираж 500 экз.

(I завод — 40 экз.).

Формат 60 x 84 1/8.

Заказ № 26-2394

Подписано в печать:

24.04.2026

Выход в свет 24.05.2026

© Финансовый университет
при Правительстве Российской
Федерации, Москва

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И МАШИННОЕ ОБУЧЕНИЕ

Румянцев С.А., Полищук Ю.В.

Искусственный интеллект в высшем образовании
и психологическом консультировании:
методическая рамка внедрения. 6

Овсянникова А.В.

Интеллектуальные рекомендательные системы
в образовании. Алгоритмы подбора
индивидуальных траекторий обучения 16

МЕТОДЫ И СИСТЕМЫ ЗАЩИТЫ ИНФОРМАЦИИ, ИНФОРМАЦИОННАЯ БЕЗОПАСНОСТЬ

Цыганков В.Р., Гринева Н.В., Голосов П.Е.

Автоматизация процесса инкассации
на основе разработки и внедрения мобильной
автоматизированной инкассаторской системы 25

Баранова Е.К., Крючков Е.С.

Управление рисками информационной безопасности
систем электронного документооборота
на основе нейросетевых моделей. 35

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ, ЧИСЛЕННЫЕ МЕТОДЫ И КОМПЛЕКСЫ ПРОГРАММ

Степанян И.К., Хрипунова М.Б.

Мультимодальные чат-боты в цифровой образовательной
среде: аналитический обзор. 46

Цветкова А.Д., Кочкаров Р.А., Окунева Э.А.

Моделирование и структурный анализ
социальных сетей 57

МАТЕМАТИЧЕСКИЕ, СТАТИСТИЧЕСКИЕ И ИНСТРУМЕНТАЛЬНЫЕ МЕТОДЫ В ЭКОНОМИКЕ

Варьяш И.Ю., Бузова Т.Ф., Климанов Д.В.

Информатика опережающих данных 63

Malyshev A.A., Muminova S.R.

Empirical Verification of the Anchoring Effect Hypothesis
on the Acquiring Company's Stock Returns in Trading Deals . . . 72

ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING

Rumyantsev S.A., Polishuk Yu.V.

Artificial Intelligence in Higher Education
and Psychological Counseling:
A Methodological Framework for Implementation 6

Ovsyannikova A.V.

Intelligent Recommender Systems in Education.
Algorithms for Personalised Learning Pathways 16

METHODS AND SYSTEMS OF INFORMATION
PROTECTION, INFORMATION SECURITY**Tsygankov V.R., Grineva N.V., Golosov P.E.**

Automation of the Cash Collection Process
Through the Development and Implementation
of a Mobile Automated Cash-in-transit System 25

Baranova E.K., Kriuchkov E.S.

Managing Information Security Risks of Electronic Document
Management Systems Based on Neural Network Models . . . 35

MATHEMATICAL MODELING, NUMERICAL METHODS
AND SOFTWARE PACKAGES**Stepanyan I.K., Khripunova M.B.**

Multimodal Chatbots
in the Digital Educational Environment:
Analytical Review 46

Tsvetkova A.D., Kochkarov R.A., Okuneva E.A.

Modeling and Structural Analysis of Social Networks 57

MATHEMATICAL, STATISTICAL AND INSTRUMENTAL
METHODS IN ECONOMICS**Vajas I.Yu., Burova T.F., Klimanov D.V.**

Advanced Data Informatics 63

Malyshev A.A., Muminova S.R.

Empirical Verification of the Anchoring Effect Hypothesis
on the Acquiring Company's Stock Returns in Trading Deals . . . 72

DIGITAL SOLUTIONS
AND ARTIFICIAL
INTELLIGENCE
TECHNOLOGIES*Scientific and practical journal*

Vol. 2, No. 2, 2026

Published Since 2025

Publication Frequency: 4
times a year

ISSN 3033-5477 (Print)

ISSN 3033-7097 (Online)

Founder and Publisher:

Financial University
under the Government of
the Russian Federation
125167, Russian Federation,
Moscow,

49, Leningradsky Avenue
+7 (499) 553-10-74

<https://www.digitarin.ru/jour>
aaizvekova@fa.ru

Digital Solutions and
Artificial Intelligence
Technologies is a platform
for publishing original and
relevant research on modern
technologies in the field of
artificial intelligence and
digital solutions.

Editor-in-Chief

Vadim G. Feklin

Head of Scientific Journals
Editorial Department

V.I. Golovatenko

Managing Editor

A.A. Izvekova

Translator

I.M. Evstratov

Proofreader

S.F. Mikhaylova

Design, make up

E.A. Smirnova

Printed in Komi Republican
Printing House LLC,

Syktyvkar, Savina St. 81

The edition is 500 copies.

(I factory – 40 copies).

Format is 60 x 84 1/8.

Order № 26-2394

Signed off to printing:

24.04.2026

Publication date 24.05.2026

© 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

ПЕТРОВСКИЙ 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., Cand. Sci. (Phys.-Math.), Associate Professor, 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., Cand. Sci. (Econ.), 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., Cand. Sci. (Tech.), 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., PhD, 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., Cand. Sci. (Econ.), 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

MELNIKOVA 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., Cand. Sci. (Tech.), 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., Dr. Sci. (Tech.), 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

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

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

DOI: 10.26794/3030-7097-2026-2-2-6-15
УДК 378.004.8(045)

Искусственный интеллект в высшем образовании и психологическом консультировании: методическая рамка внедрения

С.А. Румянцев¹, Ю.В. Полищук²¹ Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация;² Московский технический университет связи и информатики, Москва, Российская Федерация

АННОТАЦИЯ

В статье обоснованы и систематизированы подходы к применению технологий искусственного интеллекта (ИИ) в высшем профессиональном образовании (ВПО) как инструмента информационно-аналитического обеспечения индивидуального обучения, коучинга, управленческой деятельности и психологического консультирования. Цель работы — представить способы использования ИИ-инструментов (генеративных моделей, интеллектуальных ассистентов, рекомендательных систем и средств интеллектуальной обработки документов) в образовательный процесс и управление вузом при сохранении ответственности человека и требований академической этики. Показано, что ключевым эффектом ИИ в ВПО является переход от «усредненного» обучения к персонализированным траекториям, поддерживаемым образовательной и предметной аналитикой, а также формирование новых практик наставничества (коучинга) на основе данных. Предложены решения (аналитические рекомендательные системы; интеллектуальные образовательные среды; системы поддержки управления) и описаны типовые сценарии: ИИ-тьютор, коучинговый сценарий, аналитический дашборд, автоматизация методической подготовки преподавателя, поддержка психологического консультирования (скрининг запросов, симуляторы диалогов). Отдельно выделены риски (галлюцинации, смещения данных) и необходимость проверки специалистом по источникам. Практическая значимость работы заключается в формировании применимых подходов внедрения ИИ в ВПО, ориентированных на повышение качества обучения и управляемости образовательных процессов. В разработке использованы: (1) теоретические методы — анализ и синтез, системный подход, сравнительный анализ, классификация, обобщение психолого-педагогического и организационно-управленческого опыта внедрения ИИ; (2) информационно-аналитические методы — контент-анализ научных публикаций и практик применения ИИ в ВПО; анализ типовых кейсов применения (генеративные ассистенты, чат-боты); (3) методологическое моделирование — проектирование методической модели использования ИИ (уровни: обучение / коучинг / управление / консультирование), описание функций, входов / выходов и ограничений (в том числе требования к данным, валидации и этике); (4) выделение рисков и мер их минимизации, проверка по источникам, регламент раскрытия использования ИИ, защита данных. **Ключевые слова:** искусственный интеллект; профессиональное образование; аналитика; коучинг; психологическое консультирование; педагогика

Для цитирования: Румянцев С.А., Полищук Ю.В. Искусственный интеллект в высшем образовании и психологическом консультировании: методическая рамка внедрения. *Цифровые решения и технологии искусственного интеллекта*. 2026;2(2):6-15. DOI: 10.26794/3030-7097-2026-2-2-6-15

ORIGINAL PAPER


Artificial Intelligence in Higher Education and Psychological Counseling: A Methodological Framework for Implementation

S.A. Rumyantsev¹, Yu.V. Polishuk²¹ Financial University under the Government of the Russian Federation, Moscow, Russian Federation;² Moscow Technical University of Communications and Informatics, Moscow, Russian Federation

ABSTRACT

The article substantiates and systematizes approaches to the use of artificial intelligence (AI) technologies in higher professional education as a tool for information and analytical support of individual training, coaching, management activities and psychological counseling. The purpose of the work is to present ways to use AI tools (generative models, intelligent assistants, recommendation systems and intelligent document processing tools) in the educational process and university management while maintaining human responsibility and the requirements of academic ethics. It is shown that the key effect of AI in higher education is the transition from “average” learning to personalized trajectories supported by educational and subject analytics,

© Румянцев С.А., Полищук Ю.В., 2026



as well as the formation of new mentoring (coaching) practices based on data. Solutions (analytical recommendation systems; intelligent educational environments; management support systems) are proposed and typical scenarios are described: an AI tutor, a coaching scenario, an analytical dashboard, automation of teacher training, support for psychological counseling (query screening, dialogue simulators). The risks (hallucinations, data bias) and the need for verification by a source specialist are highlighted separately. The practical significance of the work lies in the formation of applicable approaches to the introduction of AI in higher education, focused on improving the quality of education and the manageability of educational processes. The following theoretical methods were used in the development: (1) analysis and synthesis, a systematic approach, comparative analysis, classification, generalization of psychological-pedagogical, organizational and managerial experience in the implementation of AI; (2) information and analytical methods — content analysis of scientific publications and practices of AI application in higher education; analysis of typical application cases (generative assistants, chatbots); (3) methodological modeling — designing a methodological model for the use of AI (levels: training / coaching / management / consulting), description of functions, inputs/outputs and constraints (including requirements for data, validation and ethics); (4) identification of risks and measures to minimize them, verification by sources, regulations for disclosure of the use of AI, data protection.

Keywords: artificial intelligence; professional education; analytics; coaching; psychological counseling; pedagogy

For citation: Rumyantsev S.A., Polishuk Yu.V. Artificial intelligence in higher education and psychological counseling: A methodological framework for implementation. *Digital solutions and artificial intelligence technologies*. 2026;2(2):6-15. DOI: 10.26794/3030-7097-2026-2-2-6-15

ВВЕДЕНИЕ

Искусственный интеллект (ИИ) активно внедряется во многие сферы, включая систему высшего образования, что требует оперативной адаптации всех операционных и рутинных задач и методики преподавания и контроля.

Как отмечается в современных исследованиях [1, 2], одним из преимуществ цифровизации образования является анализ больших массивов данных об образовательном процессе; применение технологий ИИ открывает новые перспективы для оценки его результативности, прогноза успехов обучающихся и поддержки принятия решений в управлении.

Индивидуализация обучения, развитие коучинговых практик для студентов, совершенствование системы управления вузом и оказание психологической поддержки — все эти направления получают новое развитие благодаря информационно-аналитическим средствам на базе ИИ.

Отечественные авторы (например, М.В. Коротев, А.С. Марунько, Е.В. Романова, Н.Ю. Чулина [3] и др.) исследуют вопросы автоматизации образовательного процесса, применения интеллектуальных систем в психологии и педагогике высшей школы и в образовании в целом. Все авторы отмечают актуальность внедрения технологий искусственного интеллекта (ИИ) в систему высшего образования и одним из значимых преимуществ ИИ в образовании отмечают возможность реализовать персонализированный подход, ведь традиционно в большой группе трудно учесть индивидуальные особенности каждого учащегося, но интеллектуальные обучающие системы способны адаптировать подачу материала и задания под уровень и потребности отдельного студента. В ключевых дискуссиях об образовании на Конгрессе молодых ученых также многие темы были сосредоточены вокруг ИИ и его

реального влияния на подготовку специалистов. Фактически искусственный интеллект — новая трансформирующая технология для образования¹.

Не только студенты, но и сами преподаватели выигрывают от персонализированных ассистентов. Отсылка к использованию ИИ может помочь студенту (с помощью преподавателя) быстро найти решения — например, разобраться в алгоритме использования, понять, какие файлы приложить, получить рекомендации по структуре промпта. Это позволяет студенту не только оперативно решать задачи, но и приобретать навыки научной деятельности, аналитики и менеджмента (ИИ выступает в качестве виртуального исполнителя подчиненного).

Виртуальные репетиторы (чат-боты с предметной специализацией) могут круглосуточно отвечать на вопросы учащихся, объяснять непонятные темы разными словами, приводить дополнительные примеры; выступать «вторым преподавателем», к которому студент может обратиться в любое время для уточнений. Взаимодействие с ИИ-репетитором может побуждать учащегося самому активно конструировать знание, формулировать объяснения. Таким образом, ИИ может служить катализатором активного обучения.

Проанализируем возможности информационно-аналитической поддержки индивидуального обучения, коучинга, управленческой деятельности и психологического консультирования с помощью ИИ и рассмотрим, как виртуальные инструменты могут повысить качество обучения и научной работы, персонализировать образовательный опыт, облегчить рутинные задачи преподавателя и расширить возможности тренинга и консультирования.

¹ URL: <https://www.kommersant.ru/doc/8248541?ysclid=mnzq03gqyz652232125>

1. Этические и методические основы ответственного применения ИИ в высшем образовании

Одной из проблем использования ИИ являются предубеждения. ИИ-модели обучены на больших массивах данных, в которых могут быть перекосы (гендерные, культурные, языковые, художественные интерпретации, намеренные искажения из публичной «желтой» прессы и т.д.). В образовании это недопустимо, поэтому преподаватель должен фильтровать и проверять содержимое, предлагаемое ИИ, особенно если оно касается социально чувствительных тем.

Важным помощником здесь выступает общая компетентность по предметной области. Чтобы качественно пользоваться ИИ в определенной области знаний, надо быть достаточно начитанным и экспертным в этой области, чтобы выбирать качественные материалы из предложенных, направлять работу ИИ и исключать «галлюцинации» ИИ.

Этическое и нормативное обеспечение — необходимое условие успешной интеграции ИИ в ВПО. Без него внедрение самых совершенных технологий приведет к снижению качества образования и доверия в академической среде. Поэтому развитие методических моделей применения ИИ неразрывно связано с формированием новых стандартов и правил.

Методические модели применения ИИ в высшей школе должны разрабатываться комплексно, учитывая и технические возможности, и педагогическую целесообразность, и психологические эффекты, и этические рамки.

2. Адаптация методов прогнозной аналитики в ВПО

Применимость ИИ-аналитики к управленческим практикам подтверждается не только образовательными исследованиями, но и работами по интеллектуализации управленческих решений в организациях. Так, В.Г. Абашин, Н.А. Загородних и В.Ю. Преснецова рассматривают перспективы использования нейросетевых технологий для совершенствования управления коммерческими организациями, подчеркивая ценность прогнозной аналитики и выявления скрытых зависимостей в управленческих данных [4].

Перенос данного подхода в ВПО методически оправдан: университет как сложная организация обладает сопоставимой структурой управленческих контуров (кадровые процессы, качество образовательных программ, ресурсы, финансово-экономические показатели), а значит, нейросетевые методы могут применяться для мониторинга рисков, раннего предупреждения проблем и поддержки управленческих решений в условиях неопределенности.

Информационно-аналитическая поддержка ВПО требует работы не только с архивными массивами, но и с потоковыми данными (цифровым следом ак-

тивности, посещаемостью, событиями прокторинга). В смежных областях показано, что методы машинного обучения применимы к обработке интенсивных информационных потоков в реальном времени.

Например, В.Е. Косарев и В.И. Миловидов рассматривают использование методов машинного обучения для обработки потоков интернет-эквайринга коммерческого банка [5]. Аналогичная постановка задач актуальна и в системе ВПО: потоковая аналитика для оперативного мониторинга рисков поможет выявить и оценить резкое падение активности студентов, инциденты академической добросовестности и др.

3. Оптимизация методической работы и отчетности с помощью ИИ

Практическая значимость ИИ для высшей школы проявляется и в автоматизации методического контура, включая подготовку и актуализацию рабочих программ дисциплин (РПД), фондов оценочных средств и комплектов учебно-методических материалов.

Е.П. Догадина и М.И. Бочаров описывают подход к автоматизации составления РПД с использованием виртуального ассистента для работы с нейросетью, показывая возможность сокращения трудоемкости и стандартизации методической документации [6].

Современные системы ИИ способны существенно облегчить методическую работу преподавателя на всех этапах — от проектирования программы дисциплины до проверки работ.

Во-первых, генеративные модели стали своеобразными ассистентами при подготовке учебных материалов. Преподаватель может поручить модели на основе приложенных источников, идей, предварительных планов сгенерировать черновик плана занятия, перечень кейсов или набор тестовых вопросов по нужной теме. Это может позволить сэкономить время преподавателя на рутинной работе — например, на составлении вариантов однотипных задач или разработке примеров к типовым ситуациям.

Сокращение времени на подготовку может дать возможность больше сконцентрироваться на взаимодействии со студентами и творческих аспектах преподавания.

Развитие цифровых платформ в высшем образовании создает основу для эффективного управления знаниями и образовательной аналитики. Пример — внедрение стандарта XBRL для формирования управленческой отчетности в вузах.

Я.Л. Гобарева и О.Ю. Городецкая рассматривают XBRL как инструмент цифровой трансформации отчетности, позволяющий унифицировать и облегчить анализ данных управления [7]. Использование таких стандартов в образовательных учреждениях позволит повысить прозрачность и эффективность мони-



торинга ключевых показателей деятельности вузов (академической успеваемости, финансов, ресурсов).

4. Коррекция образовательного процесса: качество данных и валидность прогнозов ИИ

Качество информационно-аналитического сопровождения на базе ИИ определяется корректностью данных и способами формирования обучающих выборок. В прикладных исследованиях по машинному обучению отдельно обсуждается задача генерации и расширения обучающих данных.

Так, А.Д. Авраменко и В.А. Судаков описывают метод генерации обучающей выборки машинного обучения в задаче коммивояжера [8]. Методологически это может быть важно и для образовательной аналитики: в университетских данных (успеваемость, активность, результаты тестов) часто присутствуют пропуски, шум и смещения, поэтому процедуры формирования корректных выборок становятся критическим элементом валидности прогнозов и рекомендаций ИИ.

Методологическим основанием персонализации служат рекомендательные системы, учитывающие индивидуальность обучающихся и структуру их образовательных связей (курсы — компетенции — результаты — интересы). В этом контексте перспективны графовые методы машинного обучения, позволяющие моделировать сложные взаимосвязи: И.И. Хасанов и З.Р. Хасанова рассматривают применение машинного обучения на графах для построения рекомендательных систем, ориентированных на учет индивидуальности пользователей [9].

В задачах ВПО графовый подход может использоваться для рекомендаций по выбору элективов, траекторий освоения компетенций, формирования командных проектов и подбора индивидуальных упражнений на основе «профиля затруднений», что усиливает роль ИИ как инструмента коучинга и тьюторского сопровождения.

Стремительное внедрение ИИ требует оперативной адаптации методик преподавания и контроля. Все это составляет актуальный контекст, в котором разрабатываются методические модели применения ИИ в высшем профессиональном образовании и научных исследованиях.

5. Применение ИИ в различных предметных областях ВПО

5.1. Информатика и ИТ

Практика применения ИИ в образовательном процессе зависит от предметной области. Наиболее естественно он применяется в сфере информатики и ИТ, где технологии ИИ являются и инструментом, и объектом изучения. Преподаватели-программисты активно используют ИИ (например, GitHub Copilot, GigaChat, ChatGPT и др.) как вспомогательный инструмент на занятиях. Эти системы дополняют традиционное об-

учение: студент пишет код, а ассистент может подсказать следующий фрагмент, указывая на возможные ошибки. Работа начинающих программистов в паре с ИИ повышает эффективность: своевременные подсказки и примеры ускоряют освоение синтаксиса и могут предотвратить фрустрацию. ИИ может предлагать следующий шаг решения, когда ученик не справляется, — как репетитор наталкивает на мысль, а не решает за студента. Такие подходы способствуют развитию навыков решения задач и одновременно поддерживают мотивацию: студент не бросает задачу, а двигается вперед с небольшой поддержкой. На данном этапе важно научить студентов не слепо копировать, а критически оценивать решения ИИ, разбираться, почему сгенерирован именно такой код. Для предотвращения злоупотреблений (когда студент просто сдает код, написанный моделью) преподаватели могут менять формат заданий — делают акцент на устные защиты проектов, разбор кода, творческие задачи, где ценится оригинальность решения, задания управленческого уровня (менеджерские, архитектурные, аналитические).

5.2. Гуманитарные и социальные науки

В гуманитарных дисциплинах персонализация проявляется через диалоговые возможности генеративных моделей. Например, при изучении иностранных языков чат-боты могут имитировать языковую среду: студент ведет диалог на изучаемом языке с ИИ-собеседником, который корректирует ошибки и дает подсказки.

5.3. Психологическое консультирование и коучинг

В психологическом консультировании, подготовке консультантов и коучей ИИ выступает как учебный инструмент для отработки навыков взаимодействия. Виртуальные собеседники и клиенты на основе ИИ могут использоваться для приобретения навыков консультирования. Так, студенты-психологи могут практиковаться в ведении консультативной беседы с виртуальным «клиентом», роль которого выполняет чат-бот, запрограммированный на определенную проблему (например, тревожность перед экзаменами, конфликт в семье). Генеративные чат-боты могут правдоподобно симулировать клиентов и предоставлять начинающим психологам безопасную среду для тренировки.

5.4. Управление и экономика

В области управления и экономики ИИ применяется для деловых игр и кейсов. К примеру, создаются бизнес-симуляции, где ИИ выступает в роли рыночной среды или контрагента, реагируя на решения студентов-управленцев. Студенты могут вести переговоры с ИИ-партнером, который имитирует поведение клиента или конкурента, — такая практика может развивать навыки коммуникации и принятия

решений в динамичной среде. Благодаря быстрому анализу данных ИИ позволяет проводить разбор реальных кейсов (финансовых, маркетинговых) гораздо быстрее: загрузив данные компании, модель может мгновенно выделить ключевые тенденции, спрогнозировать развитие показателей, предложить оптимизационные меры. Преподаватель, вооруженный такими инструментами, может организовать учебный процесс более эффективно, сосредоточившись на обсуждении причинно-следственных связей и стратегий, вместо ручного расчета показателей.

5.5. Дополнительные возможности применения ИИ в образовании и спорте

ИИ значительно ускоряет поиск источников, в том числе на иностранных языках, и быстрый анализ мирового опыта по каждой преподаваемой теме. Находит применение ИИ даже в каратэ — для подсчета количества очков и определения динамических характеристик удара в единоборствах с помощью нейронных сетей [10]. Можно также рекомендовать использовать ИИ для генерации достаточно вариативных серий приемов для тренировки без повторений.

6. Информационно-аналитическое обеспечение и мониторинг

В качестве примера интеграции с цифровыми инструментами мониторинга в прикладных задачах можно обратиться к работе Е.И. Кублик, А.И. Лабинцева и соавт., посвященной использованию цифровых инструментов мониторинга [11]. Этот пример демонстрирует, как цифровые инструменты могут выполнять функции аналитического сопровождения.

Отдельное направление информационно-аналитического обеспечения консультирования связано с анализом текстовых массивов (обращений студентов, отзывов, рефлексивных дневников, запросов в службу поддержки). Примером прикладной реализации NLP-аналитики является работа Е.С. Будаева [12], где описано веб-приложение интеллектуального анализа текстовых отзывов с применением модифицированной модели seq2seq с механизмом внимания.

Аналогичные методы в контуре ВПО могут применяться для выявления типовых затруднений обучающихся, диагностики рисков эмоционального выгорания по обращаемости и тематике запросов, а также для построения «карты проблем» курса/программы на основе текстовых данных обратной связи. Это усиливает возможности коучинга и психологического сопровождения за счет объективируемой аналитики больших массивов сообщений.

Методы машинного обучения, применяемые для анализа лояльности и настроений сотрудников на основе текстовых отзывов, методически релевантны и для образовательной среды, где аналогичным

образом анализируется вовлеченность и удовлетворенность обучающихся. Так, Г.Н. Жолобова и Е.Д. Сидницина демонстрируют применение машинного обучения для анализа лояльности сотрудников по текстовым данным [13]. Перенос данного подхода в ВПО позволяет рассматривать массивы открытых ответов анкет, комментариев к курсам и обращений в поддержку как источник диагностической информации для управления качеством образования и профилактики отчислений, а также для своевременного подключения коучинговой или психологической поддержки студентов.

7. Контроль и критическая оценка результатов работы ИИ
Полностью полагаться на ИИ при генерации учебных материалов и оценивании нельзя. Генеративные модели склонны допускать случайные ошибки и «галлюцинации» — порождать убедительно выглядящие, но фактически неверные ответы, поэтому материалы, выдаваемые ИИ, требуют тщательного анализа, проверки с опорой на источники, коррекции, а окончательное решение должен принимать специалист, обладающий достаточным уровнем компетентности в предметной области.

Практика показывает, что ИИ может воспроизводить шаблонные ответы и упускать нюансы — например, сгенерировать текст на основе художественной литературы и «желтой» прессы вместо научных источников. Роль педагога смещается в сторону экспертизы и контроля: проверять то, что предлагает ИИ, и обучать студентов критически относиться к автоматической обратной связи.

Сам контроль работ студентов (доклады, лабораторные, курсовые и т.д.) может концентрироваться на проверке использования конкретных источников, цитат, обоснований, поиска «галлюцинаций» ИИ и т.д. Такая форма обратит недостатки ИИ в пользу для учебного процесса — при достаточном акцентировании внимания студентов на особенностях работы в новых условиях и возможных ошибках ИИ.

При такой работе одним из важных аспектов может являться необходимость сформировать критическое отношение к результатам, выдаваемым ИИ, и приобрести навыки верификации, валидации материалов, тестирования, цитирования и т.д.

Некоторые люди склонны доверять уверенно сформулированным ответам ИИ, порой даже больше, чем советам ровесников или учебника. Преподавателю важно формировать у студентов здоровый скептицизм к выводам машины. Полезным упражнением служит сравнение: например, показать ответ ChatGPT на открытый вопрос и вместе найти в нем неточности, упущенные аспекты, логические ошибки. Студенты должны осознать, что, хотя модель излагает материал гладко, она может допускать фактические



ошибки или нелогичные выводы — особенно если запрос неконкретный.

Действительно, наблюдения подтверждают: когда учащиеся пытались сдавать эссе, написанные ИИ, тексты выдавали себя «идеальностью» — отсутствием ошибок, излишней стандартностью аргументов и иногда ссылками на несуществующие цитаты. Такая безупречность как раз и сигнализирует о машинном происхождении работы, ведь реальные студенческие тексты обычно содержат небольшие огрехи. Разбор подобных примеров учит студентов более критично относиться к информации и понимать ограничения ИИ.

Использование ИИ меняет мотивационную сферу. Если любую задачу можно решить с помощью алгоритма, у части студентов снижается внутренняя мотивация напрягаться самостоятельно. Чтобы поддерживать интерес и усилия, преподаватели могут применять методики, акцентирующие внимание на творческих заданиях, где ценится оригинальный продукт, созданный студентом (эссе с личной рефлексией, проекты, исследования), — там ИИ может быть лишь вспомогательным инструментом, но не заменой автору. Также помогает геймификация и элемент соревнования: когда задача подразумевает уникальное решение или соревнование, студенту важно проявить свои способности, а не просто предъявить ответ.

8. Новая роль преподавателя в эпоху ИИ и новые подходы в обучении

Искусственный интеллект ставит вопрос о новой роли преподавателя. В цифровую эпоху педагог превращается в навигатора и наставника, который уже не является единственным источником знаний (ведь информация доступна через ИИ), но ценен как авторитет в оценке, отборе и этическом применении знаний. Преподавателю можно порекомендовать обучать студентов работать с ИИ-инструментами ответственно: не запрещать их, а интегрировать с четкими правилами.

Преподаватели могут использовать ИИ для повышения качества подготовки к занятиям, для создания разноуровневых материалов (например, перевода текстов для студентов с разным уровнем подготовки), анализа большого числа источников, поиска дополнительных источников и т.д. Таким образом будет формироваться культура кооперации человека и ИИ, где технология дополняет педагога, усиливая эффективность обучения, но не подменяя живое человеческое взаимодействие.

Эффективность применения ИИ во многом зависит от методически грамотного подхода. Важно подчеркнуть, что ИИ — это инструмент в руках педагога, а не замена ему. Роль преподавателя эволю-

ционирует: он становится модератором процесса, следящим за тем, чтобы технологии служили целям обучения, а не искажали их.

Требуется новая цифровая дидактика, учитывающая психологические аспекты: как поддерживать мотивацию в условиях легкого доступа к ответам, как развивать критическое мышление и творчество при наличии алгоритмических помощников. Преподаватель будущего должен не только владеть ИИ-инструментами, но и воспитывать у студентов культуру их ответственного использования, сформировать понимание сильных и слабых сторон этих технологий.

С появлением у студентов «умного помощника» меняется динамика обучения. С одной стороны, возрастает вовлеченность: диалоговые модели обеспечивают интерактивность, мгновенную обратную связь, что позволяет поддерживать интерес к предмету. С другой — возникает риск снижения самостоятельности и критического мышления. Если студент привыкает, что ИИ всегда под рукой с готовым ответом, то снижаются навыки самостоятельного поиска, анализа, нахождения информации и ее проверки.

Задача преподавателя — не допускать деградации обучающихся, стимулировать развитие метакогнитивных навыков (внимания, памяти, мышления), проверки и оценки ответов, полученных от ИИ.

Фактически сегодня искусственный интеллект ставит вопрос о новой роли преподавателя. Педагог превращается в навигатора и наставника, который уже не является единственным источником знаний (ведь информация доступна через ИИ), но ценен как авторитет в оценке, отборе и этическом применении знаний. Преподавателю можно порекомендовать обучать студентов работать с ИИ-инструментами ответственно: не запрещать их, а интегрировать с четкими правилами.

В то же время сами преподаватели могут использовать ИИ для повышения качества подготовки к занятиям, для создания разноуровневых материалов, анализа большого числа источников и т.д. Таким образом может формироваться культура кооперации человека и ИИ, где технология дополняет педагога, усиливая эффективность обучения, но не подменяя живое человеческое взаимодействие.

9. Рекомендации в применении

9.1. Практический пример: использование ИИ в психологическом консультировании и обучении

В качестве авторского примера в психологическом консультировании можно привести использование ИИ для создания гипнотического, нарративного и консультативного контента. ИИ может эффективно выступать в роли помощника при создании текстовых и аудиоматериалов, которые комбинируют подходы с целью достижения синергии, интегрируя

элементы сказкотерапии и нарративных интервенций, обеспечивая включение языковых паттернов и техник, ассоциируемых с НЛП (нейролингвистическим программированием), — в соответствии с замыслом, при обязательной экспертной проверке специалистом и соблюдении этических стандартов консультирования.

После создания этого контента можно использовать ИИ для преобразования частей текста в поэтическую или лирическую форму. В результате образовательный или консультативный контент может быть представлен не просто в виде прозы, а в виде хорошо структурированных рифм, стихов или текстов песен, которые более привлекательны и могут повышать вовлеченность и запоминаемость.

Для полноты мультисенсорного восприятия возможна интеграция инструмента генерации музыки на основе ИИ. Например, Suno — одна из таких платформ, которая, используя приложенный текст песни или тематическую подсказку, может создать соответствующий музыкальный трек.

На практике готовый поэтический текст подается на вход генератора музыки, который сочиняет мелодию и инструментальное сопровождение, соответствующее настроению (например, успокаивающая эмбиентная музыка для гипноза или бодрая мелодия для учебной песни). ИИ обрабатывает гармонию, ритм и даже вокал — при необходимости, создавая аудиофайл, который клиент или студент может воспроизводить в цикле во время сеанса.

Однако, учитывая деликатный характер использования гипноза, НЛП, нарративной психологии и сказкотерапии, производимый ИИ-контент требует тщательной коррекции со стороны специалистов-психологов на каждом этапе создания контента — от определения запроса клиента при консультировании до анализа конечного контента, передаваемого клиенту.

Возможно использование всего вышеперечисленного и в педагогических целях — например, для создания контента, содержимое которого надо надолго и дословно запомнить. Создание такого синтеза текста, аудио и психологических техник вручную было бы сложной задачей, но ИИ позволяет создавать его эффективно, сохраняя при этом качество.

9.2. Процесс создания образовательного контента с помощью ИИ

В данном случае роль профессионала меняется: вместо того чтобы вручную писать каждое предложение, он занимается отбором и доработкой творческого результата ИИ. Происходит переход от создания контента к его отбору и руководству.

Решение о предоставлении контента в виде записываемой аудиодорожки обусловлено принци-

пами обучения и психологического консультирования: многократное прослушивание материала в музыкальной форме может закрепить обучение посредством повторения без усталости, связанной с механическим чтением. Музыка может повышать запоминаемость за счет повторения и эмоциональной окраски материала.

Для студента наличие запоминающейся мелодии в конспектах может превратить утомительное заучивание в приятное занятие — он может начать напевать формулы или определения, тем самым закрепляя материал в памяти с помощью мелодии. В консультативном контексте клиент может регулярно слушать свое персонализированное гипнотическое музыкальное произведение.

При таком подходе эксперт-человек гарантирует, что все соответствует первоначальным целям и этическим стандартам. Стоит проверять правильность образовательного контента и его соответствие заявленным учебным целям. Если какие-либо сгенерированные ИИ факты вызывают сомнения, они перепроверяются или заменяются проверенной информацией (на этом этапе «галлюцинации» недопустимы).

Аналогичным образом проверяются психологические элементы: правильно ли сформулировано гипнотическое внушение? является ли повествование культурно чувствительным и правильно персонализированным? Если что-то не так, можно рекомендовать возвращаться к предыдущим шагам (например, отредактировать текст или скорректировать стиль музыки) и повторить процесс.

Этот итеративный цикл воплощает практику сотрудничества человека и ИИ: ИИ обеспечивает креативность и скорость, а человек — руководство, критическую оценку и ответственность. В конце этого процесса получается готовый пакет материалов для занятия: письменный сценарий (для ознакомления) и аудиофайл для использования клиентом или студентом.

Такой подход может позволить использовать НЛП и алгоритмы рассказывания историй в качестве объективных инструментов для позитивного воздействия на память и мышление.

При этом, вместо того чтобы вручную прорабатывать каждое предложение, педагог курирует материалы, сгенерированные ИИ, обеспечивая их соответствие учебным целям и стандартам качества. Контроль качества становится первостепенным: по мере того как ИИ создает тексты, человек должен проверять и подтверждать точность, актуальность и отсутствие предвзятости, по сути, выступая в роли редактора и этического привратника вклада ИИ.



10. Риски и стратегические аспекты внедрения ИИ в ВПО

Современная дискуссия об ИИ в высшем образовании показывает, что внедрение интеллектуальных технологий в вузе неизбежно сопровождается как ростом эффективности учебного процесса, так и усилением рисков (возможности академического мошенничества, недостаточная защищенность данных, отсутствие эмпатии при полной замене человека ИИ, вопросы ответственности и цифровой этики), что требует сохранения контроля и ответственности человека в образовательном контуре [14].

При этом более широкий междисциплинарный взгляд на эволюцию ИИ фиксирует необходимость комплексной стратегии, включающей подготовку кадров, безопасность данных и этические стандарты использования технологий, ориентированной на эффективное освоение потенциала ИИ и минимизацию сопутствующих рисков [15].

Наконец, исследования внедрения ИИ в высокорисковых организационных системах подчеркивают, что правовое регулирование и организационно-кадровое обеспечение могут не успевать за технологическим прогрессом, а значит, устойчивое внедрение требует синхронизации нормативной базы и регламентов, управленческих процедур, а также механизмов контроля человека и ответственности при применении интеллектуальных систем — методически релевантных и для

университетского управления, образовательной аналитики и цифровой трансформации ВПО [16].

Практическая реализуемость трансформации системы ВПО во многом определяется тем, как университет институционализирует новые функции преподавателя и выстраивает контуры верификации результатов, получаемых с применением ИИ [17].

ВЫВОДЫ

ИИ может использоваться как помощник для решения разных задач, например, для поиска литературы или чернового планирования ответа, но с обязательной самостоятельной доработкой и ссылкой на источники информации. Студенты должны осознавать, что использование ИИ — не запрещенный прием, но требующий раскрытия и критической оценки.

При корректном внедрении ИИ может стать мощным ресурсом, повышающим качество образования, расширяющим индивидуальные траектории обучения и усиливающим роль преподавателя как наставника и исследователя. Совмещение образовательной и предметной аналитики на базе ИИ с человеческой эмпатией и мудростью педагога станет залогом того, что цифровая трансформация приведет к позитивным изменениям в высшем образовании, подготовив выпускников к жизни и работе в информационно насыщенном обществе будущего.

СПИСОК ИСТОЧНИКОВ

1. Иванова С.В., Азархин А.В. Модель использования искусственного интеллекта в образовательном процессе вузов. *Концепт*. 2025;09:303-317. URL: <https://doi.org/10.24412/2304-120X-2025-11189>
2. Давыдов С.Г., Матвеева Н.Н., Адемукова Н.В., Вичканова А.А. Искусственный интеллект в российском высшем образовании: текущее состояние и перспективы развития. *Университетское управление: практика и анализ*. 2024;28 (3):32-44. URL: <https://doi.org/10.15826/umpra.2024.03.023>
3. Коротеев М.В., Марунько А.С., Романова Е.В., Чулина Н.Ю. Методы машинного обучения для извлечения ключевых слов из учебных и официальных материалов. *Инновации и инвестиции*. 2025;(7):611-615. URL: <https://elibrary.ru/seinwu>
4. Абашин В.Г., Загородних Н.А., Преснецова В.Ю. Перспективы использования нейросетей в процессе совершенствования управления коммерческими организациями. *Информационные системы и технологии*. 2024;142(2):21-27. URL: <https://elibrary.ru/vcaaef>
5. Косарев В.Е., Миловидов В.И. Об использовании методов машинного обучения для обработки информационных потоков интернет-эквайринга коммерческого банка. *Инновации и инвестиции*. 2025;(1):502-507. URL: <https://elibrary.ru/vttiop>
6. Догадина Е.П., Бочаров М.И. Автоматизация процесса составления рабочих программ дисциплин с использованием виртуального ассистента для работы с нейросетью. *Стандарты и мониторинг в образовании*. 2025;13(3):64-69. URL: <https://doi.org/10.12737/1998-1740-2025-13-3-64-69>
7. Гобарева Я.Л., Городецкая О.Ю. XBRL как инструмент формирования управленческой отчетности. В сб.: *Актуальные проблемы бухгалтерского учета, анализа, контроля и налогообложения*. М.: Русайнс; 2025. URL: <https://elibrary.ru/pqtvng>
8. Авраменко А.Д., Судаков В.А. Метод генерации обучающей выборки для машинного обучения в задаче коммивояжера. В сб.: *Авиация и космонавтика*. М.: Издательство «Перо»; 2024. URL: <https://elibrary.ru/pwsykn>

9. Хасанов И.И., Хасанова З.Р. Применение машинного обучения на графах для построения рекомендательных систем, учитывающих индивидуальность пользователей. *Современные наукоемкие технологии*. 2025;(6):54-61. URL: <https://doi.org/10.17513/snt.40422>
10. Журавков А.А., Лабинцев А.И. Определение динамических характеристик удара в единоборствах с помощью рекуррентных нейронных сетей. В сб.: *Нейрокомпьютеры и их применение*. М.: МГППУ; 2022. URL: <https://elibrary.ru/wrfuko>
11. Кублик Е.И., Лабинцев А.И., Чипчагов М.С., Шилов М.А. Повышение эффективности рекламных кампаний на радио путем интеграции с цифровыми инструментами мониторинга. *Гуманитарные науки. Вестник Финансового университета*. 2023;13(5):121-128. URL: <https://doi.org/10.26794/2226-7867-2023-13-5-121-128>
12. Будаев Е.С. Разработка веб-приложения интеллектуального анализа отзывов клиентов с применением модифицированной модели seq2seq с механизмом внимания. *Computational Nanotechnology*. 2024;11(1):151-161. URL: <https://doi.org/10.33693/2313-223X-2024-11-1-151-161>
13. Жолобова Г.Н., Сеницына Е.Д. Применение машинного обучения для анализа лояльности сотрудников на основе текстовых отзывов. *Нейрокомпьютеры: разработка, применение*. 2024;26(6):76-85. URL: <https://elibrary.ru/wminjg>
14. Седых И.Ю., Хрипунова М.Б. Технологии искусственного интеллекта в современном высшем образовании России. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(1):20-27. URL: <https://www.digitarin.ru/jour/article/view/4/4>
15. 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. URL: <https://www.digitarin.ru/jour/article/view/14/14>
16. Когтева А.Н. Перспективные направления применения искусственного интеллекта в оборонно-промышленном комплексе. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(2):58-63. URL: <https://www.digitarin.ru/jour/article/view/13/13>
17. Григорьев С.М. Преподаватель высшей школы в эпоху искусственного интеллекта и цифровой трансформации. *Человеческий капитал*. 2026;1(205):40-50. URL: <https://elibrary.ru/wvagfg>

REFERENCES

1. Ivanova S.V., Azarkhin A.V. The model of using artificial intelligence in the educational process of universities. *Concept*. 2025;09:303-317. (In Russ.). URL: <https://doi.org/10.24412/2304-120X-2025-11189>
2. Davydov S.G., Matveeva N.N., Ademukova N.V., Vichkanova A.A. Artificial intelligence in Russian higher education: current state and development prospects. *University management: Practice and Analysis*. 2024;28(3):32-44. (In Russ.). URL: <https://doi.org/10.15826/umpa.2024.03.023>
3. Koroteev M.V., Marunko A.S., Romanova E.V., Chulina N. Yu. Machine learning methods for extracting keywords from educational and official materials. *Innovation and Investment*. 2025;(7):611-615. (In Russ.). URL: <https://elibrary.ru/seinwu>
4. Abashin V.G., Zagorodnih N.A., Presnetsova V. Yu. Prospects of using neural networks in the process of improving the management of commercial organizations. *Information Systems and Technologies*. 2024;142(2):21-27. (In Russ.). URL: <https://elibrary.ru/vcaaeef>
5. Kosarev V.E., Milovidov V.I. On the use of machine learning methods for processing information flows of Internet acquiring of a commercial bank. *Innovation and Investment*. 2025;(1):502-507. (In Russ.). URL: <https://elibrary.ru/vttiop>
6. Gugadina E.P., Bocharov M.I. Automation of the process of compiling work programs for disciplines using a virtual assistant to work with a neural network. *Standards and Monitoring in Education*. 2025;13(3):64-69. (In Russ.). URL: <https://doi.org/10.12737/1998-1740-2025-13-3-64-69>
7. Gobareva Ya.L., Gorodetskaya O.Y. XBRL as a management reporting tool. In the collection: *Actual problems of accounting, analysis, control and taxation*. Moscow: Rusains; 2025. (In Russ.). URL: <https://elibrary.ru/pqtvng>
8. Avramenko A.D., Sudakov V.A. The method of generating a training sample for machine learning in the traveling salesman problem. In the collection: *Aviation and Cosmonautics*. Moscow: Pero Publishing House; 2024. (In Russ.). URL: <https://elibrary.ru/pwsykn>
9. Khasanov I.I., Khasanova Z.R. The use of machine learning on graphs to build recommendation systems that take into account the individuality of users. *Modern High-tech Technologies*. 2025;(6):54-61. (In Russ.). URL: <https://doi.org/10.17513/snt.40422>



10. Zhuravkov A.A., Labintsev A.I. Determination of the dynamic characteristics of a blow in martial arts using recurrent neural networks. In: *Neurocomputers and their applications*. Moscow: MGPPU; 2022. (In Russ.). URL: <https://elibrary.ru/wrfuko>
11. Kublik E.I., Labintsev A.I., Chipchagov M.S., Shilov M.A. Improving the effectiveness of advertising campaigns on radio through integration with digital monitoring tools. *Humanities. Bulletin of the Financial University*. 2023; 13(5):121-128. (In Russ.). URL: <https://doi.org/10.26794/2226-7867-2023-13-5-121-128>
12. Budaev E.S. Development of a web application for the intelligent analysis of customer reviews using a modified seq2seq model with an attention mechanism. *Computational Nanotechnology*. 2024;11(1):151-161. (In Russ.). URL: <https://doi.org/10.33693/2313-223X-2024-11-1-151-161>
13. Zholobova G.N., Sinitsyna E.D. The use of machine learning to analyze employee loyalty based on text reviews. *Neurocomputers: Development, Application*. 2024;26(6):76-85. (In Russ.). URL: <https://elibrary.ru/wminjg>
14. Sedykh I.Yu., Khripunova M.B. Artificial intelligence technologies in modern higher education in Russia. *Digital solutions and artificial intelligence technologies*. 2025;1(1):20-27. (In Russ.). URL: <https://www.digitarin.ru/jour/article/view/4/4>
15. Salnikov E.A., Muminova S.R. The evolution of artificial intelligence: from modern technologies to future innovations. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(2):64-71. (In Russ.). URL: <https://www.digitarin.ru/jour/article/view/14/14>
16. Kogteva A.N. Promising areas of application of artificial intelligence in the military-industrial complex. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(2):58-63. (In Russ.). URL: <https://www.digitarin.ru/jour/article/view/13/13>
17. Grigoriev S.M. Higher school teacher in the era of artificial intelligence and digital transformation. *Human Capital*. 2026;1(205):40-50. (In Russ.). URL: <https://elibrary.ru/wvagfg>

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Сергей Александрович Румянцев — кандидат педагогических наук, доцент кафедры информационных технологий факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Sergey A. Rumyantsev — Cand. Sci. (Ped.), Assoc. Prof. of 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/0009-0002-9366-8503>

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

Юрий Владимирович Полищук — доктор технических наук, доцент, профессор кафедры системного программирования, Московский технический университет связи и информатики, Москва, Российская Федерация

Yuri V. Polishchuk — Dr. Sci. (Eng.), Assoc. Prof., Prof. Department of Systems Programming, Moscow Technical University of Communications and Informatics, Moscow, Russian Federation

<https://orcid.org/0000-0003-0245-5052>

Youra_Polishchuk@bk.ru

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

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

Статья поступила 19.01.2026; после рецензирования 02.03.2026; принята к публикации 13.03.2026.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 19.01.2026; revised on 02.03.2026 and accepted for publication on 13.03.2026.

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

DOI: 10.26794/3030-7097-2026-2-2-16-24
УДК 004.891:37(045)

Интеллектуальные рекомендательные системы в образовании. Алгоритмы подбора индивидуальных траекторий обучения

А.В. Овсянникова

Финансовый университет при Правительстве Российской Федерации Москва, Российская Федерация

АННОТАЦИЯ

Цифровая трансформация системы образования привела к значительному росту данных об учебной активности, что создало технологические предпосылки для внедрения интеллектуальных рекомендательных систем (ИРС). Однако коммерческие рекомендательные алгоритмы, оптимизированные на максимизацию вовлеченности и прибыли, не могут быть напрямую перенесены в образовательную среду, где главной целевой функцией выступает повышение качества усвоения знаний и снижение академической неуспешности. **Цель.** Разработать концептуальную модель интеллектуальной рекомендательной системы для формирования индивидуальных образовательных траекторий, объединяющую гибридные алгоритмы с механизмами объяснимого искусственного интеллекта и встроенными средствами этического контроля. **Методы.** Исследование базируется на систематическом обзоре рецензируемых публикаций за 2021–2025 гг., индексируемых в Scopus, Web of Science и РИНЦ. Применены методы сравнительного анализа алгоритмов рекомендаций, архитектурного моделирования, а также экспериментальная валидация на открытых образовательных датасетах. **Результаты.** Предложена четырехуровневая архитектура ИРС, включающая уровень сбора данных, уровень обработки и векторизации, алгоритмическое ядро на основе гибридной модели и уровень взаимодействия с модулем объяснения рекомендаций. Экспериментально установлено, что предложенная гибридная модель превосходит классическую коллаборативную фильтрацию по точности на 13% и решает проблему «холодного старта» за счет семантического анализа новых курсов. Разработанный модуль объяснений, использующий метод LIME (Local Interpretable Model-agnostic Explanations), позволяет визуализировать факторы, повлиявшие на каждую рекомендацию, что повышает доверие со стороны преподавателей и студентов. **Выводы.** Полученные результаты согласуются с выводами ведущих зарубежных исследователей о преимуществе гибридных графовых моделей перед чисто коллаборативными подходами. В отличие от известных решений, предложенная модель включает встроенный этический блок проверки справедливости и ориентирована на интеграцию с российскими системами управления обучением.

Ключевые слова: интеллектуальные рекомендательные системы; персонализация обучения; индивидуальная образовательная траектория; гибридные алгоритмы; графовые нейронные сети; образовательная аналитика; объяснимый искусственный интеллект

Для цитирования: Овсянникова А.В. Интеллектуальные рекомендательные системы в образовании. Алгоритмы подбора индивидуальных траекторий обучения. *Цифровые решения и технологии искусственного интеллекта*. 2026;2(2):16-24. DOI: 10.26794/3030-7097-2026-2-2-16-24

ORIGINAL PAPER

Intelligent Recommender Systems in Education. Algorithms for Personalised Learning Pathways

A.V. Ovsyannikova

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

ABSTRACT

The digital transformation of education has led to exponential growth in learning activity data, creating technological prerequisites for the implementation of intelligent recommender systems (IRS). However, commercial recommendation algorithms optimised for maximising engagement and profit cannot be directly transferred to the educational environment, where the main objective function is to improve the quality of knowledge acquisition and reduce academic failure. **Aim.** To develop a conceptual model of an intelligent recommender system with explainable artificial intelligence mechanisms and built-in ethical control tools. **Methods.** The research is based on a systematic review of peer-reviewed publications

for 2021–2025 indexed in Scopus, Web of Science, and RSCI. Methods of comparative analysis of recommendation algorithms, architectural modelling, and experimental validation on open educational datasets. **Results.** A four-level IRS architecture is proposed, comprising a data collection layer, a processing and vectorisation layer, an algorithmic core based on a hybrid model, and an interaction layer with a recommendation explanation module. Experiments have shown that the proposed hybrid model outperforms classical collaborative filtering by 13% in precision and solves the cold-start problem through semantic analysis of new courses. The developed explanation module, based on the LIME method, visualises the factors influencing each recommendation, thereby increasing trust among teachers and students.

Conclusions. The results are consistent with the findings of leading international researchers on the advantages of hybrid graph models over purely collaborative approaches. Unlike known solutions, the proposed model includes a built-in fairness checking block and is designed for integration with Russian learning management systems.

Keywords: intelligent recommender systems; learning personalization; individual learning trajectory; hybrid algorithms; graph neural networks; learning analytics; explainable artificial intelligence

Для цитирования: Ovsyannikova A.V. Intelligent recommender systems in education. Algorithms for selecting individual individual educational trajectories. *Digital solutions and artificial intelligence technologies*. 2026;2(2):16-24. DOI:10.26794/3030-7097-2026-2-2-16-24

ВВЕДЕНИЕ

Современная система образования переживает фундаментальную трансформацию, обусловленную массовой цифровизацией и внедрением технологий искусственного интеллекта. Образовательные организации всех уровней от школ до университетов накапливают огромные массивы данных, логи активности в системах управления обучением LMS, результаты тестирований, время выполнения заданий, посещаемость, взаимодействие с форумами и многое другое. По данным аналитических отчетов, глобальный рынок образовательной аналитики и адаптивного обучения достиг 15,2 млрд долл. в 2024 г. и демонстрирует ежегодный рост около 19%. Этот массив данных создает технологическую основу для применения методов машинного обучения, и в частности, рекомендательных систем, которые способны автоматизировать подбор учебных материалов и формировать индивидуальные образовательные траектории.

Персонализация обучения давно признана ключевым фактором повышения его эффективности. Традиционная модель «единой учебной программы» не учитывает различий в темпе освоения материала, когнитивных стилях, предыдущих знаниях и индивидуальных интересах учащихся. Как отмечают зарубежные источники, внедрение искусственного интеллекта в высшее образование открывает новые возможности для адаптации учебного процесса, но одновременно порождает риски, связанные с этикой и интерпретируемостью алгоритмов. Интеллектуальные рекомендательные системы призваны динамически формировать учебный маршрут, предлагая курсы, модули и задания, которые наилучшим образом соответствуют текущему уровню знаний и целям конкретного студента.

Однако большинство существующих рекомендательных алгоритмов были разработаны для коммерческих приложений, электронной коммерции, видеосервисов, социальных сетей. В этих доменах целевая функция сводится к максимизации вовлеченности

пользователя, времени пребывания на платформе или вероятности покупки. В образовании же главным результатом должно быть устойчивое усвоение знаний, развитие критического мышления и снижение доли отчислений. Прямой перенос коммерческих алгоритмов в образование приводит к ряду негативных эффектов. Во-первых, возникает «пузырь фильтра», когда студенту рекомендуются только те курсы, которые совпадают с его текущими интересами, без выхода на новые, неизвестные дисциплины. Во-вторых, алгоритмы глубокого обучения часто остаются «черными ящиками», ни преподаватель, ни студент не понимают, почему предложен тот или иной модуль. В-третьих, существуют серьезные этические риски, алгоритмы могут усиливать существующее неравенство или нарушать конфиденциальность персональных данных [1, 2].

Анализ научной литературы за последние пять лет показывает, что, несмотря на значительное число публикаций по персонализации обучения, отсутствует унифицированная архитектура интеллектуальной рекомендательной системы, которая одновременно удовлетворяла бы педагогическим, техническим и этическим требованиям. Систематический обзор Klačnja-Milićević et al. выявил, что большинство существующих решений фокусируется либо на точности рекомендаций в ущерб интерпретируемости, либо на отдельных аспектах, таких как прогнозирование успеваемости, но не предлагают целостной модели. Особенно остро эта проблема стоит в контексте российских образовательных стандартов и платформ, где требуется интеграция с LMS Moodle, Stepik [3], а также соблюдение Федерального закона от 27.07.2006 № 152-ФЗ «О персональных данных»¹.

Таким образом, проблема исследования заключается в отсутствии научно обоснованной, экспериментально подтвержденной модели интеллектуальной рекомендательной системы, которая была бы адап-

¹ URL: <https://base.garant.ru/12148567/>

тирована к специфике образования, обеспечивала высокую точность рекомендаций, их интерпретируемость и этическую безопасность. Новизна работы состоит в предложении гибридной архитектуры, объединяющей графовые нейронные сети, контентный анализ на основе BERT и встроенные механизмы объяснимого ИИ, а также в адаптации модели под российские образовательные платформы.

СОВРЕМЕННОЕ СОСТОЯНИЕ ИССЛЕДОВАНИЙ В ОБЛАСТИ ОБРАЗОВАТЕЛЬНЫХ РЕКОМЕНДАТЕЛЬНЫХ СИСТЕМ

Эволюция подходов к персонализации обучения с использованием искусственного интеллекта насчитывает несколько десятилетий. Первые системы «интеллектуальных тьюторов», появившиеся в 1980–1990-х гг., основывались на экспертных правилах и моделях предметной области. Адаптация в них заключалась в изменении последовательности учебных заданий в зависимости от правильности ответов студента. Однако, как подчеркивает обзор зарубежных авторов, такие системы требовали огромных усилий на формализацию знаний и плохо масштабировались на разные дисциплины. С началом 2000-х гг., с развитием методов машинного обучения и анализа больших данных, произошел переход от экспертных систем к статистическим и нейросетевым подходам [4–8].

В современной научной литературе выделяются три основные парадигмы построения рекомендательных систем в образовании. Коллаборативная фильтрация основана на поиске студентов со схожими профилями активности или оценок. Если два студента одинаково оценили одни и те же курсы, то курс, понравившийся одному из них, с высокой вероятностью понравится и другому. Математически предсказание оценки вычисляется как взвешенное среднее оценок соседей. Однако у этого подхода есть серьезные недостатки: проблема «холодного старта»; для нового студента или нового курса нет данных; разреженность матрицы взаимодействий; большинство студентов прошли лишь малую долю всех курсов; отсутствие интерпретируемости; рекомендация не сопровождается объяснением, почему выбран именно этот курс.

Контентно ориентированные подходы, напротив, анализируют свойства самих образовательных ресурсов: описания курсов, аннотации, ключевые слова, компетенции. Векторное представление курса строится с помощью методов обработки естественного языка от классического TF-IDF до современных нейросетевых эмбедингов. Профиль студента формируется на основе курсов, которые он уже успешно освоил. Рекомендация представляет

собой поиск курсов, семантически близких к профилю. Достоинство метода заключается в возможности работы с новыми курсами, не имеющими оценок. Недостаток — это игнорирование коллективного опыта других студентов и, как следствие, более низкая точность по сравнению с коллаборативной фильтрацией при достаточном объеме данных.

Именно поэтому наибольшую эффективность демонстрируют гибридные алгоритмы, сочетающие оба подхода. Классическим примером является матричная факторизация, где матрица взаимодействий студентов и курсов раскладывается на произведение двух матриц меньшей размерности, латентных векторов студентов и курсов. В последние годы все большее распространение получают графовые нейронные сети. В этих моделях строится гетерогенный граф, вершинами которого являются студенты, курсы, учебные понятия, а ребрами взаимодействия, например, изучение курса, успешное выполнение задания, связь «курс-понятие». Рекомендация формулируется как задача предсказания вероятности существования ребра между студентом и курсом. Графовые модели позволяют учитывать сложные многоуровневые зависимости и повышают точность рекомендаций на 15–20% по сравнению с матричной факторизацией.

Наряду с совершенствованием самих алгоритмов, сегодня все больше внимания уделяется проблемам интерпретируемости получаемых решений и их этической обоснованности. В условиях образовательного процесса особенно ценно, когда у преподавателя есть возможность доступно пояснить студенту, на основании каких соображений система выдала ту или иную рекомендацию. Такой подход не только укрепляет доверие к цифровому инструменту, но и предотвращает ситуации, когда алгоритм неоправданно сужает кругозор обучающегося, «замыкая» его на ограниченном наборе тем. Технологии так называемого объяснимого искусственного интеллекта, например метод LIME, дают возможность выделить ключевые признаки, оказавшие решающее влияние на формирование конкретного совета. Как подчеркивают Holstein и его коллеги, наиболее результативной в данном контексте признается гибридная схема «человек + ИИ», здесь педагог выступает в роли наставника, который осмысляет и комментирует выданные системой предложения, а искусственный интеллект берет на себя всю рутинную аналитическую работу [9].

Анализ публикаций российских авторов показал, что большинство работ сосредоточено на прогнозировании успеваемости или аналитике больших данных, в то время как целостные модели рекомендательных систем, учитывающие педагогический контекст и этические нормы, представлены недостаточно [10, 11].



АЛГОРИТМИЧЕСКАЯ ОСНОВА ИНТЕЛЛЕКТУАЛЬНЫХ РЕКОМЕНДАТЕЛЬНЫХ СИСТЕМ В ОБРАЗОВАНИИ

Для построения эффективной рекомендательной системы в образовательной среде необходимо понимание сильных и слабых сторон различных классов алгоритмов. Рассмотрим их более подробно, избегая схематичного перечисления.

Коллаборативная фильтрация опирается на предположение, что если студент u имел схожие с другим студентом v оценки по ряду курсов, то и по новому курсу их оценки будут близки. Формально сходство между двумя студентами A и B вычисляется как косинус угла между их векторами оценок:

$$\text{sim}(A, B) = (A \cdot B) / (||A|| \times ||B||),$$

где $A \cdot B$ — скалярное произведение векторов, а $||A||$ и $||B||$ — их евклидовы нормы, где A и B — векторы оценок студентов. Несмотря на концептуальную простоту, на практике этот метод сталкивается с проблемой «холодного старта», для нового студента, не оценившего ни одного курса, невозможно найти соседей. Кроме того, матрица взаимодействий «студент-курс» крайне разрежена в типичном университете студент проходит 10–20 курсов из сотен доступных. Это приводит к тому, что многие пары «студент-курс» не имеют оценок, и алгоритм дает ненадежные предсказания.

Один из существенных недостатков коллаборативной фильтрации — это игнорирование смыслового наполнения учебных материалов. Вследствие этого два совершенно непохожих по своей тематике курса могут быть признаны «схожими» исключительно на том основании, что они получили высокие оценки от одной и той же группы обучающихся. Подобная ситуация далеко не всегда является педагогически обоснованной.

Альтернативный класс алгоритмов, контентно ориентированные подходы, свободен от указанных ограничений, поскольку опирается на прямые и явные характеристики курсов. Каждый курс представляется в виде признакового вектора. В его роли может выступать, например, вектор частот ключевых слов либо плотный эмбединг, извлеченный из предварительно обученной нейросетевой архитектуры.

Что касается построения профиля студента, то он вычисляется как усредненный вектор тех курсов, которые обучающийся уже успешно завершил. Рекомендательный механизм в таком случае сводится к поиску курсов, для которых значение косинусного расстояния до полученного профиля оказывается минимальным.

Данный метод демонстрирует высокую эффективность при работе с новыми курсами, при этом

проблема «холодного старта» снимается автоматически. Кроме того, контентный подход обеспечивает возможность прозрачного пояснения рекомендаций. Типичный пример формулировки: «Данный курс предлагается вам, поскольку его ключевые термины совпадают с теми, что встречались в уже освоенных вами дисциплинах». Однако его точность обычно ниже, чем у коллаборативной фильтрации, поскольку он игнорирует коллективное мнение тысяч других студентов.

Гибридные модели пытаются объединить преимущества обоих подходов. Классическим примером является матричная факторизация SVD++, которая дополняет латентные векторы студентов и курсов информацией об имплицитных взаимодействиях, например, факт просмотра страницы курса, даже если студент его не оценил. Уравнение предсказания включает глобальное среднее, смещения студента и курса, а также скалярное произведение латентных векторов, к которому добавляется нормализованная сумма векторов имплицитных отзывов. Такая модель обучается с помощью стохастического градиентного спуска, минимизируя среднеквадратичную ошибку на известных оценках.

Более современным направлением являются графовые нейронные сети GNN, в частности, реляционные RGCN. В этой парадигме образовательная экосистема представляется как гетерогенный граф с несколькими типами вершин: студенты, курсы, понятия, преподаватели, и ребер, изучение, включает понятие, преподает и т.д. Каждый тип ребер имеет свою матрицу преобразования. Сообщения между вершинами распространяются через сверточные слои, и на выходе каждый студент и каждый курс получают обновленные эмбединги, учитывающие структуру всего графа. Вероятность того, что студенту u понравится курс i , вычисляется как сигмоида от скалярного произведения их эмбедингов. Преимущество GNN заключается в способности моделировать транзитивные зависимости, если студент A похож на студента B , а B изучил курс C , то A может заинтересоваться C , даже если прямых связей между A и C нет. Кроме того, в граф можно легко включать дополнительные сущности, например, учебные цели, профессиональные компетенции, что делает модель прозрачной для педагогов.

Важно отметить, что выбор конкретного алгоритма зависит от объема доступных данных и требований к интерпретируемости. Для небольших университетских курсов с числом студентов менее тысячи может оказаться достаточной коллаборативная фильтрация. Для масштабных онлайн-платформ с миллионами пользователей предпочтительны графовые модели, которые, однако, требуют значитель-

ных вычислительных ресурсов. В любом случае, как показывают эксперименты, гибридные подходы стабильно превосходят «чистые» методы по метрикам точности и полноты [11, 12].

ПРЕДЛАГАЕМАЯ МОДЕЛЬ ИНТЕЛЛЕКТУАЛЬНОЙ РЕКОМЕНДАТЕЛЬНОЙ СИСТЕМЫ

Разработанная в рамках данного исследования модель интеллектуальной рекомендательной системы для образования имеет четырехуровневую архитектуру, каждый уровень которой выполняет строго определенные функции. Такой подход обеспечивает модульность, масштабируемость и возможность поэтапного внедрения.

Первый уровень — сбор и хранение данных.

Он аккумулирует информацию из разнородных источников. К ним относятся, во-первых, академические показатели, оценки за экзамены, баллы за домашние задания. Во-вторых, логи активности в LMS, время, проведенное на странице курса, количество попыток выполнения теста, участие в форумах, просмотр видеолекций. В-третьих, данные анкетирования, интересы студента, планируемая профессиональная траектория, предпочитаемые форматы обучения. В-четвертых, образовательные стандарты и компетенции. Все данные хранятся в реляционной базе данных с соблюдением требований анонимизации, персональные идентификаторы заменяются на хешированные ключи.

Второй уровень — предобработка и векторизация. Сырые данные очищаются от выбросов и пропусков, нормализуются. Для текстового контента, аннотации курсов, описания компетенций, постов на форумах применяется модель EduBERT, версия BERT, дообученная на корпусе образовательных текстов, это учебники, научные статьи по педагогике, методические материалы. Это позволяет получить плотные векторные представления курсов, устойчивые к синонимии и многозначности терминов. Параллельно строится граф знаний, где вершинами являются курсы, а ребрами связи типа «является предпосылкой для», «дополняет», «альтернатива». Такой граф может быть построен полуавтоматически на основе учебных планов и экспертной оценки преподавателей. На выходе этого уровня каждый студент представлен вектором в латентном пространстве, при этом начальный профиль может быть задан диагностическим тестом, а каждый курс двумя векторами, один из семантической модели EduBERT и один из графа знаний.

Третий уровень — алгоритмическое ядро.

Здесь реализована гибридная модель, объединяющая матричную факторизацию, контентную

близость и графовую нейронную сеть. Базовым является предсказание матричной факторизации с дополнительными признаками:

$$r_{ui} = \mu + b_u + b_i + q_i \cdot p_u + \frac{q_i}{|N(u)|} \cdot \sum_{j \in N(u)} y_j,$$

где μ — глобальное среднее; b_u и b_i — смещения студента и курса; p_u и q_i — латентные векторы; y_j — вектор имплицитного взаимодействия, например, факт просмотра; $N(u)$ — множество курсов, с которыми студент взаимодействовал неявно.

К этому базовому предсказанию добавляется штраф за отклонение семантической близости, если вектор курса из EduBERT близок к профилю студента, а матричная факторизация дает низкую оценку, то оценка повышается. Кроме того, используется графовая нейронная сеть RGCN для распространения информации по связям «курс-предпосылка». Итоговая вероятность того, что курс i^* будет рекомендован конкретному студенту u^* , определяется как линейная комбинация трех составляющих с присвоенными весами. В роли этих составляющих выступают: коллаборативный компонент (реализованный через матричную факторизацию), контентный (косинусная мера близости) и графовый (значение на выходе модели RGCN). Оптимальные значения весов подбираются по результатам анализа валидационной выборки.

Процедура обучения модели опирается на функцию потерь типа BPR, основная задача которой максимизировать разрыв между предсказанными рейтингами для позитивных и негативных примеров. Чтобы ускорить процесс обучения при работе с крупными массивами данных, используется стохастический градиентный спуск с мини-батчевой организацией выборки. Настройка гиперпараметров, включая размерность латентного пространства, число слоев в RGCN и коэффициент регуляризации, осуществляется методом перебора по сетке.

Следующий, **четвертый уровень архитектуры** отвечает за организацию взаимодействия с пользователем и пояснение полученных рекомендаций. Данный уровень включает в себя API для подключения к различным системам управления обучением LMS, таким как Moodle, Blackboard или Stepik, а также пользовательский интерфейс, предназначенный для студентов и преподавателей. Центральное место здесь занимает модуль интерпретации рекомендаций, построенный на базе метода LIME. Для каждого случая рекомендации этот модуль строит локальную аппроксимирующую модель в окрестности рассматриваемой пары «студент-курс», после чего вычисляет степень влияния каждого отдельного признака. В результате студент получает пояснение следующего вида: «Курс «Алгоритмы и структуры данных» предложен



вам по следующим причинам: (1) ранее вы успешно освоили курс «Основы программирования» (вклад фактора — 60%); (2) другие обучающиеся, имеющие схожий профиль, тоже выбирали этот курс (вклад — 25%); (3) вы заявили о заинтересованности в теме «Искусственный интеллект», а данный курс является для нее предварительным условием (вклад — 15%)». Что касается преподавателя, он имеет возможность просматривать сводную статистику по всей учебной группе и, если потребуется, вносить коррективы в весовые коэффициенты отдельных компонентов.

Построение персональной образовательной траектории носит итерационный характер. На этапе первого входа в систему студент выполняет краткое диагностическое тестирование, на основе которого формируется его начальный профиль знаний. В дальнейшем, в процессе обучения, система фиксирует такие показатели, как результаты решения заданий, временные затраты на прохождение каждого модуля, а также количество допущенных ошибок. Актуализация профиля студента происходит в соответствии с адаптивным правилом: вектор p_i смещается по направлению градиента функции потерь, причем величина шага пропорциональна разнице между реально полученным результатом и предсказанным значением.

Это позволяет системе «учиться вместе со студентом» и подстраивать рекомендации при изменении его уровня знаний или интересов.

ЭКСПЕРИМЕНТАЛЬНАЯ ВАЛИДАЦИЯ МОДЕЛИ НА РОССИЙСКИХ ОБРАЗОВАТЕЛЬНЫХ ПЛАТФОРМАХ

Для проверки эффективности предложенной гибридной модели были проведены эксперименты на данных, собранных с российских образовательных платформ. В качестве первого источника использовалась система управления обучением на базе Moodle. Массив данных включал обезличенные логи учебной активности 827 студентов за два семестра, а также информацию о 45 курсах от дисциплин математического цикла до программирования. Вторым источником выступила платформа Stepik, содержащая результаты прохождения обучающимися курсов по языкам программирования, анализу данных и машинному обучению. Все персональные данные были анонимизированы в соответствии с требованиями Федерального закона от 27.07.2006 № 152-ФЗ «О персональных данных».

Сравнительному анализу подверглись три класса алгоритмов: классическая коллаборативная фильтрация на основе косинусного сходства, метод матричной факторизации и предложенная гибридная модель. Оценка качества проводилась по схеме пя-

тикатной кросс-валидации с разбиением выборки в процентах на обучающую (80), валидационную (10) и тестовую (10) части. В ходе экспериментальной оценки применялись три метрики. Первая — это процент релевантных (полезных) курсов в списке из первых десяти позиций. Вторая метрика отражает, какая доля от общего объема действительно подходящих курсов была успешно обнаружена системой. Третья, ранжирующий показатель, который штрафует расположение полезного курса ближе к концу списка, чем выше в перечне находится ценный для студента курс, тем лучше итоговое значение.

Проведенные эксперименты подтвердили стабильное преимущество гибридной архитектуры по сравнению с другими методами. На наборе данных из среды Moodle для предложенной модели процент полезных курсов среди первых десяти позиций достиг 0,54. Для сравнения, метод матричной факторизации дал результат 0,46, а традиционная коллаборативная фильтрация 0,41. Следовательно, выигрыш в точности относительно классического подхода составил 13%. Что касается полноты, доли обнаруженных полезных курсов от общего числа подходящих, то здесь значение выросло с 0,29 у коллаборативной фильтрации до 0,38 у гибридной модели. Показатель качества ранжирования, учитывающий порядок следования рекомендаций, также увеличился с 0,32 до 0,41.

Предложенный подход позволяет эффективно решать проблему «холодного старта» применительно к новым курсам, по которым еще отсутствуют какие-либо оценки пользователей.

В сценарии, где 20% курсов были исключены из обучающей выборки, коллаборативная фильтрация не могла сформировать для них ни одной рекомендации, а метод матричной факторизации давал предсказания, близкие к случайным. Предложенная модель, благодаря использованию семантических векторных представлений из языковой модели EduBERT, обеспечила для новых курсов долю полезных рекомендаций среди первых десяти на уровне 0,32, что сопоставимо с качеством рекомендаций для курсов, присутствовавших в обучающей выборке.

Дополнительно была проведена субъективная оценка полезности рекомендаций с участием 50 студентов Финансового университета при Правительстве РФ. Участникам предлагалось оценить по пятибалльной шкале, в какой степени предложенные курсы соответствуют их образовательным целям. Средняя оценка для рекомендаций, сгенерированных гибридной моделью, составила 4,2 балла, для матричной факторизации 3,7 баллов; для коллаборативной фильтрации 3,3 балла. Студенты также отметили, что наличие пояснений к рекомендациям, реализованных с помощью метода LIME, повышает их доверие

к системе и способствует более осознанному выбору образовательной траектории.

Полученные результаты свидетельствуют о применимости предложенной гибридной модели в условиях российских образовательных платформ. Модель демонстрирует устойчивую работу как на данных традиционных системах управления обучением, так и на данных массовых открытых онлайн-курсов. При этом вычислительные затраты не превышают возможностей типовых серверов, используемых в российских университетах. Основным ограничением остается гетерогенность форматов хранения учебной активности в различных образовательных организациях, что требует дополнительной работы по унификации данных перед внедрением системы [13, 14].

ЭТИЧЕСКИЕ И ПЕДАГОГИЧЕСКИЕ АСПЕКТЫ ВНЕДРЕНИЯ

Внедрение искусственного интеллекта в образование не может ограничиваться только техническими и экономическими соображениями. Необходим тщательный анализ этических рисков и разработка мер по их минимизации. В рамках исследования выделены основные аспекты.

Прозрачность и интерпретируемость. Преподаватели и студенты должны понимать, на каких основаниях система делает те или иные рекомендации. В отличие от коммерческих сервисов, где алгоритм может оставаться «черным ящиком», в образовании непонимание логики подрывает доверие и снижает педагогическую эффективность. Предложенная модель включает модуль LIME, который для каждой рекомендации выдает веса признаков. Это позволяет преподавателю объяснить студенту: «Система предложила вам этот курс, потому что вы хорошо справились с предыдущим модулем по линейной алгебре». Педагог наделен функцией просмотра сводных отчетов. При необходимости он может вручную изменить весовые коэффициенты отдельных компонентов, к примеру, понизить значимость коллаборативного фактора в ситуации, когда учебная группа насчитывает малое количество студентов.

Отдельный аспект — обеспечение беспристрастности рекомендаций и недопущение дискриминационных эффектов. Известно, что алгоритмы, построенные на методах машинного обучения, имеют тенденцию не просто повторять, но и усугублять те искажения, которые уже присутствуют в исходных данных. Рассмотрим гипотетический случай: если в ретроспективных данных о прохождении некоторого сложного технического курса большинство успешно справившихся обучающихся составляли мужчины, то алгоритм с высокой вероятностью начнет адресовать данный курс преимущественно мужской аудито-


рии, даже при условии, что женщины демонстрируют сопоставимый уровень подготовки. Чтобы вовремя обнаружить подобные перекосы в работе модели, автор предлагает проводить на валидационной выборке оценку по двум критериям: демографический паритет и равенство возможностей.

Конфиденциальность и безопасность данных.

Образовательные данные относятся к категории персональных и чувствительных. В России их обработка регулируется Федеральным законом о персональных данных, а также нормативными актами Министерства просвещения и Министерства науки и высшего образования РФ. В архитектуре автором реализованы следующие меры: анонимизация, удаление прямых идентификаторов, замена на хеши; минимизация, собираются только данные, необходимые для работы алгоритма; шифрование при передаче и хранении, разграничение доступа по ролям, студент видит только свои данные, преподаватель видит данные своей группы, администратор видит агрегированную статистику. Кроме того, предусмотрена возможность для студента отказаться от сбора некоторых типов данных, например, логи кликов, без потери базовой функциональности.

Баланс между персонализацией и академической свободой. Чрезмерная персонализация может привести к тому, что студент будет получать только те курсы, которые соответствуют его текущим интересам и уровню, и никогда не столкнется с новыми, сложными или неожиданными темами. Это ограничивает развитие критического мышления и междисциплинарных связей. Для предотвращения этого эффекта в модель встроены два механизма. Во-первых, в рекомендациях присутствует элемент случайности с вероятностью 5%, вместо топ-курса предлагается случайный курс из числа не входящих в текущий профиль. Во-вторых, преподаватель может задать обязательные модули, которые должны быть включены в траекторию независимо от рекомендаций. Таким образом, сохраняется баланс между адаптивностью и соблюдением образовательных стандартов.

Роль преподавателя в системе с ИИ. Важно подчеркнуть, что интеллектуальная рекомендательная система не призвана заменить педагога. Ее задача взять на себя рутинную аналитику, сбор и обработку данных, выявление паттернов, генерацию начальных рекомендаций, освобождая время преподавателя для индивидуальной работы со студентами и обсуждения сложных тем. Наилучшие результаты достигаются при гибридной модели «человек + ИИ», где преподаватель выступает как наставник, интерпретирующий рекомендации и принимающий финальные решения о корректировке траектории. Как показано в работе Molenaar, именно такая модель



способствует развитию саморегулируемого обучения и критического мышления [15, 16].

ВЫВОДЫ И ПЕРСПЕКТИВЫ

В настоящей статье представлена концептуальная модель интеллектуальной рекомендательной системы для персонализации обучения, объединяющая современные достижения в области коллаборативной фильтрации, контентного анализа, графовых нейронных сетей и объяснимого искусственного интеллекта.

По итогам выполненной работы можно сформулировать несколько ключевых положений.

Алгоритмы гибридного типа, которые одновременно учитывают историю взаимодействия студентов с учебными курсами и смысловое наполнение образовательных материалов, демонстрируют более высокие показатели по критериям полноты и точности по сравнению с методами, использующими только один тип данных.

Проблема «холодного старта» применительно к вновь созданным курсам успешно снимается благодаря применению плотных векторных представлений, эмбедингов, получаемых с помощью предварительно обученных языковых моделей. Данный подход дает возможность формировать рекомендации для курсов, еще не получивших ни одной оценки, опираясь исключительно на их текстовые аннотации. При этом достигаемая точность оказывается сопоставимой с той, что характерна для курсов с уже накопленной историей оценок.

В контексте образовательной среды способность системы объяснять выдаваемые рекомендации становится обязательным требованием. Использование технологий интерпретируемого искусственного


интеллекта позволяет наглядно представить, какой вклад вносит каждый отдельный признак в принятое решение. Как следствие, растет уровень доверия как со стороны преподавателей, так и со стороны обучающихся, а у последних появляется инструмент для осознанного построения собственной учебной траектории.

Этические вопросы, включая справедливость, защиту персональных данных, баланс между персонализацией и академической свободой, должны закладываться в фундамент архитектуры системы еще на этапе ее проектирования, а не добавляться позже в виде «надстроечных» модулей. Предложенная в данной работе модель предусматривает оценку метрик демографического паритета, встроенные механизмы обезличивания данных, а также специальную стратегию для поддержания разнообразия выдаваемых рекомендаций.

Ограничения и сложности практической реализации. К числу главных барьеров, мешающих массовому внедрению подобных решений, относятся: отсутствие унифицированных стандартов на образовательные данные в разных вузах и школах, что серьезно осложняет перенос моделей с одной платформы на другую, высокая ресурсоемкость обучения графовых нейронных сетей на крупных массивах данных, а также необходимость регулярного сопровождения и переобучения моделей по мере обновления учебных планов и появления новых курсов. Несмотря на перечисленные трудности, разработанная модель может рассматриваться как основа для создания адаптивных обучающих сред следующего поколения. Открытость ее архитектуры, кроме того, допускает поэтапное внедрение даже в условиях ограниченных вычислительных и временных ресурсов.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Bond M., Khosravi H., De Laat M., Bergdahl N. A meta systematic review of artificial intelligence in higher education: A call for increased ethics, collaboration, and rigour. *International Journal of Educational Technology in Higher Education*. 2024;21:4. URL: <https://doi.org/10.1186/s41239-023-00436-z>
2. Holmes W., Bialik M., Fadel C. Artificial intelligence in education. In: Data ethics: Building trust: How digital technologies can serve humanity. 2023:621–653. URL: <https://doi.org/10.58863/20.500.12424/4276068>
3. Klačnja-Milićević A., Ivanović M., Vesin B., Satratzemi M., Wasson B. Learning Analytics — Trends and Challenges. *Frontiers in Artificial Intelligence*. 2022;5:856807. URL: <https://doi.org/10.3389/frai.2022.856807>
4. Duan C., Yang J., Cui Q., Zhang W., Wan X., Zhang M. Enhancing the recommendation of learning resources for learners via an advanced knowledge graph. *Applied Sciences*. 2025;15(8):4204. URL: <https://doi.org/10.3390/app15084204>
5. Rigou A., Kyriazi F., Thomakos D. Predicting student success through learning analytics: A comparative modeling approach. *Creative Education*. 2025;16:1107–1119. URL: <https://doi.org/10.4236/ce.2025.168069>
6. Wu S., Sun F., Zhang W., Xie X., Cui B. Graph Neural Networks in Recommender Systems: A Survey. *ACM Computing Surveys*. 2022;55(5):97. URL: <https://doi.org/10.1145/3535101>
7. Yan J., Liu S., Armwood-Gordon C., Li L. Factors Affecting Active Flipped Learning on Underrepresented Students in Three STEM Courses. *Education and Information Technologies*. 2024;29(9):10791–10804. URL: <https://doi.org/10.1007/s10639-023-12234-1>



8. Захарова Ж.Л., Жиркова З.С. Условия создания цифровой трансформации в образовательной среде вуза. В сб.: Молодой исследователь: вопросы науки и образования. Киров; 2021:282–285. URL: <https://www.elibrary.ru/pfwwoi>
Zakharova Zh.L., Zhirkova Z.S. Conditions for creating digital transformation in the educational environment of a university. In: Young Researcher: Issues of science and education. Kirov; 2021:282–285. (In Russ.). URL: <https://www.elibrary.ru/pfwwoi>
9. Holstein K., Aleven V., Rummel N. A Conceptual Framework for Human – AI Hybrid Adaptivity in Education. In: Artificial Intelligence in Education. Part I. Cham: Springer; 2020:240–254. URL: https://doi.org/10.1007/978-3-030-52237-7_20
10. Овсянникова А.В. Цифровая трансформация образования: ключевые драйверы, барьеры и перспективы развития. *Мир науки. Педагогика и психология*. 2025;13(3):27. URL: <https://www.elibrary.ru/velqya>
Ovsyannikova A.V. Digital transformation of education: Key drivers, barriers and development prospects. *The World of Science. Pedagogy and Psychology*. 2025;13(3):27. (In Russ.). URL: <https://www.elibrary.ru/velqya>
11. Подлевских А.П., Суетин С.Н., Степкин С.В. Методология по курсу «Проектирование информационных систем» в условиях перехода к цифровой образовательной среде. *Современные наукоемкие технологии*. 2021;2:45–51. URL: <https://doi.org/10.17513/snt.38492>
Podlevskikh A.P., Suetin S.N., Stepkin S.V. Methodology for the course “Designing information systems” in the context of transition to a digital educational environment. *Modern High-tech Technologies*. 2021;2:45–51. (In Russ.). URL: <https://doi.org/10.17513/snt.38492>
12. Nguyen A., Ilesanmi F., Dang B., Vuorenmaa E., Järvelä S. Hybrid Intelligence in Academic Writing: Examining Self-Regulated Learning Patterns in an AI-Assisted Writing Task. In.: *Hybrid Human Artificial Intelligence (HHAI)*. 2024;241–254. URL: <https://doi.org/10.3233/FAIA240198>.
13. Topali P., Ortega-Arranz A., Rodríguez-Triana M.J., Er E., Khalil M., Akçapınar G. Designing human-centered learning analytics and artificial intelligence in education solutions: A systematic literature review. *Behaviour and Information Technology*. 2025;44(5):1071–1098. URL: <https://doi.org/10.1080/0144929X.2024.2345295>
14. Bai Y., et al. Impact of generative AI interaction and output quality on university students’ learning outcomes: A technology-mediated and motivation-driven approach. *Scientific Reports*. 2025;15(1):24054. URL: <https://doi.org/10.1038/s41598-025-08697-6>
15. Hummel S. Ethical and Responsible AI in Education: Situated Ethics for Democratic Learning. *Education Sciences*. 2025;15(12):1594. URL: <https://doi.org/10.3390/educsci15121594>
16. Кеннон О.В., Пустошило П.В., Иванцов А.А. Проблема использования нейросетей и инструментов искусственного интеллекта обучающимися вузов: этический аспект. *Российский гуманитарный журнал*. 2025;16(3):192–210. URL: <https://doi.org/10.12731/2658-4034-2025-16-3-862>
Cannon O.V., Pustoshilo P.V., Ivantsov A.A. The problem of using neural networks and artificial intelligence tools by university students: An ethical aspect. *Russian Humanitarian Journal*. 2025;16(3):192–210. (In Russ.). URL: <https://doi.org/10.12731/2658-4034-2025-16-3-862>

ИНФОРМАЦИЯ ОБ АВТОРЕ / ABOUT THE AUTHOR

Анна Вячеславовна Овсянникова — кандидат педагогических наук, доцент кафедры математики и анализа данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация
Anna V. Ovsyannikova — Cand. Sci. (Ped.), Assoc. Prof. of the Department of Mathematics and Data Analysis of the Financial University under the Government of the Russian Federation, Moscow, Russian Federation
<https://orcid.org/0000-0002-1716-3100>
avovsyannikova@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 19.12.2025; после рецензирования 12.01.2026; принята к публикации 26.03.2026.
Автор прочитала и одобрила окончательный вариант рукописи.
The article was submitted on 19.12.2025; revised on 12.01.2026 and accepted for publication on 26.03.2026.
The author read and approved the final version of the manuscript.

Автоматизация процесса инкассации на основе разработки и внедрения мобильной автоматизированной инкассаторской системы

В.Р. Цыганков¹, Н.В. Гринева², П.Е. Голосов³

^{1,2} Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация;

³ РАНХиГС при Президенте Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

В условиях цифровизации банковского сектора и повышения требований к оперативности и безопасности обработки наличных средств традиционные методы организации инкассации перестают обеспечивать необходимый уровень эффективности. **Анализ существующих решений** показывает, что современные инкассаторские службы сталкиваются с фрагментарностью применяемых технологий, недостаточной интеграцией между мобильными и веб-системами, а также отсутствием интеллектуальных инструментов поддержки принятия решений. Пробел в исследовательской литературе заключается в отсутствии комплексных архитектур, объединяющих мобильные приложения, веб-сервисы мониторинга и модули искусственного интеллекта в единую экосистему управления инкассационными процессами.

Цель исследования заключается в анализе возможностей автоматизации процессов инкассации с использованием мобильных и веб-технологий, а также интеллектуальных компонентов, направленных на повышение эффективности, прозрачности и безопасности инкассационного процесса на базе мобильной автоматизированной инкассаторской системы. **Методологическая база** включает системный анализ процессов инкассации, моделирование бизнес-процессов (BPMN), архитектурное проектирование, методы программной инженерии, а также применение алгоритмов машинного обучения для оптимизации маршрутов, прогнозирования задержек и выявления аномалий. Полученные результаты демонстрируют, что использование мобильного приложения в сочетании с веб-сервисом центра мониторинга и ИИ-агентами позволяет обеспечить непрерывный обмен данными, повысить точность планирования, автоматизировать инструктаж и документирование операций, а также сократить влияние человеческого фактора. **Сделанные выводы** подтверждают, что внедрение МАИС обеспечивает качественный рост эффективности инкассационных процессов, повышает уровень безопасности и создает основу для дальнейшего развития интеллектуальных решений в области логистики и банковской автоматизации. Перспективой исследования является расширение функциональности ИИ-агентов и интеграция системы с комплексами корпоративной безопасности и финансового мониторинга.

Ключевые слова: инкассация; автоматизация; мониторинг; МАИС; интеграция; безопасность; ИИ-Агенты

Для цитирования: Цыганков В.Р., Гринева Н.В., Голосов П.Е. Автоматизация процесса инкассации на основе разработки и внедрения мобильной автоматизированной инкассаторской системы. *Цифровые решения и технологии искусственного интеллекта*. 2026;2(2):25-34. DOI: 10.26794/3030-7097-2026-2-2-25-34

ORIGINAL PAPER

Automation of the Cash Collection Process Through the Development and Implementation of a Mobile Automated Cash-in-transit System


V.R. Tsygankov¹, N.V. Grineva², P.E. Golosov³

^{1,2} Financial University under the Government of the Russian Federation, Moscow, Russian Federation;

³ RANEPA, Moscow, Russian Federation

ABSTRACT

In the context of the digitalization of the banking sector and the increasing requirements for the speed and security of cash handling, traditional methods of cash-in-transit (CIT) operations no longer provide the necessary level of efficiency. **An analysis** of existing solutions shows that modern CIT services face fragmented technological infrastructures, insufficient integration between mobile and web systems, and a lack of intelligent decision-support tools. The gap in research literature lies in the absence of comprehensive architectures that unify mobile applications, web-based monitoring services, and artificial intelligence modules into a single ecosystem for managing CIT processes. **The purpose** of the study is to analyze the possibilities for automating CIT processes using mobile and web technologies, as well as intelligent components aimed at improving the efficiency, transparency, and security of cash-in-transit operations through a mobile automated CIT system.



The **methodological** foundation includes systems analysis of CIT processes, business process modeling (BPMN), architectural design, software engineering methods, and the application of machine learning algorithms for route optimization, delay prediction, and anomaly detection. **The results** demonstrate that the use of a mobile application in combination with a monitoring center web service and AI agents enables continuous data exchange, improves planning accuracy, automates briefing and documentation procedures, and reduces the impact of human factors. The conclusions confirm that the implementation of the Mobile Automated Cash-in-Transit System (MACTS) ensures a significant increase in the efficiency of CIT processes, enhances security, and establishes a foundation for the further development of intelligent solutions in logistics and banking automation. The prospects of the research include expanding the functionality of AI agents and integrating the system with corporate security and financial monitoring platforms.

Keywords: collection; automation; monitoring; MAIS; integration; security; AI-Agents

For citation: Tsygankov V.R., Grineva N.V., Golosov P.E. Automation of the cash collection process through the development and implementation of a mobile automated cash-in-transit system. *Digital solutions and artificial intelligence technologies*. 2026;2(2):25-34. DOI:10.26794/3030-7097-2026-2-2-25-34

ВВЕДЕНИЕ

Современные финансовые организации и инкассаторские службы сталкиваются с необходимостью повышения прозрачности, оперативности и безопасности процесса инкассации. Традиционные методы, основанные на бумажной документации, ручной координации маршрутов и устаревших системах контроля, создают риски задержек, ошибок и неэффективного использования ресурсов. В условиях цифровизации и роста требований к скорости обработки финансовых потоков возникает объективная потребность в автоматизации данного процесса с использованием современных ИТ-инструментов, включая веб-технологии, мобильные приложения и искусственный интеллект.

Разработка и внедрение мобильной автоматизированной инкассаторской системы (МАИС) представляет собой перспективное направление, позволяющее объединить в единой цифровой среде работу операторов центра мониторинга и выездных инкассаторов. Такая система обеспечивает онлайн-контроль за маршрутами, автоматизацию документооборота, формирование инструктажей, интеллектуальную поддержку принятия решений с помощью ИИ-агентов и многое другое. Использование интеллектуальных модулей, основанных на анализе данных, позволяет повышать эффективность распределения маршрутов, снижать риски человеческих ошибок и обеспечивать адаптивную поддержку операторов в режиме реального времени.

Объект исследования — процессы организации и сопровождения инкассации в финансовых учреждениях.

Предмет исследования — методы автоматизации процессов инкассации на основе интегрированных мобильных и веб-технологий с элементами искусственного интеллекта [1].

Цель исследования — анализ возможностей автоматизации процессов инкассации с использованием мобильных и веб-технологий, а также интеллекту-

альных компонентов, направленный на повышение эффективности, прозрачности и безопасности инкассационного процесса на базе мобильной автоматизированной инкассаторской системы.

Задачи исследования: (1) проанализировать существующие подходы и программные решения в области автоматизации инкассации и логистики денежных потоков; (2) обосновать использование ИИ-агентов для автоматизации ряда инкассаторских процессов; (3) определить методы интеграции МАИС с внутренними банковскими системами и средствами безопасности; (4) обозначить перспективы развития МАИС.

АНАЛИЗ ЛИТЕРАТУРЫ

Современные исследования по организации инкассации и кэш-менеджменту подчеркивают мультидисциплинарный характер проблемы, объединяющий банковскую операционную практику, логистику и информационные технологии. Аналитические работы по обороту наличных и прогнозированию спроса на наличные показывают, что применение временных рядов и статистических моделей позволяет существенно снизить избыточные выезды инкассаторских бригад и оптимизировать загрузку банкоматов и касс.

В сфере оптимизации маршрутов исследования фокусируются на адаптации классических задач VRP/TSP к прикладным требованиям инкассации: учету *time windows* (окна обслуживания), ограничений по вместимости и дополнительным требованиям безопасности (разделение грузов, сопровождение). Практические обзоры веб-сервисов и инструментов диспетчеризации показывают, что сочетание эвристических алгоритмов с реальными дорожными данными дает наилучший баланс между качеством маршрутов и вычислительной скоростью, что критично для оперативной диспетчеризации [2].

Безопасность при перевозке наличности — отдельная большая тема: исследования рассматри-



вают как технические решения (СКУД, GPS-мониторинг, видеонаблюдение, защищенные каналы связи), так и организационные меры (процедуры проверки, регламенты, обучение персонала). В литературе подчеркивается необходимость интеграции телеметрии и мониторинга в реальном времени с централизованными веб-сервисами мониторинга для быстрого реагирования на инциденты. Также отмечается важность оценки рисков при проектировании процедур и технических решений.

Тенденция внедрения ИИ и аналитики проявляется в двух направлениях: прогнозирование (объемов наличности, спроса по локациям, временных задержек); оперативная поддержка (рекомендательные системы для диспетчеров, детекция аномалий в поведении маршрутов).

Исследования показывают, что комбинирование исторических данных с внешними признаками (погодные условия, события, дорожная ситуация) через модели машинного обучения повышает качество прогнозов и дает основу для проактивного планирования [3]. В то же время авторы обращают внимание на требования к объяснимости моделей и прозрачности решений при их применении в банковском окружении.

Наконец, обзор практических внедрений указывает на фрагментарность доступной научной информации: многие корпоративные решения закрыты для публикации, а доступные исследования часто либо описывают отдельные компоненты (маршрутизация, безопасность, прогнозирование), либо публикуются в виде отчетов или сборников

конференций. Это формирует методологическую нишу для исследований, которые систематически описывают комплексные архитектуры МАИС [4].

АНАЛИЗ ПРЕДМЕТНОЙ ОБЛАСТИ

Современные финансовые организации и инкассаторские службы сталкиваются с необходимостью повышения эффективности, прозрачности и безопасности процесса инкассации. Традиционные методы работы, основанные на бумажной документации, ручной координации маршрутов и устаревших системах контроля, создают значительные риски ошибок, задержек и неэффективного использования ресурсов. В условиях цифровизации банковских операций возникает объективная потребность в применении современных информационных технологий, объединяющих мобильные и веб-компоненты с элементами искусственного интеллекта [1].

МАИС позволяет интегрировать работу выездных бригад и операторов центра мониторинга в единую цифровую экосистему. Инкассаторы, используя мобильное приложение, получают свои маршруты, задания с приоритетами, актуальные инструктажи и уведомления о любых изменениях или чрезвычайных ситуациях. При этом все действия фиксируются в системе в режиме реального времени, что обеспечивает непрерывный поток данных для последующего анализа и принятия управленческих решений. Мобильное приложение позволяет сотрудникам не только контролировать выполнение заданий, но и оперативно отправлять




Рис. / Fig. Архитектура взаимодействия веб-сервиса МАИС и МП МАИС /
Architecture of Interaction between the MAIS Web Service and the MAIS Mobile Application

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



отчеты, фиксировать отклонения от маршрута и временные показатели, что минимизирует риск ошибок и упрощает документооборот [5].

Взаимодействие через веб-сервис обеспечивает централизованный контроль и управление процессами со стороны операторов. Через веб-платформу планируются маршруты, распределяются задания, формируются уведомления и инструкции для инкассаторов. В системе реализованы возможности аналитики и прогнозирования с использованием ИИ-агентов, что позволяет своевременно выявлять возможные задержки, оптимизировать маршруты и перераспределять ресурсы в зависимости от текущей ситуации. Для сотрудников, осуществляющих мониторинг инкассаторов, веб-сервис выступает инструментом получения информации о своих задачах, взаимодействия с инкассаторами на выездах и обратной связи по возникающим проблемам [6].

Таким образом, система обеспечивает сквозной контроль на всех этапах процесса инкассации, интегрируя мобильное приложение инкассаторов и веб-сервис операторов в единую цифровую среду.

На рисунке представлена концептуальная и совсем верхнеуровневая архитектура взаимодействия веб-сервиса МАИС и МП МАИС. Можно увидеть, что в банке разделена зона доступности сети на два сегмента — EXTERNAL/SIGMA (внешняя зона) и INTERNAL/ALPHA (внутренняя). Также между ними существует шлюзовая сеть, которая является своего рода прокси и перекидывает поток данных из одного сегмента сети в другой. Исходя из этого, видно, что веб-сервис МАИС находится во внутренней зоне сети, поток данных из него идет в МП через шлюзовую сеть и также проходит через FIREWALL. Интеграция реализована по REST API.

Использование МАИС позволяет не только автоматизировать текущие операции, но и внедрять интеллектуальные механизмы поддержки принятия решений. Алгоритмы машинного обучения анализируют исторические данные о маршрутах, временные задержки, загруженность дорожной сети и параметры безопасности для оптимизации маршрутов и распределения заданий. Интеллектуальные модели мониторинга выявляют отклонения от графика и формируют рекомендации по корректировке маршрутов и приоритетов, что повышает уровень безопасности и эффективность работы. Системная интеграция мобильного приложения и веб-сервиса обеспечивает надежный и безопасный обмен данными в реальном времени, масштабируемость и возможность добавления новых функциональных модулей без нарушения работы системы. В результате внедрение МАИС позволяет значительно повысить прозрачность,

управляемость и безопасность процесса инкассации, снижая операционные риски и улучшая использование ресурсов.

АНАЛИЗ СУЩЕСТВУЮЩИХ ПОДХОДОВ К РЕШЕНИЮ ЗАДАЧИ АВТОМАТИЗАЦИИ

Вопрос автоматизации процесса инкассации на протяжении последних десятилетий рассматривался преимущественно в контексте оптимизации логистики, безопасности и документооборота. Однако до настоящего времени отсутствует единый комплексный подход, позволяющий интегрировать все элементы данного процесса в единую цифровую экосистему, объединяющую операторов центра мониторинга, выездные бригады и управленческий персонал [7].

Современные решения можно условно разделить на три основные категории: традиционные системы учета и мониторинга, GPS-трекинг и интегрированные цифровые платформы, каждая из которых обладает своими преимуществами и ограничениями.

Традиционные системы учета и мониторинга широко применяются в банковском и логистическом секторе и представляют собой внутренние корпоративные платформы или модули ERP-систем, обеспечивающие регистрацию заявок, формирование маршрутов и фиксацию выполнения операций. Их ключевым достоинством является устойчивость, проверенная временем, а также высокая степень интеграции с бухгалтерскими и управленческими подсистемами организации. Эти решения гарантируют надежный контроль финансовых потоков и документальное подтверждение каждой операции [8]. Тем не менее их существенными недостатками являются низкий уровень мобильности и автоматизации, высокая трудоемкость ручного ввода данных, а также ограниченная гибкость при изменении маршрутов и планов работы.

Практика показывает, что операторы вынуждены выполнять значительный объем рутинных действий: формировать отчеты, корректировать расписания и вручную обновлять статусы заданий, что приводит к росту вероятности ошибок и снижению оперативности принятия решений.

Вторая категория решений — системы GPS-мониторинга и трекинга транспортных средств [9, 10]. Они получили широкое распространение благодаря относительной простоте внедрения и возможности контроля за перемещением инкассаторских автомобилей в режиме реального времени. Такие системы обеспечивают прозрачность маршрутов, позволяют отслеживать отклонения от плана и повышают безопасность перевозимых ценностей.

**Сравнительный анализ подходов к автоматизации инкассации /
Comparative Analysis of Approaches to Cash Collection Automation**

Критерий / Criterion	Традиционные системы / Traditional Systems	GPS- мониторинг / GPS Monitoring	Интегрированные платформы / Integrated Platforms	МАИС / MAIS
Мобильность	Низкая	Средняя	Высокая	Высокая
Онлайн-контроль	Частичный	Да	Да	Да
Документооборот	Ручной	Отсутствует	Частично автоматизирован	Полностью автоматизирован
Использование ИИ	Нет	Нет	Ограниченно	Полноценные ИИ-агенты
Масштабируемость	Низкая	Средняя	Низкая	Высокая

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

Однако их функциональные возможности ограничены: они решают исключительно задачу геолокации и не включают в себя механизмы автоматизации документооборота, распределения заданий или взаимодействия между участниками процесса. Фактически GPS-мониторинг выступает вспомогательным инструментом для наблюдения, не влияя напрямую на эффективность планирования и координации действий между оператором и инкассатором. В большинстве случаев обработка данных и принятие решений по-прежнему выполняются вручную, что не соответствует современным требованиям цифровизации и интеллектуализации управления [8].

Наиболее перспективным направлением развития являются интегрированные цифровые платформы, объединяющие функциональность мобильных и веб-приложений, аналитических модулей и сервисов обмена данными в единой среде. Такие решения применяются в крупных банках, инкассаторских компаниях и логистических холдингах, где существует необходимость в координации множества маршрутов и персонала.

Интегрированные системы позволяют централизованно управлять задачами, обмениваться данными между операторами и мобильными устройствами инкассаторов, а также вести автоматический учет времени, маршрутов и выполненных операций. Современные разработки все чаще используют элементы искусственного интеллекта и машинного обучения — для анализа исторических данных, оптимизации маршрутов, прогнозирования возможных задержек и оценки рисков [2]. Применение таких технологий способствует повышению эффективности и снижению издержек.

Однако, несмотря на очевидные преимущества, большинство существующих платформ остаются

закрытыми и недоступными для адаптации под конкретные потребности небольших и средних инкассаторских служб. Они требуют значительных финансовых вложений, сложной интеграции с внутренними системами безопасности и не всегда поддерживают возможность автоматического формирования индивидуальных инструкций для персонала. Кроме того, в существующих решениях редко реализована интеллектуальная поддержка операторов центра мониторинга и мобильных сотрудников — в виде ИИ-агентов, способных автоматически анализировать ситуацию, предлагать решения и формировать инструктаж в зависимости от внешних условий (трафика, погодных факторов, уровня угрозы и пр.).

В табл. 1 представлен сравнительный анализ основных подходов к автоматизации процесса инкассации, применяемых в современной практике. Сопоставление выполнено по ключевым функциональным и технологическим критериям, включая уровень мобильности, наличие онлайн-контроля, степень автоматизации документооборота, использование интеллектуальных алгоритмов и возможности масштабирования. Проведенное сравнение позволяет наглядно выявить ограничения традиционных систем учета и решений на базе GPS-мониторинга, а также показать преимущества интегрированных цифровых платформ [11].

Отдельное внимание уделено МАИС, которая отличается комплексным подходом, глубокой интеграцией мобильных и веб-компонентов и применением ИИ-агентов для поддержки принятия решений, что обеспечивает более высокий уровень эффективности, прозрачности и безопасности инкассационных процессов.

Таким образом, проведенный анализ показывает, что современные подходы к автоматизации



процесса инкассации носят фрагментарный характер. Они частично решают отдельные задачи — мониторинг маршрутов, учет выполненных операций или ведение отчетности, — но не обеспечивают их комплексной интеграции и интеллектуального сопровождения.

Отсутствие единой цифровой экосистемы, объединяющей мобильное приложение для инкассаторов и веб-сервис для операторов с элементами искусственного интеллекта, ограничивает возможности повышения эффективности, прозрачности и безопасности инкассационных операций. Это определяет актуальность разработки мобильной автоматизированной инкассаторской системы нового поколения, обеспечивающей интеллектуальную поддержку всех участников процесса и сквозную цифровизацию инкассационного цикла.

МЕТОДЫ АВТОМАТИЗАЦИИ ПРОЦЕССА ИНКАССАЦИИ

Для реализации поставленной цели исследования применен комплекс системных, аналитических и проектных методов, направленных на обеспечение всестороннего подхода к разработке МАИС. Такой междисциплинарный подход позволяет рассматривать процесс инкассации как сложную социотехническую систему, включающую организационные, технологические и человеческие аспекты.

В качестве методологической основы используется системный анализ, который позволяет описать и структурировать все этапы процесса инкассации — от формирования заявок и планирования маршрутов до передачи отчетности и обработки данных. На основе системного анализа определяются ключевые роли участников (оператор, инкассатор, контролер, служба безопасности) и выявляются узкие места, подлежащие автоматизации. Такой подход обеспечивает комплексное понимание взаимосвязей между элементами системы и позволяет обосновать целесообразность внедрения интеллектуальных инструментов для поддержки принятия решений.

Моделирование бизнес-процессов (BPMN) применяется для построения логической структуры взаимодействия между пользователями, сервисами и компонентами системы. С помощью моделей BPMN формализуются информационные потоки, маршруты передачи данных и сценарии обработки инкассационных заданий. Это дает возможность наглядно представить процесс работы как единую цифровую экосистему, где мобильное приложение инкассатора и веб-сервис оператора

действуют синхронно, обеспечивая прозрачность и управляемость операций в реальном времени.

Особое место в разработке МАИС занимает применение ИИ-агентов. В отличие от традиционных алгоритмов автоматизации, ИИ-компоненты системы выступают не только как отдельные агенты, выполняющие конкретные функции, но и как единая интеллектуальная инфраструктура, обеспечивающая анализ данных, прогнозирование и адаптацию процессов.

В табл. 2 представлена структурированная классификация функциональных уровней применения ИИ-агентов в составе мобильной автоматизированной инкассаторской системы. Для каждого уровня определены основные задачи интеллектуальной поддержки и используемые методы обработки данных, что позволяет наглядно отразить роль искусственного интеллекта на этапах планирования, операционного управления, взаимодействия с персоналом и аналитической поддержки принятия решений [12].

Представленная структура демонстрирует сквозной характер интеграции ИИ-агентов в МАИС и подчеркивает их значение не как изолированных инструментов, а как единого интеллектуального механизма, обеспечивающего адаптивность и повышение эффективности инкассационных процессов.

Таким образом, ИИ-агенты в МАИС рассматриваются не как изолированный модуль, а как сквозной инструмент цифровой трансформации, обеспечивающий адаптивность, самообучаемость и непрерывное повышение эффективности работы системы [13].

Технической основой взаимодействия между компонентами служит интеграционная архитектура, основанная на REST API и микросервисном подходе. Она обеспечивает надежный и безопасный обмен данными между мобильным приложением инкассатора и веб-сервисом оператора в режиме реального времени. Использование микросервисной архитектуры позволяет масштабировать систему, добавлять новые модули (например, аналитический или отчетный блок) без нарушения ее общей работоспособности.

Для реализации и проверки концепции используются методы программной инженерии и прототипирования, направленные на разработку пилотной версии системы и последующую оценку ее эффективности. Оценка проводится по ключевым показателям:

- среднее время выполнения маршрута;
- количество ошибок при формировании отчетности;

Функциональные уровни применения ИИ-агентов в МАИС / Functional Levels of AI Agent Application in MAIS

Уровень / Level	Назначение / Purpose	Используемые методы / Methods Used
Планирование	Оптимизация маршрутов	ML, VRP, прогнозирование
Операционное управление	Контроль отклонений	Аномалия-детекция
Взаимодействие с персоналом	Генерация инструктажей	NLP, экспертные системы
Аналитика	Прогноз рисков	AI-driven analytics

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

- уровень задержек;
- показатель безопасности (отсутствие инцидентов);
- коэффициент использования ресурсов.

Полученные результаты служат основанием для совершенствования архитектуры и алгоритмов работы системы [14].

В целом выбранные методы обеспечивают системное и практико-ориентированное достижение поставленной цели — создание архитектурной и функциональной модели мобильной автоматизированной инкассаторской системы, способной существенно повысить производительность труда инкассаторов, минимизировать операционные риски и обеспечить высокий уровень прозрачности и управляемости инкассационного процесса [15, 16].

Интеграция искусственного интеллекта в качестве ядра интеллектуальной поддержки позволяет системе не только автоматизировать текущие операции, но и эволюционировать на основе анализа накопленных данных, переходя от режима «реакции» к режиму прогнозирования и проактивного управления.

Что же касается перспектив, то развитие МАИС целесообразно направлять по нескольким стратегическим направлениям, обеспечивающим дальнейшее повышение эффективности, безопасности и интел-

лектуальности инкассационных процессов. Именно это отражено в табл. 3.

В табл. 3 систематизированы основные направления дальнейшего развития мобильной автоматизированной инкассаторской системы, отражающие ключевые векторы усиления интеллектуальной составляющей, масштабируемости и аналитических возможностей МАИС.

ВЫВОДЫ

Проведенное исследование подтверждает, что повышение эффективности и безопасности инкассационных процессов невозможно без комплексной цифровизации, объединяющей мобильные и веб-технологии с методами искусственного интеллекта. Традиционные системы, используемые в инкассаторских службах, обладают ограниченной функциональностью и не обеспечивают сквозного управления процессом, что приводит к росту операционных рисков, задержкам и снижению прозрачности.

Разработка и внедрение мобильной автоматизированной инкассаторской системы демонстрирует, что интеграция мобильного приложения, веб-сервиса и интеллектуальных аналитических модулей позволит существенно повысить управляемость, точность планирования и оперативность принятия решений.

Таблица 3 / Table 3

Основные направления развития МАИС / Key Directions for the Development of MAIS

Направление / Direction	Содержание / Content	Ожидаемый эффект / Expected Effect
Развитие ИИ	Самообучающиеся модели	Снижение рисков
Масштабируемость	Универсальные API	Расширение внедрения
Предиктивная аналитика	Прогноз угроз	Проактивное управление

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



Использование ИИ-агентов обеспечит возможность прогнозирования, автоматической оптимизации маршрутов и выявления отклонений в реальном времени, что значительно повысит уровень безопасности и снизит нагрузку на персонал.

Таким образом, работа подтверждает актуальность создания и внедрения МАИС как инновационного инструмента цифровой трансформации инкассационного процесса. Такая система фор-

мирует единое информационное пространство, уменьшает влияние человеческого фактора, повышает эффективность использования ресурсов и обеспечивает качественно новый уровень надежности и прозрачности операций. Полученные результаты свидетельствуют о практической значимости предложенного подхода и его потенциале для дальнейшего развития в финансовых организациях.

СПИСОК ИСТОЧНИКОВ


1. Литвин И.Ю., Литвин А.Ю. Искусственный интеллект как одно из направлений инновационного развития банковского сектора. *Инновационное развитие экономики*. 2021;2-3(62-63):42-46. URL: https://doi.org/10.51832/2223-7984_2021_2-3_42
2. Попов П.В., Степин Ю.Г., Цехан О.Б. Об одном подходе к решению задачи оптимизации сети автотранспортных парков в составе транспортной инфраструктуры региона. *Транспорт: наука, техника, управление. Научный информационный сборник*. 2021;(2):54-60. URL: <https://doi.org/10.36535/0236-1914-2021-02-9>
3. Шкуропадский И.В., Овчинников П.В., Ткачев А.Н. Разработка систем интеллектуальной автоматизации бизнес-процессов на основе технологий машинного обучения. *Дружковский вестник*. 2021;(6):45-56. URL: <https://doi.org/10.17213/2312-6469-2021-6-45-56>
4. Никитин В.В., Скрыпников А.В., Высоцкая И.А. и др. Методы оптимизации транспортных сетей лесовозных автомобильных дорог. *Системы. Методы. Технологии*. 2021;(4):122-126. URL: <https://doi.org/10.18324/2077-5415-2021-4-122-126>
5. Ештокин С.В. Цифровые траектории устойчивого развития банковского сектора в период долгосрочной неопределенности в условиях военно-политических флуктуаций. *Вопросы инновационной экономики*. 2022;(4):2631-2648. URL: <https://doi.org/10.18334/vinec.12.4.116242>
6. Подольская Т.В., Сидельников А.П., Гелашвили Л. Практика внедрения компьютерного аудита и искусственного интеллекта в банковском секторе. *Вопросы инновационной экономики*. 2021;(4):1493-1508. URL: <https://doi.org/10.18334/vinec.11.4.113673>
7. Коновалова М.Е., Кузьмина О.Ю. Финансовые экосистемы в эпоху развития цифровых технологий (на примере ПАО Сбербанк). *Вопросы инновационной экономики*. 2023;(1):361-380. URL: <https://doi.org/10.18334/vinec.13.1.117453>
8. Сараев А.А. Применение технологии «Промышленный Интернет вещей» на предприятии. *Политехнический молодежный журнал*. 2021;11(64). URL: <https://doi.org/10.18698/2541-8009-2021-11-748>
9. Stepanov M.S., Poskotin L.S., Shishkin D.V. et al. The using of ZigBee protocol to organize the "Smart Home" system for aged people. *T-Comm*. 2021;15(10):64-70. URL: <https://doi.org/10.36724/2072-8735-2021-15-10-64-70>
10. Аграновский А.В. Особенности импортозамещения технологий интернета вещей в логистике. В сб.: *Аэрокосмическое приборостроение и эксплуатационные технологии*. Ч. 1. СПб.: Санкт-Петербургский государственный университет аэрокосмического приборостроения; 2023:97-101. URL: <https://doi.org/10.31799/978-5-8088-1819-4-2023-4-1-97-101>
11. Прокофьева Е.Н. Актуальные аспекты управления кассовой ликвидностью банка в условиях минимизации налично-денежного обращения. *Вестник Забайкальского государственного университета*. 2021;(2):133-139. URL: <https://doi.org/10.21209/2227-9245-2021-27-2-133-139>
12. Галушко М.В., Арькова О.В. Цифровые инновационные технологии банковского сектора на современном этапе развития. В сб.: *Фундаментальные и прикладные научные исследования: актуальные вопросы, достижения и инновации*. Пенза: Наука и Просвещение; 2023:187-190. URL: <https://elibrary.ru/cdbila>
13. Курманова Д.А., Галимарданов А.Р., Султангареев Д.Р. Цифровая трансформация Российского коммерческого банка. *Вестник УГНТУ. Наука, образование, экономика. Серия: Экономика*. 2021;(1):49-61. URL: <https://doi.org/10.17122/2541-8904-2021-1-35-49-61>
14. Измайлов М.К. Применение искусственного интеллекта для оптимизации рутинных административных задач: возможности, проблемы и перспективы. *Вестник Пермского университета. Серия: Экономика*. 2024;(4):395-408. URL: <https://doi.org/10.17072/1994-9960-2024-4-395-408>



15. Пашковская И.В. Конкурентные возможности банков в цифровой экономике. *Вестник евразийской науки*. 2021;(6). URL: <https://elibrary.ru/wmpeba>
16. Alyunov A.N., Vyatkina O.S. Identification of parameters of power transformer models using artificial intelligence methods. *E3S WEB OF CONFERENCES*. 2023;411:01001. URL: <https://doi.org/10.1051/e3sconf/202341101001>

REFERENCES

1. Litvin I.Y. Litvin A.Y. Artificial intelligence as one of the directions of innovative development of the banking sector. *Innovative Economic Development*. 2021;2-3(62-63):42-46. (In Russ.). URL: https://doi.org/10.51832/2223-7984_2021_2-3_42
2. Popov P.V., Stepin Yu.G., Tsekhan O.B. On one approach to solving the problem of optimizing the network of motor vehicle fleets as part of the transport infrastructure of the region. *Transport: Science, Technology, Management. Scientific Information Collection*. 2021;(2):54-60. (In Russ.). URL: <https://doi.org/10.36535/0236-1914-2021-02-9>
3. Shkuropadskiy I.V., Ovchinnikov P.V., Tkachev A.N. Development of intelligent automation systems for business processes based on machine learning technologies. *The Drucker Bulletin*. 2021;(6):45-56. (In Russ.). URL: <https://doi.org/10.17213/2312-6469-2021-6-45-56>
4. Nikitin V.V., Skrypnikov A.V., Vysotskaya I.A. et al. Methods of optimization of transport networks of logging roads. *The System. Methods. Technologies*. 2021;(4):122-126. (In Russ.). URL: <https://doi.org/10.18324/2077-5415-2021-4-122-126>
5. Yeshtokin S.V. Digital trajectories of sustainable development of the banking sector in a period of long-term uncertainty in the context of military and political fluctuations. *Issues of Innovative Economics*. 2022;(4):2631-2648. (In Russ.). URL: <https://doi.org/10.18334/vinec.12.4.116242>
6. Podolskaya T.V., Sidelnikov A.P., Gelashvili L. The practice of introducing computer auditing and artificial intelligence in the banking sector. *Issues of Innovative Economics*. 2021;(4):1493-1508. (In Russ.). URL: <https://doi.org/10.18334/vinec.11.4.113673>
7. Konovalova M.E., Kuzmina O.Y. Financial ecosystems in the era of digital technology development (on the example of Sberbank PJSC). *Issues of innovative economics*. 2023;(1):361-380. (In Russ.). URL: <https://doi.org/10.18334/vinec.13.1.117453>
8. Saraev A. A. Application of the "Industrial Internet of Things" technology at the enterprise. *Polytechnic Youth Magazine*. 2021;11(64). (In Russ.). URL: <https://doi.org/10.18698/2541-8009-2021-11-748>
9. Stepanov M.S., Poskotin L.S., Shishkin D.V. and others. Using the ZigBee protocol to organize a Smart Home system for the elderly. *T-Comm*. 2021;15(10):64-70. URL: <https://doi.org/10.36724/2072-8735-2021-15-10-64-70>
10. Agranovskiy A.V. Features of import substitution of Internet of Things technologies in logistics. In collection: *Aerospace Instrumentation and Operational Technologies. Part 1*. Saint Petersburg: Saint Petersburg State University of Aerospace Instrumentation; 2023:97-101. (In Russ.). URL: <https://doi.org/10.31799/978-5-8088-1819-4-2023-4-1-97-101>
11. Prokofieva E.N. Actual aspects of managing the bank's cash liquidity in terms of minimizing cash circulation. *Bulletin of the Trans-Baikal State University*. 2021;(2):133-139. (In Russ.). URL: <https://doi.org/10.21209/2227-9245-2021-27-2-133-139>
12. Galushko M.V., Arkova O.V. Digital innovative technologies of the banking sector at the present stage of development. In: *Fundamental and Applied Scientific Research: current issues, achievements and innovations*. Penza: Science and Education; 2023:187-190. (In Russ.). URL: <https://elibrary.ru/cdbila>
13. Kurmanova D.A., Galimardanov A.R., Sultangareev D.R. Digital transformation of the Russian Commercial Bank. *USNTU Bulletin. Science, Education, Economics. Series: Economics*. 2021;(1):49-61. (In Russ.). URL: <https://doi.org/10.17122/2541-8904-2021-1-35-49-61>
14. Izmailov M.K. The use of artificial intelligence to optimize routine administrative tasks: Opportunities, problems and prospects. *Bulletin of Perm University. Series: Economics*. 2024;(4):395-408. (In Russ.). URL: <https://doi.org/10.17072/1994-9960-2024-4-395-408>
15. Pashkovskaya I.V. Competitive opportunities of banks in the digital economy. *Bulletin of Eurasian Science*. 2021;(6). (In Russ.). URL: <https://elibrary.ru/wmpeba>
16. Alunov A.N., Vyatkina O.S. Identification of parameters of power transformer models using artificial intelligence methods. *WEB CONFERENCE E3S*. 2023;411:01001. URL: <https://doi.org/10.1051/e3sconf/202341101001>



ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Владислав Романович Цыганков — магистрант, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Vladislav R. Tsygankov — Master's Student, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0009-0006-2640-7919>

Автор для корреспонденции / Corresponding author:

244456@edu.fa.ru

Наталья Владимировна Гринева — кандидат экономических наук, доцент, доцент кафедры информационных технологий, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Natalia V. Grineva — Cand. Sci. (Econ.), Assoc. Prof., Assoc. Prof. of the Department of Information Technology, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0001-7647-5967>

ngrineva@fa.ru

Павел Евгеньевич Голосов — кандидат технических наук, директор Института общественных наук РАНХиГС, Москва, Российская Федерация

Pavel E. Golosov — Cand. Sci. (Tech.), Director of the Institute of Social Sciences, RANEPA, Moscow, Russian Federation

<https://orcid.org/0000-0003-4313-0887>

golosov-pe@ranepa.ru

Заявленный вклад авторов:

В.Р. Цыганков — аннотация, сравнительный анализ технологических решений для разработки мобильной автоматизированной инкассаторской системы.

Н.В. Гринева — разработка общей концепции статьи, исследование существующих подходов и технологических решений автоматизации инкассационного процесса.

П.Е. Голосов — введение, заключение, список литературы.

Authors' declared contributions:

V.R. Tsygankov — abstract, comparative analysis of technological solutions for developing a mobile automated cash collection system.

N.V. Grineva — development of the overall concept of the article; research into existing approaches and technological solutions for automating the cash collection process.

P.E. Golosov — introduction, conclusion, references.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов. Conflicts of Interest Statement: The authors have no conflicts of interest to declare.

Статья поступила 19.01.2026; после рецензирования 02.03.2026; принята к публикации 13.03.2026.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 19.01.2026; revised on 02.03.2026 and accepted for publication on 13.03.2026.

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

Управление рисками информационной безопасности систем электронного документооборота на основе нейросетевых моделей

Е.К. Баранова, Е.С. Крючков

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

В статье исследуется применение искусственных нейронных сетей в задачах управления рисками информационной безопасности систем электронного документооборота. Рассмотрены предпосылки перехода от традиционных средств защиты, основанных преимущественно на сигнатурных правилах и экспертных регламентах, к адаптивным моделям анализа событий безопасности. Особое внимание уделено специфике электронного документооборота как цифровой среды, в которой одновременно циркулируют юридически значимые документы, персональные данные, служебная переписка и технологические журналы. Показано, что рост объемов электронных документов, распределенность организационных процессов и усложнение сетевой инфраструктуры требуют пересмотра подходов к мониторингу и ранжированию угроз. В качестве перспективного направления предложена концепция нейросетевого риск-ориентированного контура, включающего сенсорный слой сбора событий, модуль интеллектуальной корреляции TrafficLLM и механизм непрерывного дообучения на основе параметрически эффективной адаптации EA-PEFT. Такая архитектура позволяет учитывать дрейф данных, выявлять нетиповые сценарии пользовательского и сетевого поведения, а также формировать оценку риска без существенного увеличения нагрузки на эксплуатационный персонал. Научная новизна работы заключается в представлении целостной модели применения нейросетевых технологий к управлению рисками информационной безопасности СЭД: от классификации организационных, административных, субъективных и технологических рисков до описания интеграции модели в инфраструктуру электронного документооборота. Практическая значимость состоит в возможности использования предложенного подхода в организациях с распределенной структурой, интенсивным обменом юридически значимыми электронными документами и повышенными требованиями к непрерывности бизнес-процессов.

Ключевые слова: информационная безопасность; защита информации; электронный документооборот; управление рисками информационной безопасности; нейросетевые модели; искусственный интеллект

Для цитирования: Баранова Е.К., Крючков Е.С. Управление рисками информационной безопасности систем электронного документооборота на основе нейросетевых моделей. *Цифровые решения и технологии искусственного интеллекта*. 2026;2(2):35-45. DOI: 10.26794/3030-7097-2026-2-2-35-45

ORIGINAL PAPER


Managing Information Security Risks of Electronic Document Management Systems Based on Neural Network Models

Е.К. Baranova, E.S. Kriuchkov

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

ABSTRACT

The article examines the use of artificial neural networks for managing information security risks in electronic document management systems. The paper considers the transition from traditional protection tools based mainly on signature rules and expert procedures to adaptive models for security event analysis. Particular attention is paid to the specifics of electronic document management as a digital environment that simultaneously processes legally significant documents, personal data, business correspondence and technological logs. The study shows that the rapid growth of electronic document flows, the distributed nature of organizational processes and the increasing complexity of network infrastructure require a revision of approaches to monitoring and prioritizing threats. As a promising solution, the article proposes a neural network-based risk-oriented security framework that includes a sensor layer for event collection, an intelligent TrafficLLM correlation module and a continuous retraining mechanism based on EA-PEFT parameter-efficient adaptation. This architecture makes it possible to take data drift into account, detect non-standard patterns of user



and network behavior, and generate risk assessments without significantly increasing the operational workload. The scientific novelty of the study lies in the development of an integrated model for applying neural network technologies to EDMS information security risk management: from the classification of organizational, administrative, subjective and technological risks to the description of model integration into electronic document management infrastructure. The practical significance consists in the possibility of applying the proposed approach in organizations with distributed structures, intensive circulation of legally significant electronic documents and strict requirements for business process continuity.

Keywords: information security; information protection; electronic document management; information security risk management; neural network models; artificial intelligence

For citation: Baranova E.K., Kriuchkov E.S. Managing information security risks of electronic document management systems based on neural network models. *Digital solutions and artificial intelligence technologies*. 2026;2(2):35-45. DOI: 10.26794/3030-7097-2026-2-2-35-45

ВВЕДЕНИЕ

Распространение электронного документооборота стало одним из заметных проявлений цифровой трансформации организационного управления. Системы электронного документооборота обеспечивают ускорение согласования материалов, упрощают поиск документов, повышают прозрачность управленческих процедур и позволяют переводить значительную часть юридически значимых операций в цифровую форму [1].

Вместе с тем повышение роли СЭД в деловой, административной и правовой коммуникации приводит к тому, что такие системы становятся критически важным элементом информационной инфраструктуры организации.

По мере увеличения объемов электронных документов расширяется и поверхность возможных атак. Угрозы могут возникать как вследствие технических уязвимостей, так и в результате ошибочных или умышленно нарушающих регламент действий пользователей. К числу наиболее существенных рисков относятся: несанкционированный доступ, компрометация учетных записей, нарушение целостности документов, утечка конфиденциальной информации, вредоносное изменение маршрутов согласования, а также отказ в обслуживании. В условиях распределенной работы, интеграции СЭД с внешними сервисами и активного обмена документами с контрагентами данные угрозы приобретают системный характер [2].

Традиционные средства защиты, основанные на статических правилах, сигнатурах и заранее заданных сценариях реагирования, сохраняют важное значение, однако их возможностей недостаточно для анализа динамически изменяющейся среды. Они требуют постоянной ручной актуализации, ограниченно реагируют на ранее неизвестные типы атак и не всегда позволяют установить связь между отдельными событиями, распределенными во времени и по различным подсистемам. В результате возрастает потребность в инструментах, которые способны выявлять скрытые зависимости в боль-

ших массивах сетевых, журнальных и поведенческих данных [3].

Искусственные нейронные сети обладают рядом свойств, делающих их применимыми к задачам информационной безопасности СЭД. Они способны обрабатывать разнородные данные, выявлять нелинейные зависимости, классифицировать события при неполноте исходной информации и адаптироваться к изменению профиля угроз. В отличие от локальных средств контроля, нейросетевой модуль может рассматриваться как элемент риск-ориентированного управления жизненным циклом электронного документа — от поступления и регистрации до согласования, подписания, архивирования и передачи адресату [4].

В настоящей работе анализируются методологические основания применения нейросетевых моделей в управлении рисками информационной безопасности СЭД. Рассматриваются основные направления использования ИНС в защитных системах, предлагается классификация рисков электронного документооборота, описывается модель TrafficLLM для выявления и прогнозирования инцидентов, а также формулируются требования к ее интеграции в инфраструктуру организации.

МЕТОДОЛОГИЧЕСКИЕ ОСНОВЫ ПРИМЕНЕНИЯ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

В ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТИ

Искусственные нейронные сети представляют собой класс математических моделей, ориентированных на обучение по данным и выявление зависимостей, которые не всегда могут быть формализованы традиционными аналитическими методами. В области информационной безопасности такие модели применяются для обнаружения вторжений, выявления аномального сетевого трафика, классификации событий безопасности, анализа поведения пользователей, прогнозирования инцидентов и поддержки принятия решений при реагировании на угрозы [5].



Ранние подходы к использованию ИНС в защитных системах были связаны главным образом с многослойными перцептронами и сравнительно небольшими наборами признаков. Такие решения применялись для бинарной классификации трафика и определения отклонений от условной нормы. В дальнейшем, по мере роста объемов журналов, сетевых пакетов и телеметрии, исследовательский интерес сместился к ансамблям нейронных сетей, самоорганизующимся картам, радиально-базисным сетям, рекуррентным моделям и глубоким архитектурам. Современный этап характеризуется использованием сверточных, рекуррентных и трансформерных моделей, позволяющих анализировать сложные последовательности событий и сохранять контекст взаимодействия пользователя, документа и сетевой сессии [6].

Для систем электронного документооборота выбор нейросетевой архитектуры должен опираться не только на показатели точности, но и на специфику данных, формируемых в процессе обращения электронных документов. В отличие от изолированных средств сетевого контроля, СЭД объединяет технологические журналы, сведения о правах доступа, маршруты согласования, данные средств аутентификации, параметры пользовательских действий и служебные признаки сетевого взаимодействия. Следовательно, применяемая модель должна быть рассчитана на обработку неоднородных источников, в которых числовые, категориальные и семантические признаки образуют единый контекст события [4].

Первым методологическим требованием выступает способность модели работать с гетерогенными данными. В контуре СЭД одно и то же событие безопасности может проявляться одновременно на нескольких уровнях: в сетевой сессии, в журнале приложения, в изменении маршрута документа и в действиях конкретного пользователя. Поэтому архитектура нейросетевого решения должна поддерживать согласованное представление различных типов признаков, чтобы анализировалось не отдельное техническое отклонение, а совокупность обстоятельств, указывающих на возможное нарушение режима защиты.

Вторым требованием является устойчивость к изменению эксплуатационной среды. Электронный документооборот не является статичным процессом: в организации меняются должностные роли, внутренние регламенты, состав контрагентов, типы документов и характер взаимодействия подразделений. В результате модель, обученная на историческом массиве данных, постепенно утрачивает соответствие текущим условиям эксплуатации. Для минимизации данного эффекта необходимы механизмы регулярного дообучения, позволяющие обновлять модель

ограниченными партиями данных без полного повторного обучения и без нарушения непрерывности работы СЭД [6].

Третьим значимым условием является интерпретируемость результатов. В сфере информационной безопасности решение модели может использоваться для ограничения операции, передачи события на расследование либо формирования управленческого вывода. Поэтому автоматическая классификация не должна оставаться полностью непрозрачной для специалистов. В практическом отношении необходимы инструменты объяснения результата: оценка вклада отдельных признаков, восстановление цепочки связанных событий, визуализация значимых элементов последовательности и подготовка отчетов, пригодных для последующего аудита.

Построение нейросетевого решения для СЭД может быть представлено как последовательный методологический цикл. На первом этапе формируется корпус данных, включающий штатные сценарии документооборота и известные отклонения от регламентной модели. На втором этапе выполняется очистка, нормализация, кодирование и приведение данных к представлению, пригодному для обучения. На третьем этапе проводится обучение и валидация модели с использованием метрик, отражающих не только общую точность, но и способность выявлять редкие инциденты: полноты, точности, F1-меры, ROC-AUC и macro-AUC. На четвертом этапе модель переводится в эксплуатационный контур, где контролируются качество предсказаний, задержка инференса, устойчивость к дрейфу и частота ложных срабатываний [6].

Сопоставление нейросетевых и традиционных методов показывает, что их противопоставление не является продуктивным (см. таблицу). Регламентные и сигнатурные механизмы обеспечивают формальную определенность контроля и эффективны при проверке известных сценариев угроз. Нейросетевые модели, напротив, более применимы в условиях больших потоков разнородных данных, когда риск проявляется не через единичный признак, а через совокупность взаимосвязанных отклонений. Поэтому наиболее обоснованным является гибридный подход, при котором традиционные средства защиты формируют нормативно-правовой и технический базис, а интеллектуальные модели дополняют его адаптивным анализом событий [7].

Таким образом, нейросетевые технологии целесообразно рассматривать как адаптивный аналитический слой информационной безопасности. Их применение в СЭД оправдано прежде всего в тех случаях, когда интенсивность документооборота, распределенность пользователей и разнообразие



потоков данных превышают возможности ручного анализа и статического контроля.

КЛАССИФИКАЦИЯ РИСКОВ СИСТЕМЫ ЭЛЕКТРОННОГО ДОКУМЕНТООБОРОТА

Риск-ориентированное управление информационной безопасностью СЭД требует предварительной классификации угроз и уязвимостей. Такая классификация позволяет установить, какие события должны фиксироваться средствами мониторинга, какие показатели следует передавать в нейросетевую модель и какие меры реагирования должны быть привязаны к определенным уровням риска [8].

В рамках данного исследования риски СЭД целесообразно сгруппировать в четыре взаимосвязанные категории: организационные, административные, субъективные и технологические.

Организационные риски

Организационные риски связаны с ошибками планирования, неясностью целей внедрения СЭД, несогласованностью действий подразделений и отсутствием единых регламентов электронного документооборота. Если организация не определяет порядок создания, согласования, подписания, хранения и архивирования электронных документов, то даже технически защищенная система может использоваться неэффективно. В подобных условиях возрастает вероятность дублирования документов, нарушения сроков обработки, конфликтов между подразделениями и неконтролируемого расширения прав доступа.

С точки зрения информационной безопасности организационные риски проявляются в разрыве между техническими возможностями СЭД и фактической дисциплиной ее эксплуатации. Например, отсутствие формализованного жизненного цикла документа затрудняет построение корректных профилей нормального поведения, а следовательно, снижает качество автоматического выявления аномалий.

Административные риски

Административные риски обусловлены недостаточным участием руководства в проектировании и контроле процессов электронного документооборота. Если внедрение СЭД воспринимается исключительно как техническая задача, без управленческого сопровождения, то снижается качество постановки требований, затягиваются сроки внедрения и ухудшается взаимодействие между ИТ-подразделениями, службой информационной безопасности и функциональными владельцами процессов.

К административным рискам также относится чрезмерная бюрократизация цифровых процедур. Парадоксально, но электронный документооборот

может не сокращать, а увеличивать нагрузку на сотрудников, если маршруты согласования построены без анализа реальных бизнес-процессов. Избыточное число согласующих лиц, дублирование функций и отсутствие ответственности за контроль доступа создают дополнительные уязвимости и повышают вероятность обхода регламентов.

Субъективные риски

Субъективные риски связаны с поведением, компетенциями и мотивацией пользователей. Они включают ошибки при работе с электронными документами, низкий уровень цифровой грамотности, неправильное использование электронной подписи, передачу учетных данных третьим лицам, сопротивление новым регламентам и умышленное нарушение правил обработки конфиденциальной информации.

Данная группа рисков особенно важна для СЭД, поскольку значительная часть инцидентов возникает не в результате сложной внешней атаки, а вследствие некорректных действий легитимных пользователей. Нейросетевые методы могут быть полезны для косвенной оценки таких рисков: они позволяют выявлять нетиповую активность пользователя, необычное время работы с документами, аномальные маршруты передачи файлов, нетипичный объем скачивания или изменение привычного поведения при согласовании документов [9].

Технологические риски

К технологическим рискам относятся нарушения, обусловленные нестабильностью или уязвимостью программно-аппаратной среды, в которой функционирует система электронного документооборота. В их состав входят отказы серверного оборудования, дефекты прикладного программного обеспечения, некорректная настройка баз данных, сбои сетевых компонентов, компрометация механизмов аутентификации, недостаточная надежность криптографической защиты, а также ошибки в организации резервного копирования. Последствия подобных нарушений могут затрагивать ключевые характеристики информационной безопасности, включая сохранение конфиденциальности сведений, неизменность электронных документов и доступность сервисов для легитимных пользователей.

В контексте СЭД технологические риски приобретают особую значимость, поскольку отказ или компрометация такой системы способны повлечь не только утрату либо искажение данных, но и нарушение установленного порядка юридически значимого документооборота. По этой причине защитный контур должен включать резервирование критически

Сравнение нейросетевых и традиционных методов в задачах информационной безопасности / A Comparison of Neural Network and Traditional Methods in Information Security Tasks

Критерий / Criterion	Нейросетевые методы / Neural Network Methods	Традиционные методы / Traditional Methods
Адаптация к изменению условий	Возможность дообучения и настройки под новые данные	Требуется ручное изменение правил и сигнатур
Работа с большими данными	Эффективны при наличии достаточного объема обучающих примеров	Ограничиваются сложностью правил и вычислительными ресурсами
Выявление неизвестных сценариев	Способны обнаруживать нетиповые паттерны поведения	Лучше работают с заранее описанными угрозами
Интерпретируемость	Требуют дополнительных средств объяснения результата	Обычно обладают более очевидной логикой принятия решения
Эксплуатационные требования	Нуждаются в MLOps-контуре, контроле качества данных и вычислительных ресурсах	Проще во внедрении, но сложнее масштабируются при росте сценариев угроз

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

важных компонентов, своевременное обновление программного обеспечения, разграничение прав доступа, постоянный анализ журналов событий, контроль целостности документов, применение электронной подписи и механизмы оперативного выявления аномальной активности.

Наряду с перечисленными угрозами необходимо отдельно учитывать риски, связанные с целенаправленными кибератаками. К ним относятся неправомерное получение доступа к документам, несанкционированное изменение или удаление файлов, атаки типа «отказ в обслуживании», фишинговые воздействия, захват привилегированных учетных записей, а также скрытое продвижение злоумышленника внутри информационной инфраструктуры организации. Эти угрозы требуют не только организационных мер, но и интеллектуального анализа событий в реальном времени.

Представленная классификация позволяет сформировать риск-карту СЭД. В такой карте каждое событие безопасности может быть связано с определенной группой рисков, уровнем критичности, набором контрольных признаков и сценарием реагирования. Нейросетевая модель в этом случае становится не изолированным детектором, а аналитическим инструментом, поддерживающим управление рисками на организационном, технологическом и поведенческом уровнях.

НЕЙРОСЕТЕВАЯ МОДЕЛЬ TRAFFICLLM ДЛЯ ОБНАРУЖЕНИЯ И ПРОГНОЗА ИНЦИДЕНТОВ

Переход от сигнатурных средств обнаружения вторжений к нейросетевым моделям изменяет логику

анализа событий безопасности. Если классическая IDS сопоставляет текущую активность с набором известных признаков атаки, то нейросетевая модель обучается выявлять статистически и семантически значимые отклонения от нормального поведения. Для систем электронного документооборота это особенно важно, поскольку инцидент может проявляться не в одном отдельном событии, а в совокупности действий: изменении маршрута документа, нетипичном доступе, аномальном объеме выгрузки, необычных сетевых соединениях и нарушении временного профиля пользователя [10].

В качестве интеллектуального ядра предлагается модель TrafficLLM. Она представляет собой трансформерную архитектуру, адаптированную для анализа сетевых и прикладных потоков, возникающих при эксплуатации СЭД. Основная идея модели состоит в объединении обработки сетевой телеметрии с интерпретацией контекста политики безопасности. Благодаря этому модель способна не только классифицировать трафик, но и соотносить наблюдаемое событие с допустимыми правилами обращения с документами.

Представление данных. На вход модели поступают данные из сетевых потоков, журналов приложений и событий безопасности. Для приведения трафика к форме, пригодной для обработки трансформером, используется доменная токенизация. Она позволяет представить сетевую сессию как последовательность токенов, отражающих структуру пакетов, параметры соединения, служебные признаки и метаданные. Такой подход полезен в условиях частичного шифрования трафика: модель анализирует не содержимое документа, а характери-



стики взаимодействия, что снижает риск раскрытия конфиденциальных данных [11].

Двухэтапное обучение. Обучение TrafficLLM может быть построено в два этапа. На первом этапе модель настраивается на понимание текстовых инструкций, политики безопасности и экспертных описаний сценариев риска. Это позволяет связать технические признаки события с управленческими формулировками: например, с ограничениями на передачу документов, правилами доступа или требованиями к обработке персональных данных [12].

На втором этапе проводится целевая настройка модели на размеченных наборах данных, отражающих классы сетевого трафика и событий, характерных для эксплуатации СЭД. В состав обучающей выборки целесообразно включать не только штатные операции, но и зафиксированные отклонения от нормального режима работы: нестандартные обращения к документам, подозрительные пользовательские сессии, нетипичные последовательности действий, индикаторы возможной утечки информации, а также попытки нарушения установленных регламентов обработки электронных документов.

Инкрементальная адаптация. Существенной характеристикой рассматриваемой модели является применение механизма EA-PEFT, ориентированного на параметрически эффективное обновление. Его использование позволяет корректировать не всю архитектуру модели, а ограниченный набор параметров, обеспечивающих приспособление к изменяющимся условиям эксплуатации. Благодаря этому сокращаются вычислительные затраты, снижается потребность в специализированных GPU-ресурсах и появляется возможность выполнять дообучение без продолжительного вывода сервиса из рабочего режима.

Для систем электронного документооборота инкрементальная адаптация имеет особую практическую значимость. Документооборот организации находится в постоянном изменении: обновляются шаблоны документов, трансформируется структура подразделений, расширяется круг контрагентов, корректируются маршруты согласования и порядок обработки материалов. Если модель не будет учитывать эти изменения, то число ложных срабатываний возрастет, а способность выявлять реальные инциденты снизится. EA-PEFT позволяет поддерживать актуальность модели при умеренных эксплуатационных затратах.

Конвейер обработки событий

Типовой конвейер TrafficLLM включает следующие этапы:

- получение зеркального сетевого трафика или экспортированных журналов СЭД;

- предварительную очистку, нормализацию и токенизацию событий;

- преобразование токенов в векторные представления;

- сопоставление текущего события с профилями нормальной активности;

- классификацию события как нормального, подозрительного или инцидентного;

- передачу оценки риска в SIEM, SOAR, внутреннюю панель мониторинга или систему уведомлений.

Результатом работы модели должна быть не только метка класса, но и риск-оценка, пригодная для управленческого реагирования. Например, событие может быть отнесено к низкому, среднему или высокому уровню риска в зависимости от типа документа, роли пользователя, времени операции, объема передаваемых данных и совпадения с известными сценариями угроз.

Функциональное назначение модели. TrafficLLM выполняет двойную функцию. С одной стороны, она выступает инструментом обнаружения инцидентов в реальном времени. С другой стороны, она поддерживает прогнозирование рисков, поскольку анализирует динамику поведения пользователей и подсистем. Если модель фиксирует постепенное отклонение от нормального профиля, это может служить основанием для профилактических мер: дополнительной проверки доступа, усиленной аутентификации, временного ограничения операции или передачи события специалисту по информационной безопасности.

Таким образом, TrafficLLM целесообразно рассматривать как модуль интеллектуальной корреляции событий. Его задача заключается не в замене всех существующих средств защиты, а в повышении связности и аналитической глубины риск-ориентированного мониторинга СЭД.

ИНТЕГРАЦИЯ МОДЕЛИ В ИНФРАСТРУКТУРУ СИСТЕМЫ ЭЛЕКТРОННОГО ДОКУМЕНТООБОРОТА

Эффективность нейросетевой модели в задачах защиты электронного документооборота определяется не только качеством ее классификационных решений, но и корректностью включения в существующую информационную среду организации. Для СЭД данный аспект имеет принципиальное значение, поскольку любые изменения в механизмах обработки документов затрагивают юридически значимые процедуры, сроки согласования, доступность сервисов и устойчивость управленческих процессов. Следовательно, внедрение интеллектуального модуля должно осуществляться не как изолированное техническое дополнение, а как часть общей архитекту-



ры управления рисками информационной безопасности [13].

Интеграция TrafficLLM в инфраструктуру СЭД может быть представлена как совокупность трех взаимодополняющих уровней: технологического, процессного и организационного. Такой подход позволяет связать технические механизмы обработки событий с регламентами документооборота и распределением ответственности между участниками эксплуатации.

Технологический уровень. На технологическом уровне внедрение модели включает последовательную реализацию четырех функциональных этапов: получение исходных данных, их предварительную обработку, выполнение инференса и передачу результатов в контур реагирования.

Сбор данных может осуществляться различными способами в зависимости от архитектуры СЭД и требований к защите персональных и служебных сведений. Одним из вариантов является анализ зеркального сетевого трафика, получаемого с использованием TAP/SPAN-механизмов. Данный подход позволяет наблюдать сетевые взаимодействия без прямого вмешательства в прикладное ядро СЭД и без дополнительной нагрузки на основной сервис. Однако его применение требует доступа к сетевой инфраструктуре, регламентированного обращения с потенциально чувствительными данными и предварительной оценки правовых ограничений.

Альтернативным вариантом является использование структурированных журналов приложений, баз данных, средств аутентификации и систем контроля доступа. Такой способ проще с точки зрения интеграции с прикладными компонентами, однако предполагает предварительную унификацию форматов, нормализацию записей и контроль полноты поступающих событий. В противном случае модель может получать фрагментарное представление о действиях пользователей и состоянии документооборота, что снижает достоверность риск-оценки.

Предобработка данных должна выполняться отдельным программным компонентом, преобразующим сетевые пакеты, журналы и события безопасности в единое представление. В малых и средних инфраструктурах такая функция может быть реализована в виде легкого сервиса, формирующего JSON-токены или иные стандартизированные структуры. В крупных организациях более оправданным является построение ETL-конвейера либо использование корпоративной шины сообщений, поскольку это обеспечивает масштабируемость, воспроизводимость обработки и возможность подключения дополнительных источников телеметрии.

Инференс целесообразно выносить за пределы прикладного ядра СЭД и размещать в изолированном

контейнере. Контейнерная реализация уменьшает риск влияния модели на работоспособность основной системы, упрощает горизонтальное масштабирование и позволяет обновлять адаптеры без остановки документооборота. Встраивание модели непосредственно в СЭД может сократить задержку обработки, однако такой вариант повышает требования к совместимости версий, усложняет сопровождение и делает обновление модели зависимым от цикла обновления основного программного продукта.

Передача результатов должна быть организована таким образом, чтобы риск-оценки могли использоваться как в автоматизированных средствах реагирования, так и в экспертном анализе. Для этого применимы брокеры сообщений, запись в специализированные таблицы базы данных, webhook-сигналы или интеграция с SIEM- и SOAR-платформами. Выбор конкретного механизма определяется требуемой скоростью реакции, уровнем зрелости инфраструктуры и необходимостью последующего аудита решений модели.

Процессный уровень. С процессной точки зрения TrafficLLM должна быть связана с жизненным циклом электронного документа. Наибольшая практическая ценность достигается в том случае, когда мониторинг охватывает не отдельный технический канал, а ключевые стадии движения документа: поступление, регистрацию, назначение маршрута согласования, внесение изменений, подписание, отправку адресату, архивирование и удаление.

На этапе регистрации входящих документов модель может использоваться для раннего выявления подозрительных вложений, нетиповых источников передачи, а также признаков сетевой активности, отличающейся от обычных профилей взаимодействия. На стадии согласования значимыми становятся отклонения от типовых маршрутов, необычная последовательность действий и доступ к документам, не соответствующий роли пользователя. На этапе подписания особое внимание должно уделяться корректности полномочий, времени операции и нетипичным сценариям применения электронной подписи. При рассылке документов модель может выполнять функцию дополнительного контроля утечек, фиксируя аномальный объем исходящих данных, необычные адресаты или нестандартные каналы передачи.

Результаты работы модели должны быть непосредственно связаны с регламентами реагирования. Низкий уровень риска может предполагать только регистрацию события и накопление статистики. Средний уровень риска предполагает информирование ответственного сотрудника, проведение дополнительной верификации операции либо применение усиленных механизмов аутентификации.



При высоком уровне риска событие может быть передано в SIEM/SOAR-контур, а соответствующее действие — временно ограничено до завершения проверки. В таких случаях также целесообразен запуск процедуры расследования инцидента с фиксацией связанных событий и оснований для принятого решения.

Использование дифференцированной шкалы реагирования позволяет избежать избыточной автоматизации защитных мер и снижает вероятность необоснованного прерывания легитимных операций. Для систем электронного документооборота это имеет особое значение, поскольку ошибочная блокировка процедуры согласования или подписания документа способна повлиять не только на ход внутреннего процесса, но и на юридическую значимость последующих действий.

Организационный уровень. Организационное сопровождение модели требует четкого распределения функций между ИТ-подразделением, службой информационной безопасности и владельцами соответствующих бизнес-процессов. ИТ-подразделение отвечает за устойчивость вычислительной среды, контейнерное развертывание, обновление программных компонентов, а также контроль производительности и доступности сервисов. Служба информационной безопасности отвечает за интерпретацию риск-оценок, настройку правил эскалации, анализ ложных срабатываний и разработку сценариев реагирования. Владельцы процессов документооборота участвуют в проверке корректности регламентов, определении критичных стадий обработки документов и оценке влияния защитных мер на производственные процедуры.

Отдельное значение имеет подготовка пользователей и администраторов. Сотрудники должны понимать, какие действия рассматриваются системой как потенциально рискованные, почему может потребоваться дополнительное подтверждение операции и каким образом следует работать с уведомлениями. Администраторы и специалисты по безопасности, в свою очередь, должны обладать навыками анализа отчетов модели, оценки причин срабатываний и использования инструментов объяснимости. Это позволяет снизить число ошибочных решений, связанных как с чрезмерным доверием к автоматической классификации, так и с игнорированием предупреждений системы.

MLOps-контур. Долговременная эксплуатация TrafficLLM требует формирования MLOps-контура, ориентированного на сопровождение модели после ее внедрения в производственную среду. Такой контур должен обеспечивать не только техническое развертывание модели, но и постоянный контроль

качества входных данных, версионирование базовой модели и адаптеров, мониторинг метрик классификации, оценку задержки инференса, журналирование решений и управление обучающими выборками.

Особое значение имеет наблюдение за дрейфом данных. Электронный документооборот в организации находится в состоянии постоянной трансформации: меняется круг пользователей, расширяется номенклатура документов, корректируются маршруты согласования, обновляется перечень внешних получателей и перестраивается характер сетевых взаимодействий. При отсутствии механизмов адаптации модель постепенно утрачивает соответствие фактической эксплуатационной среде, что может выражаться либо в росте числа ложных срабатываний, либо в снижении чувствительности к действительно значимым инцидентам [14]. Применение параметрически эффективной адаптации позволяет обновлять только ограниченную часть параметров модели, сохраняя при этом приемлемый уровень вычислительных затрат на регулярное дообучение.

С позиции обеспечения отказоустойчивости необходимо заранее предусмотреть резервирование узлов инференса, возможность быстрого возврата к предыдущей версии модели, а также периодическую проверку контрольных срезов эмбедингов. Такие меры поддерживают непрерывность мониторинга при отказах оборудования, некорректных обновлениях или временном снижении качества поступающей телеметрии. Дополнительно требуется организовать журналирование решений модели в формате, пригодном для последующего аудита: по каждому срабатыванию должны сохраняться исходные признаки, итоговая оценка риска, версия примененной модели и сценарий реагирования, использованный системой.

Рассмотренная концепция показывает, что нейросетевая модель в инфраструктуре СЭД должна использоваться не как самостоятельный экспериментальный классификатор, а как компонент комплексной системы управления рисками информационной безопасности. Ее основная ценность состоит в способности объединять разнородные признаки, выявлять связи между распределенными событиями и формировать риск-оценку с учетом контекста документа, пользователя, времени операции и стадии бизнес-процесса.

В отличие от классических механизмов контроля, ориентированных преимущественно на заранее заданные правила, TrafficLLM может фиксировать отклонения, которые не выражаются одним формальным признаком. Это особенно важно для инцидентов, развивающихся постепенно: компо-



метации учетной записи, подготовки к утечке данных, обхода маршрута согласования, нетипичного доступа к юридически значимым документам или скрытого перемещения злоумышленника внутри инфраструктуры [15].

Вместе с тем внедрение нейросетевого подхода не устраняет необходимости экспертного контроля. Качество решений зависит от полноты обучающего массива, корректности разметки, стабильности источников телеметрии и регулярности обновления модели. Нерепрезентативная выборка способна привести к снижению чувствительности к редким инцидентам либо к росту числа ложных тревог. Дополнительными ограничениями выступают потребность в вычислительных ресурсах, необходимость сопровождения модели и риск чрезмерного доверия к автоматической классификации.

Особое значение имеет интерпретируемость получаемых результатов. В сфере информационной безопасности автоматически сформированная оценка риска может стать основанием для ограничения пользовательской операции, инициирования внутренней проверки либо принятия управленческого решения. В связи с этим применение модели должно сопровождаться инструментами, позволяющими обосновать ее выводы: выделением наиболее значимых признаков, реконструкцией последовательности связанных событий, подготовкой экспертного пояснения и сохранением материалов, необходимых для последующего аудита.

Наиболее обоснованным представляется использование гибридной архитектуры защиты. В такой модели регламентные процедуры, статические правила и традиционные средства информационной безопасности формируют базовый уровень контроля, тогда как нейросетевой компонент дополняет его возможностями выявления аномалий, сопоставления разнородных событий и более гибкой оценки возникающих рисков. В такой схеме TrafficLLM не заменяет существующие механизмы информационной безопасности, а повышает их адаптивность и аналитическую глубину.

ВЫВОДЫ

Проведенное исследование подтверждает необходимость развития адаптивных механизмов защиты в системах электронного документооборота. Рост объемов документов, усложнение маршрутов согласования, распределенный характер работы пользователей и появление новых сценариев атак ограничивают эффективность исключительно статических методов контроля.

Классификация рисков СЭД на организационные, административные, субъективные и технологические категории позволяет сформировать основу риск-ориентированного мониторинга. Такая систематизация связывает технические события с управленческими последствиями и дает возможность оценивать не только сам факт отклонения, но и его значимость для конкретной стадии жизненного цикла электронного документа.


Модель TrafficLLM может использоваться как интеллектуальный модуль обнаружения и прогнозирования инцидентов. Применение доменной токенизации, трансформерной архитектуры и механизма EA-PEFT создает условия для обработки разнородных потоков данных, учета дрейфа концепций и оперативной адаптации к изменяющейся среде эксплуатации.

Интеграция модели в инфраструктуру СЭД должна осуществляться с учетом технологических, процессных и организационных требований. Наиболее обоснованным вариантом является контейнерное развертывание модели с подключением к зеркальному трафику или потокам журналов, передачей риск-оценок в SIEM/SOAR и сопровождением через MLOps-контур [13].

В целом сочетание регламентированной организационной модели, традиционных средств защиты и адаптивного нейросетевого анализа позволяет сформировать масштабируемый контур информационной безопасности СЭД. Такой контур обеспечивает не только выявление отдельных инцидентов, но и поддержку непрерывного управления рисками на всем жизненном цикле электронного документа.

СПИСОК ИСТОЧНИКОВ

1. Варфоломеева В.А., Иванова Н.А. Электронный документооборот, его преимущества, недостатки, риски. *Журнал прикладных исследований*. 2022;6-3:192-197. URL: https://doi.org/10.47576/2712-7516_2022_6_3_192
2. Бабаш А.В., Баранова Е.К. Актуальные вопросы защиты информации. Монография. М.: РИОР: ИНФРА-М; 2017. URL: <https://www.elibrary.ru/ykqffc>
3. Ковалев Е.А. Применение искусственных нейронных сетей в системах обеспечения информационной безопасности. *Безопасность. Управление. Искусственный интеллект*. 2022;4(4(4)):26-35. URL: <https://www.elibrary.ru/thnloh>
4. Микрюков А.А., Бабаш А.В., Сизов В.А. Классификация событий в системах обеспечения информационной безопасности на основе нейросетевых технологий. *Открытое образование*. 2019;23(1):57-63. URL: <https://doi.org/10.21686/1818-4243-2019-1-57-63>



5. Плугатарев А.В., Марухленко А.Л., Бугорский М.А., Булгаков А.С., Марченко М.А. Применение нейронных сетей в системах обеспечения информационной безопасности. *Безопасность информационных технологий*. 2021;28(3):73-80. URL: <https://doi.org/10.26583/bit.2021.3.06>
6. Большаков А.С., Хусаинов Р.В., Осин А.В. Обнаружение аномалий трафика с использованием нейронной сети для обеспечения защиты информации. *I-methods*. 2021;13:4. URL: <https://www.elibrary.ru/pkcxwm>
7. Хаджиева Л.К., Чадаев А.К. Кибербезопасность и искусственный интеллект: использование искусственного интеллекта для обнаружения и предотвращения кибератак. *Экономика и управление: проблемы, решения*. 2025;2-12(165):97-103. URL: <https://doi.org/10.36871/ek.up.p.r.2025.12.02.011>
8. Баранова Е.К., Крючков Е.С. Нейросетевой подход к минимизации рисков информационной безопасности систем электронного документооборота. В сб.: *Тенденции развития Интернет и цифровой экономики*. Симферополь; 2025;217-221. URL: <https://www.elibrary.ru/fdzhfk>
9. Саенко И.Б., Котенко И.В., Аль-Барри М.Х. Применение искусственных нейронных сетей для выявления аномального поведения пользователей центров обработки данных. *Вопросы кибербезопасности*. 2022;2(48):87-97. URL: <https://doi.org/10.21681/2311-3456-2022-2-87-97>
10. Симаворян С.Ж., Симонян А.Р., Попов Г.А., Улитина Е.И. Общая концепция выявления вторжений неизвестного типа на основе нейронных сетей. *Программные системы и вычислительные методы*. 2021;4:23-45. URL: <https://doi.org/10.7256/2454-0714.2021.4.37072>
11. Резник Д.В. Искусственные нейросети. Анализ возможностей использования в целях обеспечения информационной безопасности. *The Scientific Heritage*. 2021;67(1(67)):50-53. URL: <https://doi.org/10.24412/9215-0365-2021-67-1-50-53>
12. Осипова В.П. Применение нейронных сетей в сфере безопасности банковских систем. В сб.: *Фундаментальные и прикладные исследования в области экономики и финансов*. Орел; 2021;131-133. URL: <https://www.elibrary.ru/mxffbf>
13. Будзко В.И., Беленков В.Г., Королев В.И., Мельников Д.А. Особенности обеспечения информационной безопасности автоматизированных систем, использующих технологии нейронных сетей. *Системы высокой доступности*. 2023;19(3):5-17. URL: <https://www.elibrary.ru/qrerqd>
14. Жернова К.Н. Обзор применения нейронных сетей в информационной безопасности. *Информатизация и связь*. 2024;4:109-122. URL: <https://doi.org/10.34219/2078-8320-2024-15-109-122>
15. Фролов П.В., Чухраев И.В., Гришанов К.М. Применение искусственных нейронных сетей в системах обнаружения вторжений. *Системный администратор*. 2018;9(190):80-83. URL: <https://www.elibrary.ru/wlyfoj>

REFERENCES

1. Varfolomeeva V.A., Ivanova N.A. Electronic document management, its advantages, disadvantages, risks. *Journal of Applied Research*. 2022;6-3:192-197. (In Russ.). URL: https://doi.org/10.47576/2712-7516_2022_6_3_192
2. Babash A.V., Baranova E.K. Actual issues of information protection: A monograph. Moscow: RIOR: INFRA-M; 2017. URL: <https://www.elibrary.ru/ykqffc> (In Russ.).
3. Kovalev E.A. Application of artificial neural networks in information security systems. *Safety. Management. Artificial Intelligence*. 2022;4(4(4)):26-35. URL: <https://www.elibrary.ru/thnloh> (In Russ.).
4. Mikryukov A.A., Babash A.V., Sizov V.A. Classification of events in information security systems based on neural network technologies. *Open Education*. 2019;23(1):57-63. (In Russ.). URL: <https://doi.org/10.21686/1818-4243-2019-1-57-63>
5. Plugatarev A.V., Marukhlenko A.L., Bugorskiy M.A., Bulgakov A.S., Marchenko M.A. Application of neural networks in information security systems. *Information Technology Security*. 2021;28(3):73-80. (In Russ.). URL: <https://doi.org/10.26583/bit.2021.3.06>
6. Bolshakov A.S., Khusainov R.V., Osin A.V. Detection of traffic anomalies using a neural network to ensure information security. *I-Methods*. 2021;13:4. (In Russ.). URL: <https://www.elibrary.ru/pkcxwm>
7. Khadzhieva L.K., Chadaev A.K. Cybersecurity and artificial intelligence: the use of artificial intelligence to detect and prevent cyber attacks. *Economics and Management: Problems, Solutions*. 2025;2-12(165):97-103. (In Russ.). URL: <https://doi.org/10.36871/ek.up.p.r.2025.12.02.011>
8. Baranova E.K., Kryuchkov E.S. Neural network approach to minimizing information security risks of electronic document management systems. In: *Trends in the development of the Internet and the digital economy*. Simferopol; 2025;217-221. URL: <https://www.elibrary.ru/fdzhfk> (In Russ.).
9. Saenko I.B., Kotenko I.V., Al-Barry M.H. The use of artificial neural networks to detect abnormal behavior of users of data centers. *Cybersecurity Issues*. 2022;2(48):87-97. (In Russ.). URL: <https://doi.org/10.21681/2311-3456-2022-2-87-97>

10. Simavorian S.Zh., Simonyan A.R., Popov G.A., Ulitina E.I. The general concept of detecting intrusions of an unknown type based on neural networks. *Software Systems and Computational Methods*. 2021;4:23-45. (In Russ.). URL: <https://doi.org/10.7256/2454-0714.2021.4.37072>
11. Reznik D.V. Artificial neural networks. Analysis of the possibilities of using it to ensure information security. *The Scientific Heritage*. 2021;67(1(67)):50-53. (In Russ.). URL: <https://doi.org/10.24412/9215-0365-2021-67-1-50-53>
12. Osipova V.P. Application of neural networks in the field of banking system security. In: *Fundamental and Applied Research in Economics and Finance*. Orel; 2021;131-133. URL: <https://www.elibrary.ru/mxffb> (In Russ.).
13. Budzko V.I., Belenkov V.G., Korolev V.I., Melnikov D.A. Information security features of automated systems using neural network technologies. *High Availability Systems*. 2023;19(3):5-17. URL: <https://www.elibrary.ru/qrerqd> (In Russ.).
14. Zhernova K.N. Review of the use of neural networks in information security. *Informatization and Communication*. 2024;4:109-122. (In Russ.). URL: <https://doi.org/10.34219/2078-8320-2024-15-109-122>
15. Frolov P.V., Chukhraev I.V., Grishanov K.M. Application of artificial neural networks in intrusion detection systems. *System Administrator*. 2018;9(190):80-83. URL: <https://www.elibrary.ru/wlyfoj> (In Russ.).

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Елена Константиновна Баранова — доцент кафедры информационной безопасности факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Elena K. Baranova — 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
<http://orcid.org/0000-0003-4650-2623>

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

Егор Сергеевич Крючков — магистрант кафедры информационной безопасности факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Egor S. Kriuchkov — Master's Student, 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/0009-0001-0546-5419>
258918@edu.fa.ru

Заявленный вклад авторов:

Е.К. Баранова — разработка общей концепции статьи, методологические основания применения искусственных нейронных сетей к управлению рисками ИБ.

Е.С. Крючков — написание базовых разделов и рекомендации по интеграции модели в инфраструктуру системы электронного документооборота.

Authors' declared contributions:

E.K. Baranova — development of the general concept of the article, methodological foundations for applying artificial neural networks to information security risk management.

E.S. Kriuchkov — writing basic sections and recommendations for integrating the model into the electronic document management system infrastructure.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

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

Статья поступила 03.03.2026; после рецензирования 27.03.2026; принята к публикации 27.04.2026.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 03.03.2026; revised on 27.03.2026 and accepted for publication on 27.04.2026.

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



DOI: 10.26794/3030-7097-2026-2-2-46-56
УДК 004.891:37(045)

Мультимодальные чат-боты в цифровой образовательной среде: аналитический обзор

И.К. Степанян, М.Б. Хрипунова

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

В условиях цифровой трансформации российского образования, регламентируемой национальными проектами, особую актуальность приобретает внедрение интеллектуальных чат-ботов на базе больших языковых моделей (LLM). Исследование посвящено систематизации опыта применения мультимодальных чат-ботов в образовании и оценке перспектив их адаптации к российскому национальному мессенджеру MAX (VK). На основе анализа научных публикаций за период 2018–2025 гг. выявлены ключевые направления эффективного использования ботов: персонализированное обучение, автоматизация рутинных процессов, мгновенная обратная связь 24/7, геймификация и т.д. Определены оптимальные архитектурные решения, такие как гибридные системы (YaLM + RAG) и мультимодальная оркестрация (текст/графика/аудио). Выявлены ключевые риски и технические, педагогические, этические ограничения. Обозначены перспективы развития, к которым относятся: полный переход на отечественные LLM (GigaChat, Saiga), интеграция виртуальной и дополненной реальности (VR/AR) в образовательные чат-боты, создание федеральной платформы образовательных ботов, развитие дискуссионных площадок и систем подготовки педагогов для адаптации к цифровым инструментам. Статья будет полезна исследователям и практикам, интересующимся внедрением ИИ-технологий в образование, и закладывает основу для разработки новых образовательных решений на стыке педагогики и искусственного интеллекта.
Ключевые слова: чат-боты в образовании; мессенджер VK MAX; мультимодальные образовательные технологии; большие языковые модели; LLM-оркестратор; цифровая образовательная среда; искусственный интеллект

Для цитирования: Степанян И.К., Хрипунова М.Б. Мультимодальные чат-боты в цифровой образовательной среде: аналитический обзор. *Цифровые решения и технологии искусственного интеллекта*. 2026;2(2):46-56. DOI: 10.26794/3030-7097-2026-2-2-46-56

ORIGINAL PAPER

Multimodal Chatbots in the Digital Educational Environment: Analytical Review

I.K. Stepanyan, M.B. Khripunova

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

ABSTRACT

In the context of the digital transformation of Russian education, regulated by national projects, the adoption of intelligent chatbots based on large language models (LLMs) is becoming particularly relevant. The study aims to systematize the experience of using multimodal chatbots in education and assess the prospects for their adaptation to the Russian national messenger MAX (VK). Based on an analysis of scientific publications from 2018 to 2025, key areas for the effective use of bots have been identified: personalized learning, automation of routine processes, instant 24/7 feedback, gamification, etc. Optimal architectural solutions have been determined, such as hybrid systems (YaLM + RAG) and multimodal orchestration (text/graphics/audio). Key risks and technical, pedagogical, and ethical limitations have been identified. The prospects for development are outlined, which include: a full transition to domestic LLMs (GigaChat, Saiga), the integration of virtual and augmented reality (VR/AR) into educational chatbots, the creation of a federal platform for educational bots, and the development of discussion forums and a teacher training system for adapting to digital tools. This article will be useful for researchers and practitioners interested in the implementation of AI technologies in education and lays the groundwork for developing new educational solutions at the intersection of pedagogy and artificial intelligence.

Keywords: Chatbots in Education; VK MAX Messenger; Multimodal Educational Technologies; Large Language Models; LLM Orchestrator; Digital Educational Environment; Artificial Intelligence

For citation: Stepanyan I.K., Khripunova M.B. Multimodal chatbots in the digital educational environment: Analytical review. *Digital solutions and artificial intelligence technologies*. 2026;2(2):46-56. DOI: 10.26794/3030-7097-2026-2-2-46-56

© Степанян И.К., Хрипунова М.Б., 2026



ВВЕДЕНИЕ

В условиях активной цифровизации российского образования, регламентированной национальными проектами «Цифровая трансформация образования»¹ и «Образование»², особую актуальность приобретает внедрение интеллектуальных диалоговых систем на основе искусственного интеллекта (далее — ИИ). Чат-боты, оснащенные большими языковыми моделями³ (LLM), становятся ключевым инструментом автоматизации учебных процессов, сочетая гибкость взаимодействия с возможностью персонализации обучения. Современные LLM-боты способны не только обрабатывать текстовые запросы, но и оркестрировать мультимодальные функции — генерировать изображения, озвучивать ответы, подключать специализированные модули, например математические расчеты или визуализацию данных. Это особенно востребовано в образовании, где эффективность усвоения материала напрямую зависит от формата подачи информации. Параллельно с развитием ИИ наблюдается глобальный тренд на интеграцию образовательных технологий в мессенджер-экосистемы. В России таким платформенным решением возможно станет мессенджер VK Max⁴, призванный заменить зарубежные аналоги Telegram и WhatsApp. Мировой опыт подтверждает, что национальные мессенджеры с поддержкой ботов значительно упрощают внедрение цифровых инструментов в обучение. Так, в Китае широко используется мессенджер WeChat, в Японии — LINE, во Вьетнаме — Zalo, а в Южной Корее — KakaoTalk.

Целью настоящей работы является обобщение существующих подходов, решений, платформ и образовательных сценариев с использованием мультимодальных Telegram-ботов и LLM-оркестраторов, а также оценка их эффективности в цифровой образовательной среде.

Чтобы ответить на ключевой вопрос «Как мультимодальные LLM-боты в мессенджерах могут оптимизировать образовательный процесс?», мы сформулировали следующие задачи:

- отобрать и проанализировать научные публикации, описывающие применение чат-ботов в образовании, в том числе с ИИ-компонентами;
- классифицировать типовые сценарии использования таких ботов по предметным областям, функциям, целевой аудитории;
- обобщить данные об образовательных результатах и реакциях обучающихся/преподавателей при использовании ботов;
- обозначить ограничения и риски, связанные с интеграцией мультимодальных ботов в процесс обучения.

СТРАТЕГИЯ ОТБОРА И АНАЛИЗА НАУЧНЫХ ПУБЛИКАЦИЙ

Для решения поставленных задач в качестве исходных данных были отобраны научные статьи и обзоры, диссертационные исследования, описания практического опыта за период 2018–2025 гг., отражающие опыт использования чат-ботов и ИИ-технологий в образовании. Этот временной диапазон охватывает ключевые этапы развития технологии:

- первые эксперименты с чат-ботами в учебных процессах 2018–2020 гг.;
- внедрение простых ИИ-модулей 2021–2022 гг.;
- применение мультимодальных LLM, таких как GPT-4, YaLM и GigaChat, 2023–2025 гг.

Ключевыми базами данных и поисковых систем для подбора литературы стали: Scopus, Web of Science, RSCI (eLibrary), Google Scholar, а также профильные репозитории (ResearchGate, arXiv) для самых новых работ.

Критериями отбора источников в обзор были:

- фокус на образовательном использовании чат-ботов или ИИ-ботов;
- наличие сведений о влиянии этих ботов на обучение, например экспериментальные данные об успеваемости, опросы удовлетворенности, метрики вовлеченности;
- для источников технического профиля — описание архитектур решений с мультимодальностью или LLM.

Из подборки исключены теоретические работы без апробации и исследования вне образовательного контекста. Кроме того, были выявлены объективные ограничения отбора, такие как неполнота данных (только 31% работ содержат количественные метрики эффективности), различия в дизайне исследований затрудняющие сравнение.

Отметим, что базой для изучения материала послужили мета-обзоры. Из 500 первоначально найденных источников было отобрано 50 релевантных публикаций. При этом мы рассматривали категории, описанные в *табл. 1*.

¹ Распоряжение Правительства РФ от 29.12.2021 № 3829-р «Об утверждении Стратегии цифровой трансформации отраслей экономики, социальной сферы и государственного управления». URL: <http://static.government.ru/media/files/gJkHwXKAQMNsDQdD1tA5L5A1BwNzQO0.pdf>

² Распоряжение Правительства Российской Федерации от 22.11.2023 № 3274-р «Об утверждении национального проекта «Образование»». URL: <http://publication.pravo.gov.ru/Document/View/0001202311220001>

³ Определение Большой языковой модели. URL: https://ru.wikipedia.org/wiki/Большая_языковая_модель

⁴ Стратегия развития российского сегмента интернета (Рунета) на период до 2030 года. URL: <https://digital.gov.ru/uploaded/files/strategiya-razvitiya-runeta-do-2030-goda.pdf>




Таблица 1 / Table 1

Классификация исследований /
Classification of Research

Категория / Category	Ключевые работы (№) / Key Works (No.)	Количество / Quantity
1. Нормативные документы	[1–4, 6]	5
2. Общие исследования	[1–6]	6
3. Исследования по генеративному ИИ в образовании	[7–14]	8
4. Предметное применение	[15–22]	8
5. Риски цифрового образования	[23–28]	6
6. Образовательные технологии	[29–36]	8
7. Психологические и социальные аспекты взаимодействия с ботами	[37–43]	7
8. Технические аспекты	[44–50]	7

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

География исследований, представленных в списке источников, охватывает различные страны и регионы, что отражает глобальный интерес к теме цифровизации образования, искусственного интеллекта и чат-ботов во всем мире в последние годы. Основные страны, фигурирующие в источниках: Австралия, Великобритания, Вьетнам, Германия, Индия, Индонезия, Иран, Испания, Италия, Канада, Китай, Малайзия, Нигерия, Нидерланды, Россия, США, ЮАР.

Заметим, что анализ научной литературы выявил три ключевых тренда:

- рост использования LLM в ботах (2023–2025 гг.: +40% публикаций);
- преимущество гибридных систем (RAG + модули);
- дефицит исследований по школам и СПО.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Сценарии и области применения чат-ботов в образовании

Анализ современных практик выявил широкое распространение прежде всего Telegram-ботов во всех звеньях образовательной системы — от школ до вузов. Наибольшую эффективность де-

монстрируют кейсы, требующие интерактивного взаимодействия и оперативной обратной связи. Результаты систематизации представлены в табл. 2.

Приведем несколько примеров использования ключевых кейсов эффективности.

Языковое обучение. Исследование Syahreza и Hartina [15] зафиксировало рост среднего балла по письму на 18,7% после внедрения специализированного бота для индонезийских школьников. Аналогично, бот, описанный Kovtun и соавторами [18], через автоматизированную корректировку ошибок, ситуативные диалоги, геймифицированные упражнения повысил уверенность студентов в языковой практике.

Поддержка вузовских курсов. Многие преподаватели внедряют Telegram-боты в рамках своих предметов для расширения возможностей LMS (Learning Management System), таких, как электронная обучающая среда Moodle. Бот может рассылать студентам учебные материалы, напоминания о дедлайнах, ссылки на ресурсы. Такие электронные учебные курсы для изучения дисциплин математического блока внедрены в учебную практику Финансового университета при Правительстве РФ с 2018 г. [29].

Кроме того, боты часто используются для проведения викторин, тестов и опросов в интерактивной форме [20].

Интеграция бота в курс позволяет персонализировать обучение. Студенты, стесняясь лишнего раз беспокоить преподавателя, охотно спрашивают бота и получают разъяснения, что поддерживает их при самостоятельной работе.

STEM-образование. Итальянский проект астрономических ботов *Astrophysical Cody Maze*, *International Code Hunting Game*, *Astro-Tamagotchi* [20] показал на выборке из 1400+ участников образовательных квестов повышение интереса к астрофизике среди школьников на 52% и эффективность игровых технологий.

Административная автоматизация. Вьетнамский чат-бот для приемной комиссии [19, 36] подтвердил, что бот приемной комиссии обработал 89% типовых вопросов абитуриентов, снизил нагрузку на сотрудников на 35% и обеспечил круглосуточную поддержку.

Отметим, что чат-боты наиболее востребованы сегодня для формирования практических навыков, оперативной обратной связи и, в целом, индивидуализации обучения [11]. Перспективным направлением является интеграция LLM для RAG-поиска (Retrieval Augmented Generation — простой обширный поиск) учебных материалов.

**Классификация образовательных сценариев использования Telegram-ботов /
Classification of Educational Scenarios for Using Telegram Bots**

Область применения / Scope of Application	Характеристики / Characteristics	Примеры реализации / Implementation Examples Translation
Изучение иностранных языков	• Интерактивные упражнения; • автоматическая проверка письменных работ; • разговорная практика	Бот для смешанного обучения [13, 14]. Тренажер письменного английского [15, 30]
Поддержка учебных курсов	• Интеграция с LMS; • тестирование и опросы; • персональные консультации	Бот-ассистент в LMS Moodle [29, 35, 45]. Викторины по дисциплинам [18, 20, 42]
STEM-образование	• Визуализация концепций; • программирование; • виртуальные лаборатории	Астрономический бот [20]. Тренажер математических задач [27, 31, 34]
Административная поддержка	• Расписание; • напоминания; • консультирование абитуриентов	Бот приемной комиссии [24, 36]. FAQ-системы для студентов [36]

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

Интеграция больших языковых моделей: роль LLM-оркестраторов

Современные образовательные чат-боты перешли от простых сценариев «вопрос-ответ» к сложным интеллектуальным системам благодаря интеграции больших языковых моделей (LLM). Эти модели выступают в роли когнитивного ядра, обеспечивая три ключевые функции: прямое API-подключение, генерация контента, мультимодальная оркестрация (табл. 3).

Прямое подключение LLM через API. В работе [18] отмечается, что LLM позволяет давать точные и обоснованные ответы, минимизируя риск ошибок, свойственных открытым моделям. Примером может служить бот МГИМО⁵.

LLM как генератор дидактического контента. Другой вариант использования — генерация индивидуальных заданий и примеров, объяснений. В статье S.V. Fulgencio [44] описывается как бот с LLM может каждому ученику сформулировать свой вариант вопроса или задачи, учитывая уровень подготовки. Исследование Калифорнийского технологического института (2025 г.) показало, что студенты, использовавшие ChatGPT для подготовки к экзаменам по математическому анализу, улучшили средний балл на 23% по сравнению с контрольной группой⁶.

⁵ Бот МГИМО. URL: <https://smc.mgimo.ru/news/sobytiya/telegram-bot-mgimo-life>

⁶ Роль ChatGPT в современном образовании. URL: <https://>

Оркестрация мультимодальных функций.

LLM может управлять не только текстовым диалогом, но и решать, какой канал информации задействовать. Например, если студенту нужен график, он может вызвать подходящую библиотеку построения графиков и отправить его изображение в чат. Существуют открытые модели Silero для распознавания и синтеза русской речи, которые интегрируются в чат-боты⁷. Такие LLM могут выступать центральным «разумом», направляющим данные через нужные модули и объединяющим результаты в связный ответ.

В рамках нашего обзора мы констатируем, что пока лишь закладываются основы таких сложных систем, но в ближайшем будущем они могут стать реальностью.

В табл. 4 представлены характеристики методов внедрения LLM в образовательный процесс, полученные из анализа многих источников и характеристик, описанных в официальных документах. Согласно этим данным, для российского образования оптимальны гибридные системы с локальными LLM (YaLM) для обработки запросов, облачными API для сложных вычислений.

В современных условиях ключевое значение приобретает развитие русскоязычных языковых

gpt-chatbot.ru/rol-chatgpt-v-sovremennom-obrazovanii-personalnyj-repetitor-dlya-slozhnyh-disciplin-i-instrument-razvitiya-kriticheskogo-myshleniya#

⁷ Открытые модели Silero. URL: <https://silero.ai/>




Таблица 3 / Table 3

Архитектурные подходы к интеграции LLM в образовательные боты /
Architectural Approaches to Integrating LLM into Educational Bots

Подход / Approach	Характеристики / Characteristics	Реализация / Implementation
Прямое API-подключение	- Доступ к облачным LLM (GPT-4, GigaChat); - быстрое развертывание; - зависимость от интернета	LangChain [36, 37]. Бот-консультант ВШЭ*
Генерация контента	- Создание персонализированных заданий; - адаптивные объяснения; - формирование учебных траекторий	GPT-тренажер [6, 7, 39, 47, 48]. Бот-репетитор МГУ**
Мультимодальная оркестрация	- Координация текста/графики/аудио; - интеграция с внешними API; - сборка комплексных ответов	Психологический бот МФТИ*** Астрономический симулятор @CosmoBot****

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

Примечания / Notes: * URL: <https://www.hse.ru/news/priority/1010385434.html>; ** URL: <https://mentormsu.com/>; *** URL: <https://mipt.ru/news/v-mfti-sozdali-chat-bota-dlya-upravleniya-emotsiyami-i-borby-so-strakhami>; **** Астрономический симулятор. URL: <https://cosmobot.in/>

моделей (GigaChat⁸, Saiga⁹) и их интеграция с учебными материалами через RAG-архитектуры, что позволит обеспечить достоверность контента, соответствие образовательным стандартам и адаптацию под специфику российского образования [17]. Для реализации этих задач необходимо объединение усилий разработчиков, педагогов и методистов, чтобы создать эффективные инструменты, сочетающие передовые ИИ-технологии с проверенными академическими знаниями и учитывающие возрастные особенности учащихся. Ключевыми задачами на 2025–2026 гг. станут внедрение автономных цифровых тьюторов, интеграция VR-технологий с LLM для интерактивного обучения и полный переход на отечественные API-решения в образовательной сфере.

⁸ Гига-чат. URL: <https://giga.chat/>

⁹ Русский LLM-помощник (saiga) с кэшем. URL: <https://habr.com/ru/articles/769124/>

Педагогическая эффективность
и влияние на учебный процесс

Системный анализ исследований 2018–2025 гг. выявил значимые количественные показатели эффективности применения чат-ботов на ключевые образовательные метрики.

Академическая успеваемость в языковом обучении: прирост письменных навыков до 29% отмечается в исследовании [15], улучшение устной речи на 37% в исследовании Zhou [30]. В точных науках: повышение успешности решения задач фиксируется в исследовании [22], лучшее понимание абстрактных концепций у Sandri [20]. В этом же исследовании показано, что игровые технологии увеличивают мотивацию и вовлеченность учащихся; частоту взаимодействий (до 5,7 сеансов/нед.). В статье [38] описывается снижение стресса перед тестами и уменьшение тревожности на 22% при общении с чат-ботом. Персонализированное

Таблица 4 / Table 4

Сравнение параметров интеграции LLM в образовательный процесс /
Comparison of Parameters for Integrating LLM into the Educational Process

Параметр / Parameter	Прямое API / Direct API	Локальная LLM / Local LLM	Гибридная система / Hybrid System
Скорость ответа (с)	1–3	5–10	2–5
Точность (%)	85–92	78–85	89–95
Соответствие Закону о персональных данных*	Риск утечек	Полное	Частичное

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

Примечания / Notes: * Федеральный закон от 27.07.2006 № 152-ФЗ «О персональных данных». URL: <https://base.garant.ru/12148567/>



обучение с помощью адаптивных систем демонстрирует в среднем снижение времени освоения тем на 18–25%, возможность мгновенной обратной связи. Так, например, в исследовании Van der Kleij [42] сообщается об уменьшении ошибок при повторении на 63%.

Авторы исследуемых работ отмечают, что использование ботов в образовании является существенной поддержкой преподавателей в плане автоматизации рутины. В частности, Labadze [8] пишет о сокращении времени проверки ученических работ на 65%, обработка типовых вопросов сокращается на 89%. В среднем более 80% рутинных работ можно поручить ИИ-боту.

В электронной библиотеке Финансового университета можно найти множество научных работ студентов и преподавателей, посвященных разработке и применению чат-ботов, роботизации бизнес-процессов и использованию искусственного интеллекта в различных сферах. Так, студенты и преподаватели факультета информационных технологий и анализа больших данных Финансового университета активно занимаются разработкой ботов и сервисов для платформы МАХ. Наиболее яркий пример — победа команды вуза на всероссийском хакатоне с проектом «Цифровой кампус»¹⁰.

Развитие бот-экосистем имеет региональные особенности. Так, в развивающихся странах, таких как Нигерия или Индонезия, большинство населения имеют смартфоны и не имеют компьютеры. В этих странах развитие мобильных ботов может увеличить охват образования в 3,2 раза, снизить стоимость обучения на 45%, обеспечить доступ в сельских районах [4, 30, 35].

Однако мета-анализ [6] и систематические обзоры [1–5] показывают, что 23% ботов не дали глобального эффекта. Наибольшая эффективность была достигнута в языковом обучении, минимальный эффект — в гуманитарных дисциплинах, но все сходится к мнению, что использование чат-ботов уменьшает неравенство образования.

Обсуждение: ограничения и риски

при использовании мультимодальных LLM-ботов

Несмотря на перечисленные достоинства, анализ источников и учебная практика выявили и ряд проблемных моментов. К техническим и содержательным рискам относятся **ошибки в фактах**, известные как «галлюцинации» [9, 25, 50], которые достигают 15–20% в открытых моделях, а также

некорректные решения математических задач. Поэтому требуется внедрение механизмов валидации ответов. Один из подходов — ограничивать знание бота рамками утвержденных учебных материалов. Например, бот черпает информацию только из учебника курса, а не из всего интернета. Однако для Telegram-бота такая практика еще не стала массовой. Ответственность за надежность и точность ответов лежит на разработчиках.

Внедрение ИИ в образовательный процесс несет и **этические риски**. К ним относятся: нарушение приватности, утечка персональных данных [26, 28]; академическое мошенничество [10, 14, 23–25], предвзятость и инклюзия [33]. По данным обзоров, вопросы этики и ответственности — одни из наиболее обсуждаемых применительно к ИИ в образовании. Пока нет единых стандартов, учреждения самостоятельно регулируют эти моменты, не редко вплоть до запрета пользования ChatGPT на экзаменах. Для уменьшения таких рисков необходимо, на наш взгляд, шифрование данных (по примеру ГОСТ 57580¹¹), прокторинг для итоговой аттестации, регулярный аудит контента.

Очевидно, что **технические ограничения и доступность** также являются объективной реальностью [4, 35, 41, 43]. Проблемы касаются технической инфраструктуры, например, нестабильный интернет в регионах или высокая стоимость API GPT-4 [30]. Решение этих проблем в применении offline-режима и, конечно, господдержка [32, 39].

Педагогические риски, или методическая адаптация педагогов. Ключевые барьеры здесь — это неготовность педагогов, отсутствие ИИ-компетенций, сопротивление изменениям [9, 39]. Пути решения мы видим в разработке и внедрении соответствующих программ повышения квалификации, гибридных форматов обучения тьютор+бот, геймификации обучения для преподавателей, разработке стандартов Минпросвещения России, сертификации образовательных ботов [12, 20, 26, 39].

Итак, преодоление ограничений требует: системного подхода, включающего технические решения; методическую поддержку педагогов; государственное регулирование.

Многое уже делается — квантовое шифрование данных в экспериментах РКЦ, Федеральная

¹⁰ URL: <https://www.fa.ru/university/press-center/studenty-finansovogo-universiteta-pobediteli-studencheskogo-khakatona-po-razrabotke-servisov-dlya-me>

¹¹ ГОСТ Р 57580.1–2017. Национальный стандарт Российской Федерации «Безопасность финансовых (банковских) операций. Защита информации финансовых организаций. Базовый состав организационных и технических мер» (утв. и введен в действие Приказом Росстандарта от 08.08.2017 № 822-ст). URL: <https://regulhub.kaspersky.ru/upload/iblock/71a/k99732yk7w1rrz8d3yg3y4hwqzm8g8bcw.pdf?ysclid=mo2q9p2llt210615266>



платформа образовательных ботов, ИИ-ассистенты для учителей по аналогии с «Киберучитель» СберОбразования¹².

ВЫВОДЫ И ПЕРСПЕКТИВЫ РАЗВИТИЯ ОБРАЗОВАТЕЛЬНЫХ LLM-БОТОВ

Мультимодальные ИИ-боты с LLM-оркестраторами доказали свою **эффективность** как платформы интерактивного обучения с адаптацией контента под уровень знаний и мгновенной обратной связью. Чат-боты на базе LLM демонстрируют значимое улучшение образовательных результатов: +29% успеваемости по языкам; +41% усвоения STEM-дисциплин; снижение нагрузки на преподавателей более 80%.

Для наибольшего успеха применения необходимы: **синергия «преподаватель+бот»** (модель MGIMO), использование RAG (Retrieval-Augmented Generation) — архитектуры для достоверности, интеграция с национальным мессенджером Max. А также методическая поддержка — создание центров компетенций при вузах (по аналогии с НИТУ «МИСиС»¹³), разработка типовых сценариев для разных дисциплин, пилотные проекты с обязательным обучением педагогов.

При создании технологической платформы должен учитываться приоритет российских решений: языковые модели: GigaChat, YaL M. Хостинг: Сбе-рОблако, VK Cloud и интеграция с государственными

ми сервисами (МЭШ¹⁴, Сферум¹⁵). Целесообразно разбить инфраструктуру внедрения на 3 этапа: тестирование в вузах/школах, формирование нормативной базы и массовое масштабирование.

Для успешной интеграции цифровых технологий во все образовательные учреждения России необходимо создавать и активно развивать профессиональные дискуссионные площадки среди педагогов. В этой связи предлагаем создать консорциум вузов (Финуниверситет, МФТИ, ВШЭ, ИТМО) с фокусом на развитие и исследование в области образовательных ботов, привлечение школьников, учителей, студентов и преподавателей через участие в конкурсах и вебинарах к разработке и созданию образовательной чат-бот экосистемы с единым маркетплейсом сертифицированных решений и межвузовской базой учебных ИИ-модулей.

По нашим оценкам современной ситуации, к 2030 г. чат-боты могут стать: стандартным инструментом в 80% вузов, основным каналом консультаций для школьников, интегратором всех цифровых образовательных сервисов.

Итак, ответственное внедрение LLM-ботов **требует баланса между инновациями и педагогической традицией** [40, 46]. При сохранении текущих темпов развития к 2030 г. Россия может занять лидирующие позиции в области: персонализированного обучения через мессенджеры; мультимодальных образовательных систем; этичного использования ИИ в педагогике.

¹² СберОбразование. URL: <https://sbereducation.ru/>

¹³ Тестирование и развитие компетенций МИСиС. URL: <https://misis.ru/university/struktura-universiteta/centers/career-center/competencies>


¹⁴ Московская электронная школа. URL: <https://www.mos.ru/city/projects/mesh/>

¹⁵ Единое безопасное пространство для общения по учебе. URL: <https://www.sferum.ru/>

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Gregorac A., Brünner B., Ebner M. Chatbots in Education: A Systematic Rapid Literature Review. In: Proceedings of Society for Information Technology & Teacher Education International Conference. Orlando. 2025:652-657. URL: <https://www.learntechlib.org/p/225579>
2. Debets T., Banihashem S.K., Brinke D., Vos T., Maillette de Buy Wenniger G., Camp G. Chatbots in education: A systematic review of objectives, underlying technology and theory, evaluation criteria, and impacts. *Computers and Education*. 2025;234:105323. URL: <https://doi.org/10.1016/j.compedu.2025.105323>
3. Bekkar H.-A., Chtouki Y. Chatbots in Education: A Systematic Literature Review. In: 2024 10th International Conference on Smart Computing and Communication (ICSCC). 2024:637-644. URL: <https://doi.org/10.1109/ICSCC62041.2024.10690334>
4. Okonkwo C.W., Abejide A. Chatbots applications in education: A systematic review. *Computers and Education: Artificial Intelligence*. 2021;2:100033. URL: <https://doi.org/10.1016/j.caeai.2021.100033>
5. Wollny S., Schneider J., Di Mitri D., Weidlich J., Rittberger M., Drachsler H. Are We There Yet? — A Systematic Literature Review on Chatbots in Education. *Frontiers in Artificial Intelligence*. 2021;4:654924. URL: <https://doi.org/10.3389/frai.2021.654924>
6. Liu Zh., Zuo H., Lu Yo. The Impact of ChatGPT on Students' Academic Achievement: A Meta-Analysis. *Journal of Computer Assisted Learning*. 2025;41(4): e70096. URL: <https://doi.org/10.1111/jcal.70096>

7. Магомедов Р.М. Влияние искусственного интеллекта на цифровую трансформацию бизнеса в России. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(4):69-75. URL: <https://doi.org/10.26794/3033-7097-2025-1-4-69-75>
Magomedov R.M. Impact of Artificial Intelligence on the Digital Transformation of Business in Russia. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(4):69-75. (In Russ.). URL: <https://doi.org/10.26794/3033-7097-2025-1-4-69-75>
8. Labadze L, Grigolia M., Machaidze L. Role of AI Chatbots in Education: Systematic Literature Review. *International Journal of Educational Technology in Higher Education*. 2023;20:56. URL: <https://doi.org/10.1186/s41239-023-00426-1>
9. Бермус А.Г. Преимущества и риски использования ChatGPT в системе высшего образования: теоретический обзор. *Педагогика. Вопросы теории и практики*. 2024;9(8):776-787. URL: <https://doi.org/10.30853/ped20240099>
Bermus A. G. Benefits and risks of using ChatGPT in higher education: A theoretical review. *Pedagogy. Theory and Practice*. 2024;9(8):776-787. (In Russ.). URL: <https://doi.org/10.30853/ped20240099>
10. Baidoo-Anu D., Owusu Ansah L. Education in the Era of Generative AI: ChatGPT's Impact on Learning. *Journal of AI*. 2023;7(1):52-62. URL: <https://doi.org/10.1007/s10639-023-12114-8>
11. Gill S.S., Xu M., Patros P., Wu H., Kaur R., Kaur K., et al. Transformative effects of ChatGPT on modern education: Emerging Era of AI Chatbots. *Internet of Things and Cyber-Physical Systems*. 2024;4:19-23. URL: <https://doi.org/10.1016/j.iotcps.2023.06.002>
12. Su J., Yang W. Unlocking the Power of ChatGPT: A Framework for Applying Generative AI in Education. *ECNU Review of Education*. 2023;6(3):355-366. URL: <https://doi.org/10.1177/20965311231168423>
13. Shoufan A. Exploring Students' Perceptions of ChatGPT: Thematic Analysis and Follow-Up Survey. *IEEE Access*. 2023;11:38805-38818. URL: <https://doi.org/10.1109/ACCESS.2023.3268224>
14. Shuhaiber A., Kuhail M.A., Salman S. ChatGPT in Higher Education — a Student's Perspective. *Computers in Human Behavior Reports*. 2025;17:100565. URL: <https://doi.org/10.1016/j.chbr.2024.100565>
15. Syahreza, St. Hartina. Teaching Writing through Telegram Bot: The Impact on Students Writing Performance. *JLE: Journal of Literate of English Education Study Program*. 2023;4(1):1-8. URL: <https://doi.org/10.47435/jle.v4i01.2091>
16. Abu-Ayfah Z.A. Telegram App in Learning English: EFL Students' Perceptions. *English Language Teaching*. 2019;13(1):51-62. URL: <https://doi.org/10.5539/elt.v13n1p51>
17. Ослякова И.В. Перспективы обучения языкам с применением Телеграм бота и пользовательского контента. *Образование и право*. 2023;(7):334-341. URL: <https://doi.org/10.24412/2076-1503-2023-7-334-341>
Osliakova I. V. Prospects for language learning using a Telegram bot and user content. *Education and Law*. 2023;(7):334-341. (In Russ.) URL: <https://doi.org/10.24412/2076-1503-2023-7-334-341>
18. Kovtun L., Lazareva A., Polyanskaya E. Telegram Chatbot as an Educational Tool in Blended Learning Environment. *EDULEARN21 Proceedings*. 2021:9189-9193. URL: <https://doi.org/10.21125/edulearn.2021.1851>
19. Nguyen M-T., Tran-Tien M., Viet A.P., Vu., Nguyen V.-H. Building a Chatbot for Supporting the Admission of Universities. In: 2021 13th International Conference on Knowledge and Systems Engineering (KSE). 2021:1-6. URL: <https://doi.org/10.1109/KSE53942.2021.9648677>
20. Sandri M., Bogliolo A., Klopfenstein L. C., et al. The International Astrophysical Online Code Hunting Game and the Astrophysical Cody Maze. *Memorie della Società Astronomica Italiana*. 2023;94(1):128. URL: https://doi.org/10.36116/MEMSAIT_94n1.2023.128
21. Маликова М.Г. Речевой этикет в цифровую эпоху: роль телеграм-ботов в иноязычном образовании. *Восточно-европейский научный журнал*. 2024;1(09(106)):27-29. URL: <https://doi.org/10.31618/ESSA.2782-1994.2024.1.106.508>
Malikova M. G. Speech etiquette in the digital age: the role of Telegram bots in foreign language education. *East European Scientific Journal*. 2024;1(09(106)):27-29. (In Russ.). URL: <https://doi.org/10.31618/ESSA.2782-1994.2024.1.106.508>
22. Гуляева Ч.И., Попова А.М. Опыт применения образовательного телеграмм-бота на уроках математики в 5 классе. В сб.: Проблемы современного педагогического образования. Ялта: РИО ГПА; 2024;(84(3)):142-146. URL: <https://www.elibrary.ru/icsnvb>
Gulyaeva Ch.I., Popova A. M. Experience of using an educational Telegram bot in mathematics lessons in the 5th grade. In: Problems of modern pedagogical education. Yalta: RIO GPA; 2024;(84(3)):142-146. (In Russ.). URL: <https://www.elibrary.ru/icsnvb>



23. Шмелева Е.Д. Академическое мошенничество среди студентов российских вузов: масштаб и факторы. Дис. ... канд. пед. наук. М.; 2021. URL: <https://www.elibrary.ru/>
Shmeleva E.D. Academic fraud among students of Russian universities: scale and factors. Diss. Cand. Sci. Ped. Moscow; 2021. 157 p. (In Russ.). URL: <https://www.elibrary.ru/>
24. Седых И.Ю., Хрипунова М.Б. Академическое мошенничество студентов. *Право и образование*. 2024;(10):28-34. URL: <https://www.elibrary.ru/bolsmi>
Sedyh I.Yu., Khripunova M.B. Academic cheating among students. *Law and Education*. 2024;(10):28-34. (In Russ.). URL: <https://www.elibrary.ru/bolsmi>
25. Бакулина Р.А. Искусственный интеллект как инструмент академического мошенничества: правовые и этические аспекты. *Политика и Общество*. 2025;(3):61-74. URL: <https://doi.org/10.7256/2454-0684.2025.3.75253>
Bakulina R.A. Artificial intelligence as a tool of academic fraud: legal and ethical aspects. *Politics and Society*. 2025;(3):61-74. (In Russ.). URL: <https://doi.org/10.7256/2454-0684.2025.3.75253>
26. Бегишев И.Р. Международно-правовые основы регулирования искусственного интеллекта и робототехники. *Международное публичное и частное право*. 2021;(1):37-40. URL: <https://doi.org/10.18572/1812-3910-2021-1-37-40>
Begishev I.R. International law bases of regulation of artificial intelligence and robotic engineering. *International Public and Private Law*. 2021;(1):37-40. (In Russ.). URL: <https://doi.org/10.18572/1812-3910-2021-1-37-40>
27. Жуков А.Д. Генеративный искусственный интеллект в образовательном процессе: вызовы и перспективы. *Вестник Московского государственного университета культуры и искусств*. 2023;5(115):66-75. URL: <https://doi.org/10.24412/1997-0803-2023-5115-66-75>
Zhukov A.D. Generative artificial intelligence in the educational process: challenges and prospects. *Bulletin of Moscow State University of Culture and Arts*. 2023;5(115):66-75. (In Russ.). URL: <https://doi.org/10.24412/1997-0803-2023-5115-66-75>
28. Журков А.А. Этические аспекты использования систем искусственного интеллекта: международно-правовой опыт. *Вестник Университета имени О.Е. Кутафина (МГЮА)*. 2022;(4):186-194. URL: <https://doi.org/10.17803/2311-5998.2022.92.4.186-194>
Zhurkov A.A. Ethical aspects of the use of artificial intelligence systems: international legal experience. *Courier of Kutafin Moscow State Law University (MSAL)*. 2022;(4):186-194. (In Russ.). URL: <https://doi.org/10.17803/2311-5998.2022.92.4.186-194>
29. Коннова Л.П., Липагина Л.В., Олехова Е.Ф., Рылов А.А., Степанян И.К. Корректирующий подход к оцениванию академических достижений студентов в LMS Moodle. *Информатика и образование*. 2022;37(6):75-85. URL: <https://doi.org/10.32517/0234-0453-2022-37-6-75-85>
Konnova L.P., Lipagina L.V., Olekhova E.F., Rylov A.A., Stepanyan I.K. A corrective approach to assessing students' academic achievements in LMS Moodle. *Informatics and Education*. 2022;37(6):75-85. (In Russ.). URL: <https://doi.org/10.32517/0234-0453-2022-37-6-75-85>
30. Zhou Q., Hashim H., Sulaiman N.A. Supporting English speaking practice in higher education: the impact of AI chatbot integrated mobile assisted blended learning framework. *Education and Information Technologies*. 2025;30:14629-14660. URL: <https://doi.org/10.1007/s10639-025-13401-2>
31. Sufi F., Alsulami M. AI-Driven Chatbot for Real-Time News Automation. *Mathematics*. 2025;13(5):850. URL: <https://doi.org/10.3390/math13050850>
32. Godase M. Impact of AI in Indian Education System. *SSRN*. 2025:1-7. URL: <https://doi.org/10.2139/ssrn.5219491>
33. Melo-López V-A., Basantes-Andrade A., Gudiño-Mejía C-B., Hernández-Martínez E. The Impact of Artificial Intelligence on Inclusive Education: A Systematic Review. *Education Sciences*. 2025;15(5):539. URL: <https://doi.org/10.3390/educsci15050539>
34. Kenchakkanavar A., Rathod A., Kamble Ar. Artificial Intelligence in Indian Education: Transforming Teaching and Learning for the Digital Age. *International Research Journal of Innovations in Engineering and Technology*. 2024;8(11):200-204. URL: <https://doi.org/10.47001/IRJIET/2024.811024>
35. Essel H.B., Vlachopoulos D., Tachie-Menson A., et al. The Impact of a Virtual Teaching Assistant (Chatbot) on Students' Learning in Ghanaian Higher Education. *International Journal of Educational Technology in Higher Education*. 2022;19:57. URL: <https://doi.org/10.1186/s41239-022-00362-6>
36. Nguyen L.S.T., Quan T.T. URAG: Implementing a Unified Hybrid RAG for Precise Answers in University Admission Chatbots — A Case Study at HCMUT. In: Buntine W., Fjeld M., Tran T., Tran M.T., Huynh Thi. Thanh B., Miyoshi T., editors. Information and Communication Technology. SOICT 2024. *Communications in Computer and Information Science*. Springer, Singapore. 2025:2351. URL: https://doi.org/10.1007/978-981-96-4285-4_7

37. Micheal A.A., Prasanth A., Aswin T.S., Krisha B.L. Advancing Educational Accessibility: The LangChain LLM Chatbot's Impact on Multimedia Syllabus-Based Learning. 2024. Preprint. URL: <https://doi.org/10.21203/rs.3.rs-4399670/v1>
38. Kim M., Lee S., Kim S., Heo JI., Lee S., Shin YB., et al. Therapeutic Potential of Social Chatbots in Alleviating Loneliness and Social Anxiety: Quasi-Experimental Mixed Methods Study. *Journal of Medical Internet Research*. 2025;27: e65589. URL: <https://doi.org/10.2196/65589>
39. Капитанова Н.В. Проблемы адаптивности преподавателей вузов МВД России в условиях цифровизации образования. *Вестник Нижегородского университета им. Н.И. Лобачевского. Серия: Социальные науки*. 2025;(1(77)):178-182. URL: https://doi.org/10.52452/18115942_2025_1_178
Kapitanova N.V. Problems of adaptability of university teachers of the MIA of Russia in the conditions of digitalization of education. *Vestnik of Lobachevsky State University of Nizhni Novgorod. Series: Social Sciences*. 2025;1(77):178-182. (In Russ.). URL: https://doi.org/10.52452/18115942_2025_1_178
40. Весманов С.В., Источников В.В. Учебная деятельность школьников в цифровой среде. *Вестник МПГУ. Серия: Педагогика и психология*. 2023;17(4):166-191. URL: <https://doi.org/10.25688/2076-9121.2023.17.4.10>
Vesmanov S.V., Istochnikov V.V. Educational activities of schoolchildren in the digital environment. *MCU Journal of Pedagogy and Psychology*. 2023;17(4):166-191. (In Russ.). URL: <https://doi.org/10.25688/2076-9121.2023.17.4.10>
41. Pallivathukal R.G., Soe H.H.K., Donald P.M., Samson R.S., Ismail A.R.H. ChatGPT for Academic Purposes: Survey among Undergraduate Healthcare Students in Malaysia. *Cureus*. 2024;16(1): e53032. URL: <https://doi.org/10.7759/cureus.53032>
42. Yang S., Taylor-Griffiths D., van der Kleij F., Taylor-Guy P., Saubern R. Empowering teaching and learning with educational technology: Literature review. Australian Council for Educational Research; 2025. URL: <https://doi.org/10.37517/978-1-74286-784-7>
43. Коляда М.Г., Бугаева Т.И. Искусственный интеллект как движущая сила совершенствования и инновационного развития в образовании и педагогике. *Информатика и образование*. 2019;10(309):21-30. URL: <https://doi.org/10.32517/0234-0453-2018-33-10-21-30>
Koliada M.G., Bugayova T.I. Artificial intelligence as a moving force of improvement and innovative development in education and pedagogic. *Informatics and Education*. 2019;(10(309)):21-30. (In Russ.). URL: <https://doi.org/10.32517/0234-0453-2018-33-10-21-30>
44. Fulgencio S-V. Developing Effective Educational Chatbots with GPT: Insights from a pilot study in a university subject. *Trends in Higher Education*. 2024;3(1):155-168. URL: <https://doi.org/10.3390/higheredu3010009>
45. Esiyok E., Gokcearslan S., Kucukergin K.G. Acceptance of Educational Use of AI Chatbots in the Context of Self-Directed Learning with Technology and ICT Self-Efficacy of Undergraduate Students. *International Journal of Human-Computer Interaction*. 2024;41(1):641-650. URL: <https://doi.org/10.1080/10447318.2024.2303557>
46. Григорьев С.Г., Лернер И.М., Мариносян А.Х., Григорьева М.А. К вопросу подбора учебно-методической информации для реализации адаптивной электронной образовательной среды: алгоритм подбора авторов литературы с учетом эмоционально-психологических особенностей пользователей на базе идей академической генеалогии. *Информатика и образование*. 2025;40(3):69-79. URL: <https://doi.org/10.32517/0234-0453-2025-40-3-69-79>
Grigoriev S.G., Lerner I.M., Marinosyan A.Kh., Grigorieva M.A. On the issue of educational and methodological information selection for implementing an adaptive learning management system: Algorithm of selecting authors of literature taking into account the emotional and psychological characteristics of users based on the ideas of academic genealogy. *Informatics and Education*. 2025;40(3):69-79. (In Russ.). URL: <https://doi.org/10.32517/0234-0453-2025-40-3-69-79>
47. Jeon J., Lee S. Large language models in education: A focus on the complementary relationship between human teachers and ChatGP T. *Education and Information Technologies*. 2023;28:15873-15892. URL: <https://doi.org/10.1007/s10639-023-11834-1>
48. Назаров Д.М., Бегичева С.В. Применение больших языковых моделей в образовательном процессе. *Бизнес. Образование. Право*. 2024;(3(68)):430-436. URL: <https://doi.org/10.25683/VOLBI.2024.68.1057>
Nazarov D.M., Begicheva S.V. Application of large language models in educational process. *Business. Education. Law*. 2024;3(68):430-436. (In Russ.). URL: <https://doi.org/10.25683/VOLBI.2024.68.1057>
49. Violakis P. Leveraging large language models for enhanced simulation-based learning in police and law enforcement. *Policing: A Journal of Policy and Practice*. 2025;19: paaf012. URL: <https://doi.org/10.1093/police/paaf012>



50. Можаровский Е.А., Алуев А.С., Дудак А.А., Ишанхонов А.Ю. Применение больших языковых моделей для автоматизации тестирования и отладки программного обеспечения. *Современная наука: актуальные проблемы теории и практики. Серия: Естественные и технические науки*. 2024;(11(2)):103-108. URL: <https://doi.org/10.37882/2223-2966.2024.11-2.22>
Mozharovskii E.A., Aluev A.S., Dudak A.A., Ishankhonov A.Y. Application of large language models for software testing and debugging automation. *Modern Science: actual problems of theory and practice. Series: Natural and Technical Sciences*. 2024;11(2):103-108. (In Russ.). URL: <https://doi.org/10.37882/2223-2966.2024.11-2.22>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Ирина Кимовна Степанян — канд. пед. наук, доцент кафедры математики и анализа данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Irina K. Stepanyan — Cand. Sci. (Ped.), Assoc. Prof., Department of Mathematics and Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0003-2942-0976>

ikstepanyan@fa.ru

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>

Автор для корреспонденции / Corresponding author:

mbkhripunova@fa.ru

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов. *Conflicts of Interest Statement: The authors have no conflicts of interest to declare.*

Статья поступила 26.02.2026; после рецензирования 19.03.2026; принята к публикации 13.03.2026.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 26.02.2026; revised on 19.03.2026 and accepted for publication on 13.03.2026.

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

Моделирование и структурный анализ социальных сетей

А.Д. Цветкова¹, Р.А. Кочкаров², Э.А. Окунева³^{1,2,3} Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация;
¹ Odyssey Consulting Group, Москва, Российская Федерация

АННОТАЦИЯ

Современные социальные сети характеризуются сложной неслучайной топологией, однако существующие исследования фрагментарно описывают их структурные свойства применительно к российскому сегменту, оставляя пробел в валидации классических графовых моделей. Актуальность обусловлена необходимостью разработки точных математических методов анализа для управления информационными потоками и противодействия угрозам в цифровой среде. Целью работы является моделирование и анализ структуры социальной сети «ВК» с использованием графовых теорий для выявления ключевых метрик кластеризации, эффекта «малого мира» и масштабируемости. Исследование основано на анализе анонимизированного среза данных социальной сети «ВК» объемом более 1 млн пользователей. Построен неориентированный граф дружеских связей. Применены алгоритмы расчета коэффициента кластеризации, распределения степеней узлов, средней длины кратчайшего пути и модульности (метод Louvain). Установлено, что сеть «ВК» обладает свойствами scale-free сети с показателем степенного распределения и наличием хабов, высоким коэффициентом кластеризации ($\approx 0,52$) и малой средней длиной пути (<5 шагов), что соответствует модели Барабаши-Альберта и эффекту «малого мира». Выявлены устойчивые тематические сообщества с высокой структурной замкнутостью. Полученные результаты коррелируют с выводами работ Милгрэма, Уоттса-Строгаца и Барабаши-Альберта, подтверждая универсальность данных моделей для российских платформ. Перспективы исследования связаны с изучением динамических процессов распространения информации и применением графовых нейронных сетей для прогнозирования связей.

Ключевые слова: социальная сеть; теория графов; кластеризация; сетевой анализ; хабы; scale-free

Для цитирования: Цветкова А.Д., Кочкаров Р.А., Окунева Э.А. Моделирование и структурный анализ социальных сетей. *Цифровые решения и технологии искусственного интеллекта*. 2026;2(2):57-62. DOI: 10.26794/3030-7097-2026-2-2-57-62

ORIGINAL PAPER

Modeling and Structural Analysis of Social Networks


A.D. Tsvetkova¹, R.A. Kochkarov², E.A. Okuneva³^{1,2,3} Financial University under the Government of the Russian Federation, Moscow, Russian Federation;
¹ Odyssey Consulting Group, Moscow, Russian Federation

ABSTRACT

Modern social networks are characterized by a complex non-random topology; however, existing research provides only a fragmented description of their structural properties within the Russian segment, leaving a gap in the validation of classical graph models. The relevance is driven by the need to develop precise mathematical analysis methods for managing information flows and countering threats in the digital environment. The aim of the work is the modeling and structural analysis of the “VK” social network using graph theory to identify key metrics of clustering, the “small-world” effect, and scalability. The study is based on the analysis of an anonymized data sample from the “VK” social network comprising over 1 million users. An undirected graph of friendship ties was constructed. Algorithms were applied to calculate the clustering coefficient, node degree distribution, average shortest path length, and modularity using the Louvain method. It was established that the “VK” network exhibits properties of a scale-free network with a power-law degree distribution and the presence of hubs, a high clustering coefficient (≈ 0.52), and a short average path length (<5 steps), which corresponds to the Barabási–Albert model and the “small-world” effect. Stable thematic communities with high structural closure were identified. The obtained results correlate with the findings of Milgram, Watts–Strogatz, and Barabási–Albert, confirming the universality of these models for Russian platforms. Research prospects involve the study of dynamic information diffusion processes and the application of graph neural networks for link prediction.

Keywords: social network; graph theory; clustering; network analysis; hubs; scale-free

For citation: Tsvetkova A.D., Kochkarov R.A., Okuneva E.A. Modeling and structural analysis of social networks. *Digital solutions and artificial intelligence technologies*. 2026;2(2):57-62. DOI: 10.26794/3030-7097-2026-2-2-57-62



ВВЕДЕНИЕ

Развитие социальных сетей радикально изменило характер человеческих коммуникаций. Современные платформы, такие как «ВК», Facebook, Instagram, X(Twitter)¹, обладают сложной структурой, которую невозможно адекватно описать без использования математических моделей. Сетевой анализ, в основе которого лежит теория графов, стал важным инструментом для изучения этих структур как в академической, так и в прикладной плоскости.

Стремительный рост объема данных и усиление влияния социальных сетей на социально-экономические процессы требуют развития точных методов анализа их структурных характеристик. Сетевой анализ социальных платформ опирается на прикладную теорию графов, основы которой применимы к задачам моделирования сложных систем². Ключевыми для понимания структуры социальных сетей являются концепции эффекта «малого мира», формализованные в модели Уоттса-Строгаца [1, 2], и масштабируемости (scale-free), описываемой моделью Барабаши-Альберта [3]. Модель случайных графов Эрдёша-Реньи (Erdős-Rényi) [4], несмотря на математическую стройность, оказалась неприменимой для социальных структур из-за отсутствия в ней механизмов кластеризации и формирования хабов — страницы или пользователи с тысячами или миллионами подписчиков, через которых осуществляется основной обмен информации между пользователями. Альтернативой выступили подходы, учитывающие неслучайный характер образования связей³.

В российском сегменте социальных медиа наиболее изученной платформой является «ВК». В работах [5, 6] представлены результаты анализа ее структурных характеристик, однако объем выборки в этих исследованиях, как правило, не превышает нескольких сотен тысяч узлов, что ограничивает возможность выявления свойств масштабируемости в области «тяжелого хвоста» распределения. Вопросы визуализации сетевых структур и выделения сообществ на графе «ВК» рассматривались в [7, 8], где показана эффективность алгоритмов модульности для идентификации тематических класте-

ров. Отдельного внимания заслуживают исследования динамики распространения информации [9] и групповой активности пользователей⁴, в которых сетевые метрики связываются с поведенческими паттернами аудитории.

Современный этап развития методов сетевого анализа характеризуется переходом к более сложным архитектурам, в частности к графовым нейронным сетям, успешно применяемым в рекомендательных системах [10]. Перспективным направлением остается также анализ многокритериальных задач на предфрактальных графах [11], позволяющий учитывать иерархическую природу социальных структур.

МЕТОДОЛОГИЯ ИССЛЕДОВАНИЯ

В рамках исследования использовался анонимизированный срез данных социальной сети «ВК», включающий информацию о более чем 1 млн пользователей и их дружеских связях. Выборка такого объема обусловлена необходимостью обеспечения статистической значимости результатов при анализе «тяжелых хвостов» распределения степеней узлов: при меньших объемах выборки свойства scale-free сетей могут проявляться недостаточно явно. На основе полученных данных был сформирован неориентированный граф $G = (V, E)$, где множество вершин V соответствует пользователям, а множество ребер E — наличию двусторонней дружеской связи между ними.

Анализ проводился с использованием языка Python и специализированных библиотек NetworkX и igraph. В качестве ключевых структурных метрик рассчитывались: распределение степеней вершин $P(k)$, средний коэффициент кластеризации C , средняя длина кратчайшего пути L (методом выборки по 10 000 случайных пар вершин в гигантской компоненте связности), а также показатели центральности — по степени и по посредничеству (с аппроксимацией на основе 1000 узлов-источников). Для выявления структурных сообществ применялся алгоритм Louvain, основанный на максимизации модульности и не требующий априорного задания числа кластеров.

Эмпирические метрики сравнивались с предсказаниями указанных выше трех моделей. Параметры модельных графов подбирались таким образом, чтобы обеспечить сопоставимость с реальной сетью по числу вершин и среднему числу ребер.

¹ Социальные сети Facebook, Instagram, X(Twitter) принадлежат компании Meta, чья деятельность признана экстремистской и запрещена на территории Российской Федерации.

² Кочкаров А.А., Яцкин Д.В., Кочкаров Р.А. Прикладная теория графов и сетевые модели. М.: КноРус; 2021. 210 с.

³ Чвякин В.А., Чертков А.С. Теория социальных сетей; 2023. 160 с.; Ньюман М.Э. Дж. Сети: введение. М.: Техносфера; 2020. 772 с.

⁴ Бакалов А. Анализ частоты заходов пользователей ВКонтакте в социальную сеть. Сравнение с 2-летней аудиторией. URL: <https://vc.ru/social/278271-analiz-chastoty-zahodov-polzovatelei-vkontakte-v-socialnuyu-set-sravnienie-s-2-letnei-auditoriei?ysclid=mo6w4r8faw607600809>

МОДЕЛИ СЕТЕВОЙ СТРУКТУРЫ

Социальные сети характеризуются высокой кластеризацией, малой средней длиной пути и наличием узлов с высокой степенью связности (хабов). В «ВК» к хабам относятся популярные паблики, медиа и блогеры. Эти параметры объясняют быстрое и масштабное распространение контента в сети, а также формируют основу для построения аналитических моделей.

На *рисунке 1В* показана визуализация эффекта «малого мира» на примере социальной сети. Четыре кластера (оранжевый, зеленый, красный и голубой) символизируют локальные сообщества пользователей, внутри которых очень плотные связи. Между кластерами проведены редкие длинные связи, которые объединяют разные группы в единую сеть. Такая структура отражает свойства реальных социальных сетей: высокая кластеризация и малая средняя длина пути между любыми двумя участниками.

Ранняя модель случайных графов (Erdős-Rényi) предполагает равновероятные связи между узлами — *рис. 1Б*. Несмотря на математическую простоту, она плохо описывает реальные сети из-за низкой кластеризации и отсутствия хабов [1]. Все узлы графа одинаково важны, такая сеть не отражает реальной структуры социальных сетей.

На *рисунке 1Г* представлена модель Уоттса-Строгаца — это гибрид регулярного и случайного графа. В данной модели органично сочетается высокая кластеризация, присущая регулярным сетям, и короткие пути, свойственные случайным графам. В такой сети плотные локальные группы пользователей соединены несколькими случайными «длинными» связями, что эффективно отражает структуру реальных социальных сетей, например «ВКонтакте», где плотные локальные группы соединены подписками на публичные страницы.

Наиболее реалистичной моделью считается scale-free сеть Барабаши-Альберта, где формирование связей осуществляется по принципу предпочтительного присоединения. Новые пользователи склонны подключаться к популярным аккаунтам, формируя хабы. Эта модель объясняет распределение степеней и устойчивость к случайным сбоям, но уязвимость к атакам на ключевые узлы⁵. На *рисунке 1А* представлена модель Барабаши-Альберта, где хабы выделены цветом.

⁵ Ньюман М.Э. Дж. Сети: введение. М.: Техносфера; 2020. 772 с.




Рис. 1 / Fig. 1. Визуализация моделей на примере социальной сети / Visualization of Models Using the Example of a Social Network

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



РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

В результате эмпирического анализа сети «ВК» установлено следующее:

1. Сеть «ВК» имеет ярко выраженный степенной характер (scale-free) с наличием хабов, что подтверждает сходство с моделью Барабаши-Альберта.

2. Среднее значение коэффициента кластеризации для сети «ВК» составило $\sim 0,52$, что свидетельствует о наличии плотных локальных сообществ — типично для социальных сетей и значительно выше, чем у случайных графов.

3. Средняя длина кратчайшего пути оказалась меньше 5 шагов, что согласуется с эффектом «малого мира» (Милгрэм, Уоттс-Строгац) и указывает на высокую доступность информации в сети.

4. Основная масса пользователей входит в единую гигантскую компоненту, что делает сеть хорошо связанной и пригодной для широкого распространения информации.

5. С помощью алгоритма Louvain были обнаружены крупные тематические и локальные сообщества (школы, вузы, регионы), обладающие высокой когерентностью и структурной замкнутостью.

Эмпирические данные подтверждают применимость теоретических графовых моделей к реальной платформе.

Практическое применение результатов — в маркетинге, распространении контента, выявлении ботов и предсказании поведения пользователей. Более поздние исследования [5] показали, что через паблики с аудиторией >100 тыс. контент распро-

страняется с наибольшей скоростью, а для предсказания поведения пользователей применяются графовые нейронные сети (GNN) [8]. Сетевой анализ используется в маркетинге для выбора инфлюенсеров, таргетинга и сегментации аудиторий.

Также сетевой анализ используется не только в кибербезопасности — для выявления ботов и фейковых аккаунтов с помощью анализа аномальной активности и структуры связей, но и в управлении информацией — для блокировки дезинформации и прогнозирования кризисных ситуаций.

ВЫВОДЫ

Анализ структурных характеристик социальных сетей, таких как кластеризация, эффект малого мира и масштабируемость, позволяет более глубоко понять поведение цифровых сообществ. Использование моделей Уоттса-Строгаца и Барабаши-Альберта дает возможность строить реалистичные симуляции и проводить эффективный сетевой анализ. Практическое применение этих моделей в маркетинге, кибербезопасности и аналитике делает их незаменимыми в условиях современной цифровой среды.

Вместе с тем за пределами настоящего исследования остались вопросы динамики изменения сети во времени, идентификации бот-сетей и учета направленности и веса связей. Перспективы дальнейших исследований связаны с переходом к динамическим и взвешенным графовым моделям, а также с интеграцией методов машинного обучения для анализа кросс-платформенных взаимодействий.

СПИСОК ИСТОЧНИКОВ

1. Milgram S. The small world problem. *Psychology Today*. 1967;1(1):60-67. URL: <https://snap.stanford.edu/class/cs224w-readings/milgram67smallworld.pdf>
2. Watts D., Strogatz S. Collective dynamics of 'small-world' networks. *Nature*. 1998;393:440-442. URL: <https://doi.org/10.1038/309182020;393:440-442>
3. Barabási A.-L., Albert R. Emergence of scaling in random networks. *Science*. 1999.286(5439):509-12. URL: <https://doi.org/10.1126/science.286.5439.509>
4. Erdős P., Rényi A. On the evolution of random graphs. *Publications of the Mathematical Institute of the Hungarian Academy of Sciences*. 2021;5:17-61.
5. Галаганова С.Г., Турусина Т.В. Технологии анализа социальных сетей с целью выявления социальных трендов. *Человеческий капитал*. 2023;1(169):121-136. URL: <https://doi.org/10.25629/HC.2023.01.14>
6. Журина А.А., Кочкаров А.А., Кочкаров Р.А. Анализ структурных характеристик социальных сетей. *Социальные сети и Интернет-технологии*. 2023;21(5):63-72. URL: <https://doi.org/10.18127/j20700814-202305-08>
7. Кочкаров Р.А., Черкасов В.В., Тимошенко А.В., Кочкаров А.А., Мартынов Н.С., Бодров А.О. Структурно-графовая визуализация социальных сетей и исследование сообществ в них. *Социальные сети и Интернет-технологии*. 2021;8(1):169-176. URL: <https://www.elibrary.ru/sgdrqn>
8. Кочкаров А.А., Калашников Н.В., Кочкаров Р.А. Сравнительный анализ алгоритмов выявления сообществ в сложных сетевых системах на примере социальных сетей. *Программные продукты и системы*. 2020;(2):349-356. URL: <https://doi.org/10.15827/0236-235X.130.349-356>



9. Бадрызлов В.А. Оценка эффективности распространения информации в социальных сетях с использованием имитационного моделирования. *Креативная экономика*. 2018;12(9):1359-1372. URL: <https://doi.org/10.18334/ce.12.9.39389>
10. Ying R., He R., Chen K., Eksombatchai P., Hamilton W.L., Leskovec J. Graph Convolutional Neural Networks for Web-Scale Recommender Systems. In KDD '18: The 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, August 19–23, 2018, London, United Kingdom. NY: ACM. URL: <https://doi.org/10.1145/3219819.3219890>
11. Кочкаров Р.А., Кочкаров А.А., Сенникова Л.И. Классификация многокритериальных задач на много-взвешенных предфрактальных графах. В сб.: Актуальные проблемы прикладной математики, информатики и механики. Воронеж: Издательский дом ВГУ; 2017:112-119. URL: <https://www.elibrary.ru/zgpfej>

REFERENCES

1. Milgram S. The small world problem. *Psychology Today*. 1967;1(1):60-67. URL: <https://snap.stanford.edu/class/cs224w-readings/milgram67smallworld.pdf>
2. Watts D., Strogatz S. Collective dynamics of 'small-world' networks. *Nature*. 1998;393:440-442. URL: <https://doi.org/10.1038/309182020;393:440-442>
3. Barabási A.-L., Albert R. Emergence of scaling in random networks. *Science*. 1999.286(5439):509-12. URL: <https://doi.org/10.1126/science.286.5439.509>
4. Erdős P., Rényi A. On the evolution of random graphs. *Publications of the Mathematical Institute of the Hungarian Academy of Sciences*. 2021;5:17-61.
5. Galaganova S.G., Turusina T.V. Technologies for analyzing social networks in order to identify social trends. *Human Capital*. 2023;1(169):121-136. (In Russ.). URL: <https://doi.org/10.25629/HC.2023.01.14>
6. Zhurina A.A., Kochkarov A.A., Kochkarov R.A. Analysis of structural characteristics of social networks. *Social Networks and Internet Technologies*. 2023;21(5):63-72. (In Russ.). URL: <https://doi.org/10.18127/j20700814-202305-08>
7. Kochkarov R.A., Cherkasov V.V., Timoshenko A.V., Kochkarov A.A., Martynov N.S., Bodrov A.O. Structural graph visualization of social networks and community research in them. *Social Networks and Internet Technologies*. 2021;8(1):169-176. (In Russ.). URL: <https://www.elibrary.ru/sgdrqn>
8. Kochkarov A.A., Kalashnikov N.V., Kochkarov R.A. Comparative analysis of algorithms for identifying communities in complex network systems using the example of social networks. *Software Products and Systems*. 2020;(2):349-356. (In Russ.). URL: <https://doi.org/10.15827/0236-235X.130.349-356>
9. Badryzlov V.A., Sideltsev V.V. Evaluation of the effectiveness of information dissemination in social networks using simulation. *Creative Economy*. 2018;12(9):1359-1372. (In Russ.). URL: <https://doi.org/10.18334/ce.12.9.39389>
10. Ying R., He R., Chen K., Eksombatchai P., Hamilton W.L., Leskovec J. Graph Convolutional Neural Networks for Web-Scale Recommender Systems. In KDD '18: The 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, August 19-23, 2018, London, United Kingdom. NY: ACM. URL: <https://doi.org/10.1145/3219819.3219890>
11. Kochkarov R.A., Kochkarov A.A., Sennikova L.I. Classification of multicriteria problems on multi-weighted prefractal graphs. In: Actual Problems of Applied Mathematics, Computer Science and Mechanics. Voronezh: VSU Publishing House; 2017:112-119. (In Russ.). URL: <https://www.elibrary.ru/zgpfej>

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Анастасия Дмитриевна Цветкова — магистрант Института открытого образования, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация; младший консультант Odyssey Consulting Group, Москва, Российская Федерация

Anastasia D. Tsvetkova — Master's student at the Financial University under the Government of the Russian Federation, Moscow, Russian Federation; Junior Consultant at Odyssey Consulting Group, Moscow, Russian Federation

<https://orcid.org/0009-0002-4025-1907>

232431@edu.fa.ru



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

Rasul A. Kochkarov — Cand. Sci. (Econ.), Deputy Dean for Research, Associate Professor of 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
<https://orcid.org/0000-0003-3186-3901>
rkochkarov@fa.ru

Эвелина Александровна Окунева — ассистент кафедры математики и анализа данных факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Evelina A. Okuneva — assistant of the Department of Mathematics and Data Analysis, Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation
<https://orcid.org/0009-0006-4385-4462>

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

Заявленный вклад авторов:

А.Д. Цветкова — аннотация, сравнительный анализ технологических решений для разработки мобильной автоматизированной инкассаторской системы.

Р.А. Кочкаров — разработка общей концепции статьи, исследование существующих подходов и технологических решений автоматизации инкассационного процесса.

Э.А. Окунева — введение, выводы, список источников.

Authors' declared contributions:

A. D. Tsvetkova — abstract, comparative analysis of technological solutions for developing a mobile automated cash collection system.

R. A. Kochkarov — development of the overall concept of the article; research into existing approaches and technological solutions for automating the cash collection process.

E. A. Okuneva — introduction, conclusion, references.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.


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

Статья поступила 19.01.2026; после рецензирования 02.03.2026; принята к публикации 13.03.2026.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 19.01.2026; revised on 02.03.2026 and accepted for publication on 13.03.2026.

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



Информатика опережающих данных

И.Ю. Варьяш¹, Т.Ф. Бурова², Д.В. Климонов³

^{1,2,3} Научно-исследовательский финансовый институт (НИФИ), Москва, Российская Федерация;

³ Московский университет «Синергия», Москва, Российская Федерация

АННОТАЦИЯ

В статье предлагается решение проблемы социоэкономического синтеза больших опережающих данных с помощью информатики. Размерность экономических процессов сближается с размерностью социальных процессов, что составляет новизну объекта исследования опережающих данных. По-новому стоит вопрос о предмете исследования — на стыке эконометрики и социологии в информатике, а также о трансформации методов социально-экономического анализа, поиска, обработки и аналитического представления больших опережающих данных. Рассмотрены социоэкономические аспекты актуализации опережающих данных, а также информатика как платформа трансформации эконометрических методов для синтеза больших опережающих данных. В выводах формулируется положение о выдвижении технологии больших опережающих данных на авансцену экономики и управления; представлены принципиальные методологические и организационно-технические мероприятия по внедрению технологии опережающих данных в новые, более высокие хозяйственные уклады.

Ключевые слова: информатика; эконометрика; опережающие индикаторы; анализ данных; подобие данных

Для цитирования: Варьяш И.Ю., Бурова Т.Ф., Климонов Д.В. Информатика опережающих данных. Цифровые решения и технологии искусственного интеллекта. 2026;2(2):63-71. DOI:10.26794/3030-7097-2026-2-2-63-71

Advanced data informatics

I.Yu. Vajas¹, T.F. Burova², D.V. Klimonov³

^{1,2,3} Scientific Research Financial Institute (NIFI), Moscow, Russian Federation;


³ Moscow University "Synergy", Moscow, Russian Federation

ABSTRACT

This article proposes a solution to the problem of socioeconomic synthesis of big data using informatics. The dimensionality of economic processes converges with the dimensionality of social processes, which is a novel feature of the research object of leading data. It reframes the subject of research as the intersection of econometrics and sociology in informatics, transforming methods of socioeconomic analysis, and searching, processing, and analytical presentation of big data. The article examines the socioeconomic aspects of updating leading data and informatics as a platform for transforming econometric methods for synthesizing big data. The conclusions advance the idea of big data technology to the forefront of economics and management, and presents fundamental methodological, organizational, and technical measures for introducing leading data technology into new, higher economic paradigms.

Keywords: informatics; econometrics; leading indicators; data analysis; data similarity

For citation: Vajas I.Yu., Burova T.F., Klimonov D.V. Advanced data informatics. Digital solutions and artificial intelligence technologies. 2026;2(2):63-71. DOI:10.26794/3030-7097-2026-2-2-63-71



ВВЕДЕНИЕ

Опережающие индикаторы являются уникальным информационным потоком коллективного мнения деловых кругов и домашних хозяйств о будущем изменении направлений и широте деловой и потребительской активности [1]. Социуму нужны не только результаты, но и перспективы, что особенно присуще российскому общественному сознанию.

Необходимо формировать и поддерживать на основе научно обоснованных данных веру в общее будущее, противопоставляя ее распространению внутри страны и из-за рубежа страхов, боязни и непонимания действий властей, а также недоверия к власти. В не меньшей степени это относится к экономическому управлению, в том числе к финансовым технологиям: доверие к власти и доверие власти к населению и бизнесу играют первостепенную роль в поддержании социально-политической стабильности и статуса России в качестве одного из новых мировых центров силы в международных отношениях.

Ускорению социально-экономических процессов будут способствовать преодоление разноречия и несистемности статистического наблюдения в разных сферах экономики и единообразие в размерности статистического наблюдения.

Важно привести состав опросов в соответствие с изменяющейся структурой направлений экономической деятельности; добавить информацию по действующим формам за 2023 г. с целью восстановления баз данных длинных динамических рядов для масштабирования горизонтов ожиданий; способствовать раскрытию информации статистического наблюдения в странах ЕАЭС/СНГ для допуска к листингу на международных биржах БРИКС+, а также к международным и корпоративным финансовым ресурсам; регламентировать расчеты сводных данных экономических ожиданий на единой методологической основе для международных бизнес-экосистем, инвестирования, банковского дела, страхования, листинга, хеджирования, комплаенса, объединений саморегулирования.

Любая дополнительная информация обеспечивает принятие решений международными сообществами, организациями саморегулирования, бизнес-экосистемами, национальными регуляторами с учетом обмена масштабируемыми ожиданиями хозяйствующих субъектов в режиме реального времени.

Реновация методологии статистического наблюдения опережающих индикаторов основывается на использовании новых информационных принципов:

- распространение статистического наблюдения на генеральную совокупность хозяйствующих субъектов;

- учет формирующихся направлений экономической деятельности;

- перевод заполнения опросных форм, сбора и обработки первичных данных в электронную форму;

- использование технологии блокчейн для организации обмена опережающими индикаторами между регуляторами экономической деятельности.

Использование балансового и диффузного методов расчета опережающих индикаторов со временем теряет эффективность из-за увеличения количества больших данных. Увеличиваются и ошибки измерения, так как выборка респондентов мониторинга становится и абсолютно, и относительно меньше.

Увеличение численности генеральной совокупности респондентов в связи с вхождением в состав России новых территорий не меняет ситуацию, так как принципы формирования выборки остаются ориентированными на уже не существующую экономику прошлого.

Снятие жестких ограничений на глубину ожиданий подтверждается научной оценкой горизонта текущих решений — 3–4 месяцами, являющимися первоосновой фрактального масштабирования до среднесрочного горизонта (1,5 г).

ИНФОРМАТИКА СИНТЕЗА ОПЕРЕЖАЮЩИХ ДАННЫХ

Синтез больших опережающих данных опирается на подобие опережающих индикаторов и статистических наблюдений показателей (табл. 1), что можно показать на примере¹ биржевых рынков [1, 2].

Сравнение коэффициентов корреляции (см. рисунок) между динамическими рядами статистики и опережающих индикаторов в 2016 г. против 2025 г. показало устойчивость корреляции, рассчитываемой ЕМІ-методом², увеличившись с 0,73 до 0,79 соответственно, тогда как корреляция с рассчитываемым балансовым методом опережающим индексом ухудшилась с 0,71 до 0,62 соответственно³ [3].

Примечательно, что в условиях ограничения торговли долларами на валютном рынке Мосбиржи эффект подобия на внебиржевом рынке продолжал воспроизводиться.

¹ Здесь и далее используется расчет опережающих индикаторов по вероятностной ЕМІ модели с V-распределением доли ответов об отсутствии изменений.

² Метод используется для оценки изменений в области новых производственных заказов, объема индекса промышленного производства, занятости, а также товарных запасов и скорости работы поставщиков. $PMI = 50 + (Pg + 0,5C) \times 0,5 - (Pd + 0,5C) \times 0,5$.

³ Котенко А.П. Парная регрессия. Методические указания к лабораторным работам по эконометрике. Самара: Издательство Самарского университета; 2016.

Подобие опережающих индикаторов и динамики статистических показателей во внебиржевой торговле на примере USD/RUB* / Similarity of Leading Indicators and Dynamics of Statistical Indicators in Over-The-Counter Trading Using the Example of USD/RUB*

Период		EMI	Stat	Корре - ляция	Период		EMI	Stat	Корре - ляция	
23.12.2024	25.12.2024	44,50	100,46	0,73	10.04.2025	14.04.2025	53,00	83,96	0,61	
25.12.2024	27.12.2024	46,50	100,71		14.04.2025	16.04.2025	49,50	82,78		
27.12.2024	30.12.2024	51,00	104,07		16.04.2025	18.04.2025	49,00	82,25		
30.12.2024	06.01.2025	55,50	108,77		18.04.2025	22.04.2025	45,50	80,89		
06.01.2025	10.01.2025	52,00	104,49		22.04.2025	24.04.2025	49,50	82,14		
10.01.2025	14.01.2025	53,00	102,08		24.04.2025	28.04.2025	50,50	82,68		
14.01.2025	16.01.2025	48,50	102,56		28.04.2025	30.04.2025	53,50	81,95		
16.01.2025	20.01.2025	45,00	102,28		30.04.2025	02.05.2025	50,00	81,86		
20.01.2025	22.01.2025	49,00	99,96		02.05.2025	06.05.2025	44,00	81,80		
22.01.2025	24.01.2025	48,00	98,68		06.05.2025	08.05.2025	42,50	81,43		
07.02.2025	11.02.2025	49,00	96,92	0,79	08.05.2025	12.05.2025	49,00	82,24	0,81	
11.02.2025	13.02.2025	49,50	94,06		12.05.2025	14.05.2025	48,00	80,72		
13.02.2025	17.02.2025	48,00	91,25		15.07.2025	17.07.2025	42,89	78,11		
17.02.2025	19.02.2025	47,50	90,97		17.07.2025	21.07.2025	18,87	78,31		
19.02.2025	21.02.2025	45,00	89,01		21.07.2025	23.07.2025	17,76	78,30		
21.02.2025	25.02.2025	45,50	87,77		23.07.2025	25.07.2025	26,15	78,92		
25.02.2025	27.02.2025	38,50	86,81	0,78	25.07.2025	29.07.2025	43,77	80,54	0,87	
07.03.2025	11.03.2025	56,50	87,79		29.07.2025	31.07.2025	72,60	81,26		
11.03.2025	13.03.2025	55,00	86,51		08.08.2025	12.08.2025	14,39	79,72		
13.03.2025	17.03.2025	51,00	85,63		12.08.2025	14.08.2025	23,62	79,59		
17.03.2025	19.03.2025	45,00	83,21		14.08.2025	18.08.2025	41,71	79,89		
19.03.2025	21.03.2025	48,00	83,93		18.08.2025	20.08.2025	44,46	80,37		
21.03.2025	25.03.2025	45,50	84,06		20.08.2025	22.08.2025	71,37	80,46		
25.03.2025	27.03.2025	44,50	84,02		22.08.2025	26.08.2025	99,86	80,53		
27.03.2025	31.03.2025	53,00	84,35		26.08.2025	28.08.2025	55,54	80,31		
31.03.2025	02.04.2025	49,50	84,34		28.08.2025	01.09.2025	66,61	80,24		
02.04.2025	04.04.2025	49,00	84,38		26.08.2025	28.08.2025	14,39	80,31		0,63
04.04.2025	08.04.2025	45,50	85,27		28.08.2025	01.09.2025	23,62	80,24		
08.04.2025	10.04.2025	49,50	85,55	01.09.2025	03.09.2025	41,71	80,51			
Медиана		0,788051717			03.09.2025	05.09.2025	44,46	80,96		
					05.09.2025	09.09.2025	71,37	82,14		
					09.09.2025	11.09.2025	99,86	84,23		
					11.09.2025	15.09.2025	55,54	84,11		
					15.09.2025	17.09.2025	66,61	83,03		
					17.09.2025	19.09.2025	56,23	83,37		
					19.09.2025	23.09.2025	21,55	83,51		
					23.09.2025	25.09.2025	62,41	83,65		

Источник / Source: рассчитано автором по данным Росстата и Мосбиржи / Calculated by the authors according to data from Rosstat and the Moscow Stock Exchange.

Примечание / Note: * корреляционный анализ проведен по микроциклам / * Correlation analysis was performed on microcycles.




Рис. / Fig. Подобие динамических рядов балансовых опережающих индикаторов и индексов производства в добыче полезных ископаемых в марте – августе 2025 г., п.п. / Similarity of Dynamic Series of Balance Sheet Leading Indicators and Production Indices in Mining in March – August 2025, p.p.

Источник / Source: рассчитано авторами на основе данных Росстата / Calculated by the authors based on Rosstat data.

В эконометрике принято считать, что долгосрочные колебания данных, которые могут длиться годы или десятилетия, являются непредсказуемыми и часто — результатом резкого изменения внешних экономических условий или политики национальных регуляторов⁴. Но к такому типу случайных переменных относятся и циклические отклонения, которые невозможно элиминировать из временной последовательности ряда ожиданий. Колебания численных значений таких показателей выражают их главный экономический смысл. В случаях экстремального изменения в периоды прохождения подошв (минимумов) циклов кризисов их следует оценивать с помощью дополнительных процедур. В случае парной регрессии выделяется доминирующий фактор ожиданий, выступающий в качестве объясняющей переменной x . Для парной модели спецификация — это определение вида f аналитической зависимости $\tilde{y} = f(x)$. Спецификация модели выполняется экспериментальным методом: сначала зависимость между переменными представляют двумя моделями, затем среди них выбирают наиболее качественную (модель ожиданий) — критерием выступает величина остаточной дисперсии, характеризующая расхождение между моделями [4, 5]. Этот метод корреспондирует с теорией случайных величин А.Н. Колмогорова [6, 7].

Согласно исследованиям фрактальности в социальной сфере [8], она проявляется и в динамических рядах, но своеобразным образом⁵. Если кватрировать динамический ряд опережающих индикаторов на группы из трех событий в микроциклы, то получится графический ряд треугольников, подобие которых заключается в противолежащих острых углах [9].

Нелинейные парные уравнения в рассматриваемой области характеризуются гомоскедастичностью и коллинеарностью благодаря приведению временных последовательностей ожиданий к размерности динамических статистических рядов и выявлению функциональной зависимости между регрессорами. В случае сопоставления статистических данных и ожиданий наличие больших по модулю значений коэффициентов парной корреляции (выше 0,7) свидетельствует о принципиальной возможности нахождения между ними стохастической взаимосвязи, что является критически важным для корректной идентификации экстраполяции статистического ряда данных согласно ожиданиям (см. табл. 1).

Данные, отраженные в табл. 1, характеризуются увеличением выборки при соблюдении требования ее однородности и высоком значении коэффици-

⁴ Агаларов З.С., Орлов А.И. Эконометрика. Учебник. М.: Дашков и К; 2021. 380 с.

⁵ Кулак Л.А. (Антония Ильинская). Динамика формирования нового социального фрактала. URL: <https://proza.ru/2020/01/19/184>



ента коллинеарности в условных глубинах горизонтов ожиданий. Интервальный прогноз реалистичен в пределах диапазона исходных данных, но простая экстраполяция кривой регрессии в информатике не оправдывает себя в случаях ее использования вне пределов наблюдаемого диапазона значений объясняющей переменной для долгосрочного прогнозирования по трендовым моделям, где в качестве независимой переменной выступает время.

Однако использование временной последовательности ожиданий актуально для трендов, рассчитываемых на основе ожиданий, так как они заведомо выходят за границы наблюдавшегося в прошлом диапазона значений объясняющей переменной.

При решении модели парных уравнений регрессии общепринято, что число наблюдений (в нашем случае — временных периодов) должно в 7–8 раз превышать число рассчитываемых параметров переменной x . Но в парных уравнениях регрессии с использованием временных последовательностей численных значений показателя ожиданий, выходящих за границу последних по времени данных, учитываются не только архивные, но и данные неопределенной переменной, что зависит от результатов корреляционного анализа, а не от применения формальных ограничений модели.

Чем длиннее ряд будущих значений, тем менее длинной может быть заведомо избыточная выборка временных периодов архивных данных, ограничиваемая выборкой временных периодов, на которой возникает корреляция порядка $K \leq 0,7$.

На множественность уравнений регрессии накладывается отпечаток значительная численность участников наблюдения и мультипликация отмечаемых ими событий, учтенных в исходных данных, агрегируемых в преактивных параметрах, а также агрегирование временных периодов в микроциклах, что отвечает условию увеличения числа наблюдений при усложнении вида функции.

СОЦИОЭКОНОМИЧЕСКИЙ ИНСТРУМЕНТАРИЙ СИНТЕЗА ОПЕРЕЖАЮЩИХ ДАННЫХ

Задача здесь состоит в том, чтобы агрегировать мнения деловых сообществ, выразив их в соответствующих опережающих индикаторах. Для этого есть два пути. Первый — агрегировать непосредственно предикативные оценки специалистов. Второй — осуществлять частотный анализ динамики обращения к выделенным ключевым сюжетам (темам) презентативной выборки показателей (ключевых параметров), соответству-

ющей целевой ориентированности потоков новостей.

Обычно выбирают второй путь, кажущийся более представительным, но он содержит изрядную долю информационных шумов, что делает в слишком большом количестве случаев весьма затруднительным выделение смыслов ожиданий. А в случаях неразвитости рынка этот путь является фактически вынужденным.

Первый путь представляется более надежным, но только в случае развитости рынка, поскольку дает возможность оценивать не только ориентацию профессиональных участников на те или иные векторы изменения конъюнктуры, но и их веса, а также те самые факторы, от изменения которых зависит корректность оценки ожиданий с использованием уравнения регрессии.

Согласно социологической теории, в выборке из генеральной совокупности респондентов необходимо иметь не менее 54 респондентов. Если количество наблюдений в каждый момент переменной x составляет 4–5 микроциклов с 250–300 событиями, распределенными между числом респондентов больше 54, то этого достаточно для признания статистической значимости модели, в том числе с точки зрения ее репрезентативности и гомоскедастичности⁶. Но на этом социология опережающих данных только начинается.

Современные информационные технологии позволяют уже сейчас осуществлять поиск, обработку, синтез данных, а также, что исключительно важно, обмен аналитическими данными между любым числом субъектов статистического наблюдения опережающих индикаторов. Это впервые делает реальной задачу не только сплошного наблюдения генеральной совокупности участников хозяйственной деятельности, но и использования практически любой (разумеется, имеющей научно-практическое применение) группировки распределения численных значений признаков опережающих индикаторов, находимых в статистических данных и естественных языках.

Сегодня Росстат осуществляет расчеты парных распределений признаков ответов по широкому кругу показателей в строительстве (табл. 2).

Кроме того, в большей части двойных группировок присутствует третий параметр — территориальный. Таким образом осуществляется тройное распределение признаков для анализа внутренней взаимосвязи между базовыми показателями: выпуска, занятости, загрузки мощностей, спроса

⁶ Яковлев А.М., Осипов Г.В. и др. Рабочая книга социолога. Учебное пособие. М.: URSS; 2009.



Таблица 2 / Table 2

Типы форм результатов расчетов распределения парных значений признаков в мониторинге опережающих индикаторов, рассчитываемых в строительстве / Types of Forms of Calculation Results for the Distribution of Paired Values of features in Monitoring Leading Indicators Calculated in Construction

Показатель / indicator	Группа / Group
Основные факторы, ограничивающие строительную деятельность	В разрезе территорий, основных сфер финансово-хозяйственной деятельности, управления, форм собственности
Распределение строительных организаций по ключевым показателям деловой активности	В разрезе территорий, групп крупных и средних предприятий, субъектов малого предпринимательства, форм собственности
Распределение строительных организаций по ключевым показателям деловой активности	В разрезе оценки текущего периода по отношению к предшествующему периоду и будущего периода (12 месяцев) по отношению к текущему периоду, сферам управления
Распределение строительных организаций по ключевым показателям финансово-хозяйственной деятельности	В разрезе территорий, групп крупных и средних предприятий, субъектов малого предпринимательства, форм собственности, сфер управления
Нарушения строительных правил, норм и регламентов	В разрезе территорий, групп по формам собственности
Направления в строительстве	В разрезе территорий, крупного и малого предпринимательства, форм собственности

Источник / Source: составлено авторами по данным Росстата / Compiled by the authors based on Rosstat data.

(портфеля заказов), закупочных цен и цен реализации, профилей строительства (промышленного, инфраструктурного, жилищного, социального), финансового положения строителей и платежеспособности партнеров и клиентов.

В анализе не предусмотрена взаимосвязь строительно-монтажных работ с производством строительных материалов и их транспортировкой, являющихся неотъемлемой частью строительного комплекса.

Пример строительства выбран не случайно, так как он — единственный в своем роде. При всем том, что он, очевидно, может служить базовым шаблоном для анализа опережающих данных, тем не менее не случайно, что в других сферах экономических опережающих индикаторов он не применяется.

Сегодня информационные технологии достигли такого уровня, что анализ больших данных может проводиться не только централизованно, но и по мере необходимости сообществами всех участников строительных комплексов, не говоря уже о регулирующих органах в вертикали государственного управления и объединениях саморегулирования.

Перенос измеренной в варьирующей совокупности в статике для преактивных значений результативного признака в динамике не является закономерностью взаимосвязи и требует проверки условий допустимости экстраполяции, что выходит за рамки статистики и относится к сфере экспертных оценок, использующихся для подтверждения возможности их отнесения к будущему.

Задачу описания опережающих индикаторов, решавшуюся до сих пор простым методом конвенционализма⁷, нельзя отнести к строгим доказательствам. Объективность и актуальность опережающих индикаторов доказывается: (1) путем математически строгого обоснования выборки участников⁸; (2) актуальностью временных периодов и присваиваемых исследуемым событиям соответствующих экономических смыслов [10]; (3)

⁷ Орлов А.И. Консенсус-прогнозы. Сбonds. Экспертные оценки. Учебное пособие. М.: ИВСТЭ; 2002. URL: https://cbonds.ru/consensus_forecasts/

⁸ Обоснование выборки в социологическом исследовании. URL: https://studwood.net/1570626/sotsiologiya/obosnovanie_vyborki_v_sotsiologicheskom_issledovanii#google_vignette



исключением мультиколлинеарности подбором стохастически взаимосвязанных факторов⁹; (4) тестированием сходимости опережающих индикаторов с результатами статистического наблюдения динамики соответствующих показателей.

Прогнозирование на основании регрессионного анализа в информатике обычно ограничивается малой изменчивостью факторов и условий изучаемого процесса, прямо не связанных с ними¹⁰. Предположение «при прочих равных условиях» в экономике неприменимо, так как все факторы, условия и обстоятельства изменяются постоянно во взаимосвязи друг с другом.

Считается, что если резкие, например, ценовые шоки рынка изменяют факторы, учитываемые для неизменных условий, то уравнение регрессии в информатике теряет экономический смысл. На самом деле именно изменчивость факторов в первую очередь учитывается при использовании ожиданий, и эта изменчивость должна отображаться не только архивными данными, но и ожидаемыми данными. Именно так и происходит в преактивном синтезе мнений и действий субъектов хозяйственной деятельности.

ВЫВОДЫ

Основной вывод из сравнения рассмотренных вариантов методологии моделирования фрактальности¹¹ динамики финансово-экономических процессов состоит в том, что любое включение генеральной совокупности верифицируемых мнений деловых сообществ в прогнозные модели улучшает ее качество и тем больше, чем большее значение им придается с помощью наделения эконометрических изменений социолого-экономическим смыслом. Этот результат достигается путем использования временных последовательностей показателей, приведения их к единой фрактальной размерности, перенесения верификации модели и оценки качества модели ожидаемых параметров экономики и финансов на прогнозную модель.

Для производителей крайне острой является задача формирования информационной платфор-

мы опережающих данных их бизнес-экосистем и названных выше партнеров, особенно с иностранным участием. Сплошное наблюдение опережающих индикаторов дает возможность решать указанные задачи каждым хозяйствующим субъектом и их сообществами по собственным программам анализа данных с помощью централизованных или клиентоориентированных дата-центров, соединяемых при необходимости в блокчейн-системы. В этом заинтересованы государственные регулирующие органы в отраслях и на территориях, объединения саморегулирования, крупные предприятия (корпорации).


В условиях резко меняющихся социально-экономических условий предстоит проделать значительную работу по внедрению технологии опережающих данных в ядро будущей экономики и управления. С этой целью представляется необходимым:

- дополнить методологические подходы к формированию клиентоориентированной базы пользователей данных об опережающих индикаторах, включая Банк России, ГРБС, ФОИВ в целом и с разбивкой по административным территориям, муниципалитетам, объединениям саморегулирования, внешнеэкономическим и международным организациям;
- дополнить обоснование методологии статистического наблюдения опережающих индикаторов перспективными требованиями и предложениями регулирующих органов и международных организаций с участием Российской Федерации;
- внести поправки в законодательство РФ и ведомственные акты, регламентирующие статистическое наблюдение опережающих индикаторов, а также дополнения и корректировки в распорядительные документы национального проектирования, программирования и стратегического планирования социально-экономического развития;
- внести предложения в распорядительные документы по гармонизации методологии статистического наблюдения опережающих индикаторов стран ЕАЭС, БРИКС+, ОЭСР, S&P (MARKit Economics), ISM (USA);
- сформировать и поддерживать базы данных лучшей практики использования информационных ресурсов опережающих индикаторов НБР, Международного евразийского банка, Банка СНГ для импортозамещения МВФ, БМР на новых информационных принципах.

⁹ Стохастический анализ: описание, методы, особенности правила. FB.ru. URL: <https://fb.ru/article/544807/2023-stohasticheskiy-analiz-opisanie-metodyi-osobennosti-pravila>

¹⁰ Регрессия в анализе данных: объяснение и примеры. Skypro. URL: <https://sky.pro/wiki/sql/regressiya-v-analize-dannyh-obuyasnenie-i-primery/>

¹¹ Кулак Л.А. (Антония Ильинская) Динамика формирования нового социального фрактала. URL: <https://proza.ru/2020/01/19/184>




СПИСОК ИСТОЧНИКОВ

1. Варьяш И. Ю. Контроллинг экономических ожиданий. Монография. М.: Финуниверситет; 2012. URL: <https://www.elibrary.ru/qvimen>
2. Варьяш И. Ю., Бурова Т. Ф., Панасенко К. К. Исследование моделей опережающих индикаторов условий финансирования. *Кронос. Экономические науки*. 2019;1(15):100-114. URL: <https://www.elibrary.ru/njzzlv>
3. Варьяш И. Ю., Зубец А. Н. Оценка опережающих индикаторов экономической деятельности в Российской Федерации по методологии ОЭСР. *Вопросы статистики*. 2016;11:31-36. URL: <https://www.elibrary.ru/xddrpx>
4. Варьяш И. Ю., Логвинов С. А., Ильинский А. И., Донцова О. И. и др. Макропланирование экономического развития. Динамическая модель опережающих индикаторов. Монография. Николаев: Издательство Ирины Гудым; 2014. URL: <https://www.elibrary.ru/vqrkdh>
5. Чесноков С. В. Детерминационный анализ социально-экономических данных. М.: Наука; 1982. URL: <https://djvu.online/file/6OBkODV25zaPa?ysclid=mnx91ke2lv459588904>
6. Колмогоров А. Н. Теория вероятностей и математическая статистика. М.: Наука; 1986. URL: <https://reallib.org/reader?file=507152&ysclid=mnx8nshb7u686557531>
7. Колмогоров А. Н. О представлении непрерывных функций нескольких переменных суперпозициями непрерывных функций меньшего числа переменных. Доклады АН СССР. 1956;108:179-182. URL: <https://bigenc.ru/b/o-predstavlenii-nepreryvny-5e6285?ysclid=mnx8qub38c697393602>
8. Жуков Д. С., Лямин С. К. Варианты использования методов фрактальной геометрии в социальных и политических исследованиях. *Internum*. 2010;2:17-35. URL: <https://www.elibrary.ru/nccxnl>
9. Варьяш И. Ю. Исследование реальных фракталов опережающих индикаторов. *Цифровые решения и технологии искусственного интеллекта*. 2026;2(1):73-82. URL: <https://doi.org/10.26794/3030-7097-2026-2-1-73-82>
10. Толстен В. Ш. О некоторых параллелях процессов формирования и организации внутренней структуры искусственных и естественных языков. *Вестник Адыгейского государственного университета. Серия: Естественно-математические и технические науки*. 2007;4:52-55. URL: <https://www.elibrary.ru/kbxddj>

REFERENCES

1. Varjas I. Yu. Controlling economic expectations. A monograph. Moscow: Financial University; 2012. (In Russ.). URL: <https://www.elibrary.ru/qvimen>
2. Varjas I. Yu., Burova T. F., Panasencko K. K. Research of models of leading indicators of financing conditions. *Kronos. Economic Sciences*. 2019;1(15):100-114. (In Russ.). URL: <https://www.elibrary.ru/njzzlv>
3. Varjas I. Yu., Zubets A. N. Assessment of leading indicators of economic activity in the Russian Federation according to the OECD methodology. *Statistical Issues*. 2016;11:31-36. (In Russ.). URL: <https://www.elibrary.ru/xddrpx>
4. Varjas I. Yu., Logvinov S. A., Ilyinsky A. I., Dontsova O. I. and others. Macro-planning of economic development. Dynamic model of leading indicators. A monograph. Nikolaev: Irina Gudym Publishing House; 2014. (In Russ.). URL: <https://www.elibrary.ru/vqrkdh>
5. Chesnokov S. V. Determinative analysis of socio-economic data. Moscow: Nauka; 1982. (In Russ.). URL: <https://djvu.online/file/6OBkODV25zaPa?ysclid=mnx91ke2lv459588904>
6. Kolmogorov A. N. Probability theory and mathematical statistics. Moscow: Nauka Publ., 1986. (In Russ.). URL: <https://reallib.org/reader?file=507152&ysclid=mnx8nshb7u686557531>
7. Kolmogorov A. N. On the representation of continuous functions of several variables by superpositions of continuous functions of a smaller number of variables. Reports of the USSR Academy of Sciences. 1956;108:179-182. (In Russ.). URL: <https://bigenc.ru/b/o-predstavlenii-nepreryvny-5e6285?ysclid=mnx8qu38c697393602>
8. Zhukov D. S., Lyamin S. K. Options for using fractal geometry methods in social and political research. *Internum*. 2010;2:17-35. (In Russ.). URL: <https://www.elibrary.ru/nccxnl>
9. Varjas I. Yu. Investigation of real fractals of leading indicators. *Digital solutions and artificial intelligence technologies*. 2026;2(1):73-82. (In Russ.). URL: <https://doi.org/10.26794/3030-7097-2026-2-1-73-82>
10. Tolstenov V. S. About some parallels of the processes of formation and organization of the internal structure of artificial and natural languages. *Bulletin of the Adygea State University. Series: Natural mathematical and technical sciences*. 2007;4:52-55. (In Russ.). URL: <https://www.elibrary.ru/kbxddj>



ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Игорь Юрьевич Варьяш — доктор экономических наук, руководитель Аналитического центра финансовых исследований Научно-исследовательского финансового института, Министерство финансов Российской Федерации, Москва, Российская Федерация

Igor Yu. Varjas — Dr. Sci. (Econ.), Head of the Analytical Centre for Financial Research, Financial Research Institute, Ministry of Finance of the Russian Federation, Moscow, Russian Federation
<https://orcid.org/0000-0002-4816-8086>
varjas@nifi.ru

Татьяна Федоровна Бурова — научный сотрудник Аналитического центра финансовых исследований Научно-исследовательского финансового института, Министерство финансов Российской Федерации, Москва, Российская Федерация

Tatiana F. Burova — Researcher at the Analytical Center for Financial Research of the Scientific Research Institute of Finance, Ministry of Finance of the Russian Federation, Moscow, Russian Federation
<https://orcid.org/0000-0001-6280-837X>
burova@nifi.ru

Даниил Викторович Климонов — аналитик Аналитического центра финансовых исследований Научно-исследовательского финансового института, Министерство финансов Российской Федерации, Москва, Российская Федерация; аспирант, Московский университет «Синергия», Москва, Российская Федерация

Daniil V. Klimonov — Analyst of the Analytical Centre for Financial Research, Financial Research Institute of the Ministry, Finance of the Russian Federation, Moscow, Russian Federation; Ph.D. Student of the Moscow University “Synergy”, Moscow, Russian Federation
<https://orcid.org/0009-0000-4319-6857>

Автор для корреспонденции / Corresponding author:
dklimonov@nifi.ru

Заявленный вклад авторов:

И.Ю. Варьяш — разработка концепции статьи, представление проведенных исследований и анализ результатов, заключение, выводы, рекомендации.

Т.Ф. Бурова — разработка концепции статьи, представление проведенных исследований и анализ результатов, заключение, выводы, рекомендации.

Д.В. Климонов — разработка концепции статьи, представление проведенных исследований и анализ результатов, заключение, выводы, рекомендации.

Authors' contributions:

I.Yu. Varjas — development of the article concept, presentation of the conducted research and analysis of the results, conclusion, findings, recommendations.

T.F. Burova — development of the article concept, presentation of the conducted research and analysis of the results, conclusion, findings, recommendations.

D. V. Klimonov — development of the article concept, presentation of the conducted research and analysis of the results, conclusion, findings, recommendations.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов. Conflicts of Interest Statement: The authors have no conflicts of interest to declare.

Статья поступила 19.01.2026; после рецензирования 02.03.2026; принята к публикации 13.03.2026.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 19.01.2026; revised on 02.03.2026 and accepted for publication on 13.03.2026.

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



Empirical Verification of the Anchoring Effect Hypothesis on the Acquiring Company's Stock Returns in Trading Deals

A.A. Malyshev¹, S.R. Muminova²¹ Plekhanov Russian University of Economics, Moscow, Russian Federation;² Financial University under the Government of the Russian Federation, Moscow, Russian Federation

ABSTRACT

Currently, theoretical and practical research pays much attention to merger and acquisition deals, but it is of great importance to study behavior factor and irrational behavior buying company too. The anchoring effect enables estimating this type of deviations on the quantitative level. The relevance of the study is provided by the necessity to take into account investor cognitive bias to explain logic and to evaluate efficiency of the national stock market. Academic novelty is an empirical verification of the hypothesis applied to Russian capital market with the use of quantitative methods. The aim of the paper is to test the hypothesis concerning the influence of anchoring effect on acquiring company's stock returns on Russian M&A market and to perform quantitative estimation of the strength of this influence by regression modeling. The outcome of the study is the practical recommendations on taking into account the behavior bias designed for investors. The research was carried out on the basis of data on domestic acquiring companies by means of correlation and regression analysis. The methodology comprised modeling of expected and abnormal stock returns relative to merger and acquisition deals date announcement to reveal statistically significant relationship. The study empirically proves a significant anchoring effect on quotation dynamics. The regression equations have been obtained, statistical significance of factors has been determined that is a quantitative measure of the given behavior bias on Russian market. The obtained results concord with the results of the studies performed for foreign stock markets, proving universality of the effect. Practical value of the research is the possibility to implement this approach for comparative analysis of efficiency of various capital markets and for development of investment strategies addressing the consequences of behavior prejudice.

Keywords: anchoring effect; merge and acquisition deal; behavior economics; correlation and regression analysis; stock return

For citation: Malyshev A.A., Muminova S.R. Empirical verification of the anchoring effect hypothesis on the acquiring company's stock returns in trading deals. *Digital solutions and artificial intelligence technologies*. 2026;2(2):72-80. DOI: 10.26794/3030-7097-2026-2-2-72-80

ОРИГИНАЛЬНАЯ СТАТЬЯ

Эмпирическая проверка гипотезы влияния эффекта якоря на доходность акций компании-покупателя в торговых сделках

А.А. Малышев¹, С.Р. Муминова²¹ Российский экономический университет им. Г.В. Плеханова, Москва, Российская Федерация;² Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

В современной научной литературе исследование сделок слияний и поглощений занимает одно из ключевых положений, однако изучение поведенческого фактора и нерационального поведения покупателя требует большего внимания. Эффект якоря позволяет оценить подобного рода отклонения на количественном уровне. **Актуальность работы** обусловлена необходимостью учета когнитивных искажений инвесторов для понимания закономерностей и оценки эффективности национального фондового рынка. Научная новизна заключается в эмпирической проверке данной гипотезы применительно к российскому рынку капитала с использованием количественных методов. **Целью статьи** является эмпирическая проверка гипотезы о влиянии эффекта якоря в доходности акций компаний-покупателей на российском рынке M&A, количественная оценка силы этого влияния с помощью построения регрессионных моделей и разработка практических рекомендаций для инвесторов по учету данного поведенческого искажения. Исследование проводилось на основе данных об отечественных компаниях-покупателях с применением корреляционно-регрессионного анализа. **Методология** включала моделирование ожидаемой и аномальной доходности акций относительно даты объявления сделок слияний и поглощений для выявления статистически значимых

закономерностей. В результате исследования эмпирически подтверждено значимое влияние эффекта якоря на динамику котировок. Получены уравнения регрессий, установлена статистическая значимость факторных признаков, что количественно характеризует силу данного поведенческого искажения на российском рынке. **Полученные результаты** согласуются с выводами исследований зарубежных фондовых рынков, подтверждая универсальность эффекта. **Практическая ценность** работы заключается в возможности применения подхода для сравнительного анализа эффективности разных рынков капитала и для разработки инвестиционных стратегий, нивелирующих поведенческие предубеждения.

Ключевые слова: эффект якоря; M&A; поведенческая экономика; корреляционно-регрессионный анализ; доходность

Для цитирования: Малышев А.А., Муминова С.Р. Эмпирическая проверка гипотезы влияния эффекта якоря на доходность акций компании-покупателя в торговых сделках. *Цифровые решения и технологии искусственного интеллекта*. 2026;2(2):72-80. DOI: 10.26794/3030-7097-2026-2-2-72-80

INTRODUCTION

Today, the strong impact produced by the deals on financial markets hardly can be ignored. Therefore, much attention is given to merger and acquisition (M&A) deals relating to big companies. Such options affect vendor's and consumer's financial status, consolidate companies' sources, enable wide use of patents and technologies and allow scaling for companies in targeted economy sector. Analysis of M&A deals makes it possible to estimate financial attractiveness and strategical pragmatism of the option, to reveal synergetic effects, including lowered costs and income increase, to forecast future cash flow and cost of the merged company. One of the factors to be taken into account is the anchoring effect. Anchoring effect is a psychological phenomenon where people make a judgment based on a reference point and then make adjustments based on it. Due to insufficient judgement the final judgment is subject to the influence of the reference point [1]. For the last decade, this psychological phenomenon has been studied in various spheres: from real estate market [2, 3] to management [4–6]. In financial sector, the anchoring effect shows one of the characteristics related to investor's behavior on stock market if the acquirer is a public company [7, 8].

The anchoring effect is a phenomenon of behavioral economics, investors' cognitive distortion, which in M&A deals is expressed through changing stock quotation of acquiring company at the moment of option event announcement in dependence of historical stock quotation [9–11]. The investigators of foreign stock markets proved that the acquirer obtains higher earnings ratio at the moment of deal announcement if stock price prior to merge had been significantly lower than its maximum value within a time horizon of 52 weeks (one year). In contrast, they have lower earnings ratio if the stock value had been close to its maximum within the year. Such investors' behavior is caused by their biased estimation of company value, low efficiency of investigated market. The research of the anchoring effect enables quantitative assessment of degree of impact produced by investors' behavior

bias on the company value at the moment when M&A option is announced.

The behavior of economic actor is based on the bias concerning some initial asset value. Investors pass two stages: at first they create “an anchor” in their mind, and after that they adopt final decision on acquiring or selling asset on the basis of this anchor that is expressed in the stock value within the horizon of one year.

THE METHODS USED IN RESEARCH

At the first stage statistics was collected, that became information base for research. The process of gathering data is based on recording the fact about deal, its date and share quotations of company-acquirer (day return) with other variables. The sample includes 83 M&A deals. The selected deals meet the following criteria: acquirer's shares are traded on the stock market, and IPO have taken place at least one year prior the date of the deal. The researchers also collected data on sum of transactions, amount of acquirer's capitalization one year before the deal, indicator of concordance of acquiring company and target company, indicator of availability target share listing on exchange at the moment of deal announcement. The ratio of deal amount to acquirer's capitalization has been calculated.

The first composite variable of acquirer's return is the expected return of its own shares. Model values of share return (expected return) are calculated on the horizon [–20; +20] trade days (null day corresponds to deal announcement day) with the method of linear regression function proposed by MacKinlay [12], where independent factor is a market return of Moscow Central Stock Exchange index. To obtain coefficients of the equation the horizon [–120; –21] days (a half of the year) was selected:

$$R_{it} = \alpha_i + \beta_i R_{mt} + \varepsilon_{it}, \quad (1)$$

where R_{it} — return of share i in period t ; R_{mt} — market return in period t ; α_i — constant of linear regression of share i ; ε_{it} — regression error; β_i — regression coefficient of share i .

A regression of expected returns on the example of SBER shares is shown on Fig. 1.




Fig. 1. Regression Chart of Expected Returns of SBER Shares

Source: author's calculations.

To obtain actual cumulative abnormal returns (CAR) that will clearly show the anchoring effect, one should calculate abnormal returns. To do this, it is necessary to know the following variables: day returns of the share (real returns), model day returns of the same share on the same observed horizon (expected returns).

$$AR_{it} = R_{it} - \hat{\alpha}_i - \hat{\beta}_i R_{mt}, \quad (2)$$

where AR_{it} — abnormal return of share i within range τ from deal date; R_{it} — return of share i within range τ from deal date; R_{mt} — market return on period within range τ from deal date; $\hat{\alpha}_i$ — a model constant of linear regression for share i ; $\hat{\beta}_i$ — model coefficient of regression for share i .

$$CAR_{it} = \sum AR_{it}, \quad (3)$$

where AR_{it} — abnormal return of share i within range τ from deal date.

Taking into account that expected, hence, abnormal returns were calculated on horizon $[-20; +20]$, cumulative returns were calculated within on the same horizon. Additionally, cumulative abnormal returns have been computed within the ranges $[-10; +10]$, $[-5; +5]$, $[-5; +3]$, $[-5; +1]$.

Anchoring indicator is a reference price ratio (RPR) that is a ratio of stock quotation prior deal to its maximum value in the past on certain horizon. The authors of the study [13] proposed to use peak value for the last 54 weeks (1 year). They also tested alternative

anchors for periods of 1, 2 and 3 last quarter, on 75%, 90% and 95% quartile of the last year.

$$RPR_{365} = \frac{y_{t-21}}{\max[y_{t-250}; y_{t-22}]}, \quad (4)$$

where y_{t_0} — closing price of the share on the trade day of deal announcement.

Regression modelling was performed to test following hypothesis: anchoring effect is present at Russian stock market and it is statistically significant; acquirer obtains higher returns due to deal announcement as a result of lower share price respect to annual peak.

To model how cumulative abnormal returns depends on anchoring effect multifactor equation of linear regression (least square method), based on method by Ma [14], was applied. The general equation can be presented in the following way:

$$\begin{aligned} CAR_i = & \alpha + \beta_0 RPR + \beta_1 \text{General economy sector} + \\ & + \beta_2 \text{Presence of target listing} + \\ & + \beta_3 \frac{\text{Sum of transaction}}{\text{Acquirer capitalization 1 year prior to deal}} + \\ & + \beta_4 \ln(\text{Sum of transaction}) + \\ & + \beta_5 \ln(\text{Acquirer capitalization 1 year prior to deal}) + \varepsilon_i. \end{aligned} \quad (5)$$

DESCRIPTIVE STATISTICS

Analysis of M&A deals shows that the most part of such deals is concentrated in oil and financial economy sectors (Table 1). Database was collected from information sources, such as Kept (earlier known as KPMG),¹ information materials of Cbonds Review,² data from Investing.com, Moscow Exchange³ and SMART-LAB.⁴

Descriptive statistics of general variables is given in Table 2. The statistics demonstrates that the wider range of event is, the higher absolute values of maximum and minimum of abnormal returns are. That speaks for increased data scattering and standard deviation. That demonstrates that the wider range enables recording later maximum market reaction for merges, and it is also true for less efficient markets.

Further, the sample was divided into two parts: with high and low values of anchor for the range $[-20; +20]$ (higher and lower of median RPR1 accordingly). The data of Table 3 allow us to conclude that the lower values of anchor are corresponded to higher values of abnormal returns, i.e. the lower stock price respect to its annual maximum before the deal is, the higher actual cumulative abnormal returns are, that proves the

¹ URL: <https://kept.ru/>

² URL: <https://review.cbonds.info/>

³ URL: <https://www.moex.com/ru/data/>

⁴ URL: https://smart-lab.ru/q/shares_fundamental2/



presence of anchoring effect on Russian stock market. Maximum difference of average values is registered for the range $[-5; +5]$ and is equal to 2.53%.

Table 1

Distribution of M&A deals by Economic Sector

Economy Sector	USA USD	Percentage, %	Number of Deals
Oil and gas sector	65 733 272 727	57.35	32
Finances	17 097 666 667	14.92	17
Electrical energy industry	14 713 000 000	12.84	3
Tele-communication	4 873 914 286	4.25	13
Mountain metallurgy	3 975 000 000	3.47	2
Retail	3 330 904 762	2.91	4
Metallurgy	1 679 000 000	1.46	3
Coal industry	914 000 000	0.80	1
Construction	797 000 000	0.70	1
Agriculture	627 390 244	0.55	3
Chemical industries	588 000 000	0.51	2
Other industries	256 000 000	0.22	1
Medicine	33 000 000	0.03	1

Source: compiled by the authors.

ANCHORING EFFECT MODELLING

At first, single-factor models for various time ranges and for anchors, differently calculated, were analyzed. If one uses classic one year range with maximum peak in nominator as an anchor, the best results are provided by the model for the range $[-20; +20]$ with determination coefficient 11.1% at significance level 0.2% and by the model for the range $[-5; +1]$ with determination coefficient 12.6% at significance level 0.1%. Coefficient of the variable, reflecting anchoring effect, is negative, therefore, when stock quote approaches its annual peak before deal, the variable increases, dramatically diminishing acquirer's return. In addition, significant results were obtained when the anchor was used within the range of one quarter $[-62; -22]$ for the models $[-20; +20]$, $[-5; +5]$, $[-5; +1]$ with determination coefficient equal to 11.8%, 13.8%, 15.5% accordingly at 0.2–0.1% significance level. Models within the range $[-20; +20]$ are of stable quality for all types of calculations of anchor. The anchor for the range of one year and last quarter demonstrates the most valid results. Respectively low values of determination coefficients are practically unimportant, as the hypothesis tests statistical significance of return variation (resultative indicator) from anchor variation (factorial feature). Table 4 contains general model parameters on example of one year and quarter interval.

After that, we also built models for all deal event ranges, one-year and quarter anchors, but we used all independent variables mentioned in formula (5). Model for the range $[-20; +20]$ with one-year horizon anchor has determination coefficient which is equal

Table 2

Descriptive Statistics of Main Variables

Variable	Min	Q1	Average	Median	Q3	Max	SD
CAR $[-20; +20]$	-0.384	-0.072	0.017	0.003	0.073	0.649	0.140
CAR $[-10; +10]$	-0.312	-0.04	0.024	0.001	0.068	0.454	0.117
CAR $[-5; +5]$	-0.179	-0.03	0.024	-0.002	0.042	0.502	0.103
CAR $[-5; +3]$	-0.153	-0.029	0.015	0.001	0.038	0.35	0.081
CAR $[-5; +1]$	-0.095	-0.022	0.016	-0.001	0.033	0.354	0.073
RPR1	0.16	0.77	0.85	0.88	0.95	1.00	0.13
Sum of transaction, USD million	1	186	1394	412	1276	16 000	2713
Capitalization, USD million	87	6656	33 695	16 926	54 708	130 581	35 635
Sum of transaction / Capitalization	0.00	0.01	0.16	0.03	0.13	2.39	0.37

Source: compiled by the authors.




Table 3

Average Values of Cumulative Abnormal Returns in the Samples of the Lowest and Highest Anchor Values, %

Variable	All sample	Low anchor	High anchor	Sample differences
CAR[-5;+1]	1.63	1.67	1.59	0.08
CAR[-5;+3]	1.46	1.63	1.30	0.33
CAR[-5;+5]	2.36	3.62	1.10	2.53
CAR[-10;+10]	2.36	2.58	2.15	0.43
CAR[-20;+20]	1.74	2.25	1.23	1.02

Source: compiled by the authors.

Table 4

Parameters of Single-factor Anchoring Effect Models

Metrics	Model				
	1. CAR[-20; +20]	2. CAR[-10; +10]	3. CAR[-5; +5]	4. CAR[-5; +3]	5. CAR[-5; +1]
Constant	0311 (0,001)	0.158 (0,058)	0.202 (0,006)	0.156 (0,006)	0.179 (0,000)
RPR365	-0.346 (0.002)	-0.158 (0.102)	-0.210 (0.013)	-0.166 (0.012)	-0.191 (0.001)
R-squared	0.111	0.033	0.075	0.076	0.126
F-statistic	9.9850	2.729	6.456	6.599	11.53
p-value(F)	0.002	0.102	0.013	0.012	0.001
Constant	0.588 (0.001)	0.364 (0.018)	0.473 (0.000)	0.334 (0.002)	0.357 (0.000)
RPR_Q1	-0.618 (0.002)	-0.369 (0.027)	-0.487 (0.001)	-0.346 (0.002)	-0.369 (0.000)
R-squared	0.118	0.06	0.133	0.109	0.155
F-statistic	10.6600	5.095	12.32	9.837	14.71
p-value(F)	0.002	0.027	0.001	0.002	0

Source: compiled by authors.

to 18.3% at 0,2% significance level. The best result is demonstrated by the model for the range [-5; +5] with one-year horizon anchor which determination coefficient is equal to 44% at significance level <0,01%. Accuracy of the models is practically equal both for one-year horizon anchor and the last quarter. This could be suggestive of investors taking into account historical stock prices both for one-year period and the last quarter to the same extent. The Fig. 2 shows parameters of the basic model for one-year horizon with an anchor within the limits ± 20 days from the deal date.

One the basis of obtained multifactor models, one can exclude unimportant factors from regression at 10% significance level. General model for the range [-20; +20] with one-year horizon anchor has deter-

mination coefficient which is equal to 16,5% at significance level less than 0.01%. Significant variable, along with the constant and anchor, is acquirer's total capitalization. That means that the investors consider large companies as the least profitable when regarding the widest of all possible horizons concerning deal event. It can be explained either by higher liquidity of stocks of such companies due to their prevalence or by huge amount of information on the market, which decreases uncertainty level, that results in decreased abnormal returns. The academic works provide sufficient proofs of direct dependencies between uncertainty and anchoring effect [15–17]. Using the range [-5; +5], it is possible to obtain determination coefficient 42.1%, but one should take into account significance level of variables, at which the constant and anchor are at

OLS Regression Results						
Dep. Variable:	car_20_20		R-squared:	0.183		
Model:	OLS		Adj. R-squared:	0.118		
Method:	Least Squares		F-statistic:	2.803		
Date:	Mon, 12 Jan 2026		Prob (F-statistic):	0.0163		
Time:	21:42:37		Log-Likelihood:	53.666		
No. Observations:	82		AIC:	-93.33		
Df Residuals:	75		BIC:	-76.48		
Df Model:	6					
Covariance Type:	nonrobust					
	coef	std err	t	P> t	[0.025	0.975]
const	0.5743	0.275	2.087	0.040	0.026	1.122
rpr_max365	-0.2958	0.112	-2.631	0.010	-0.520	-0.072
industry	-0.0100	0.031	-0.319	0.751	-0.073	0.053
listed	-0.0032	0.038	-0.084	0.934	-0.079	0.073
ratio	0.0176	0.052	0.337	0.737	-0.086	0.121
ln_size	-0.0213	0.012	-1.767	0.081	-0.045	0.003
ln_deal	0.0099	0.010	0.939	0.351	-0.011	0.031
Omnibus:	8.300	Durbin-Watson:	2.419			
Prob(Omnibus):	0.016	Jarque-Bera (JB):	13.147			
Skew:	0.330	Prob(JB):	0.00140			
...						

Fig. 2. Model Parameters on a 1-year Horizon With an Anchor Within ± 20 Trading Days From the Transaction Date

Source: author's calculations.

8% and 6% significance level accordingly, that is not quite reliable result. Within the range $[-5; +5]$ transaction value to market capitalization ratio is significant too. Transaction value variable is connected to uncertainty level as it is much more difficult to estimate big deals. Transaction value variable turned out to be insignificant. Regression diagram for the deal range $[-5; +5]$ and excesses are illustrated in figures (3) and (4) accordingly. Table 5 contains parameters of cleared multifactor models.

To test model result robustness, several types of anchors, calculated by alternative method, were introduced. For that, one-quarter, two-quarters and three-quarters horizon anchors, stock price percentile division for the last year at the level 75%, 90% and 95% were introduced in the calculation above. On the basis of built single-factor and multifactor models in most cases the anchors turned out to be significant independent variables (Table 6). That proves robustness of the result and demonstrates anchoring effect in all




Fig. 3. Regression Chart Over a 1-year Horizon With an Anchor Within ± 5 Trading Days From the Trade Date

Source: compiled by the authors.




Fig. 4. Charts of the Model's Residuals on a 1-year Horizon with an Anchor Within ± 5 Trading Days From the Trade Date

Source: author's calculations.



Table 5

Significant Variables of Multivariate Anchoring Effect Models

Metrics	Model				
	1. CAR[−20; +20]	2. CAR[−10; +10]	3. CAR[−5; +5]	4. CAR[−5; +3]	5. CAR[−5; +1]
Constant	0.742 (0.001)	0.084 (0.283)	0.105 (0.074)	0.468 (0.000)	0.451 (0.000)
RPR365	−0.290 (0.010)	−0.095 (0.291)	−0.127 (0.06)	−0.126 (0.048)	−0.156 (0.006)
Economy sector	—	—	—	—	—
Target listing	—	—	—	0.033 (0.083)	—
Sum of transaction / capitalization	—	0.126 (0.000)	0.165 (0.000)	—	—
ln(Sum of transaction)	—	—	—	—	—
ln(capitalization)	−0.021 (0.027)	—	—	−0.015 (0.004)	−0.013 (0.006)
R-squared	0.165	0.189	0.421	0.199	0.206
F-statistic	7.8040	9.2	28.68	6.44	10.23
p-value(F)	0.0008	0.0003	0	0.0006	0.0001
Constant	0.897 (0.000)	0.198 (0.186)	0.254 (0.023)	0.555 (0.000)	0.549 (0.000)
RPR_Q1	−0.493 (0.014)	−0.209 (0.190)	−0.277 (0.021)	−0.249 (0.029)	−0.291 (0.004)
Economy sector	—	—	—	—	—
Target listing	—	—	—	0.032 (0.09)	—
Sum of transaction / capitalization	—	0.119 (0.000)	0.158 (0.000)	—	—
Ln (Sum of transaction)	—	—	—	−0.014 (0.012)	−0.011 (0.019)
Ln (capitalization)	−0.018 (0.056)	—	—	—	—
R-squared	0.158	0.195	0.434	0.208	0.212
F-statistic	7.3900	9.575	30.26	6.82	10.66
p-value(F)	0.0011	0.0002	0	0.0004	0

Source: compiled by the authors.

calculation methods. Also, to test dependency of stock quotation on annual peak of market index, applicability of anchoring effect to Moscow Central Stock Exchange has been studied. However, the market anchoring coefficient turned out to be insignificant (Fig. 5).

CONCLUSION

The hypothesis concerning the presence of anchoring effect on Russian market has been proved. The results of the study revealed statistically significant negative dependency between acquirer's abnormal reward in M&A deals and anchoring value (closeness stock price to its historical maximum). The higher the anchoring value (i.e., the closer quotation to

its peak), the lower the abnormal reward is, that indicates cognitive investor prejudice.

Long-term estimations are the most relevant ones. Anchoring effect is mostly stable and significant in calculations of one-year horizon and last quarter, as well as for wide range of events [−20; +20] trade days in respect to the deal. These models demonstrate constant quality and significance of the coefficients.

Multi-factor analysis revealed key factors affecting acquirer's reward. The most significant model (in the range [−20; +20] of reward) proved the importance of company size along with anchoring effect. The negative tie between abnormal reward and capitalization

Values of the Coefficients and Significance of the Anchor Variable in Single-factor Models

Metrics	Model				
	1 CAR[-20; +20]	2 CAR[-10; +10]	3 CAR[-5; +5]	4 CAR[-5; +3]	5 CAR[-5; +1]
RPR365	-0.346 (0.002)	-0.158 (0.102)	-0.210 (0.013)	-0.166 (0.012)	-0.191 (0.001)
RPR_Q1	-0.618 (0.002)	-0.369 (0.027)	-0.487 (0.001)	-0.346 (0.002)	-0.369 (0.000)
RPR_Q2	-0.498 (0.001)	-0.275 (0.033)	-0.356 (0.001)	-0.25 (0.005)	-0.248 (0.002)
RPR_Q3	-0.411 (0.001)	-0.202 (0.057)	-0.264 (0.004)	-0.196 (0.007)	-0.205 (0.002)
RPR365_q0.75	-0.334 (0.002)	-0.141 (0.122)	-0.186 (0.02)	-0.130 (0.038)	-0.145 (0.009)
RPR365_q0.9	-0.349 (0.002)	-0.146 (0.127)	-0.191 (0.023)	-0.144 (0.03)	-0.166 (0.005)
RPR365_q0.95	-0.339 (0.003)	-0.142 (0.144)	-0.187 (0.027)	-0.146 (0.028)	-0.172 (0.004)

Source: compiled by the authors.

complies with information effectiveness hypothesis: big companies' operations are to be controlled more strictly to decrease uncertainty and probability of abnormal reward.

The anchoring effect is a feature of single companies and it is not valid for the market index. An attempt to apply anchoring concept to Moscow Central Stock Exchange index didn't reveal statistically significant tie. That is a sign that the discovered effect is a characteristic of how investors percept stock quotations of acquiring companies but not general state of the market.

The results are reliable. Robustness test with the use of various anchoring effect calculation methods proved reliability and reproducibility of the results, that reinforces validity of conclusions.

Thus, the hypothesis of the study has been proved at statically significant level. Russian stock market, in the context of single acquirer's stocks, demonstrates liability to anchoring effect when the merge and acquisition deals are announced.

OLS Regression Results						
=====						
Dep. Variable:	car_20_20		R-squared:	0.124		
Model:	OLS		Adj. R-squared:	0.054		
Method:	Least Squares		F-statistic:	1.772		
Date:	Mon, 12 Jan 2026		Prob (F-statistic):	0.116		
Time:	21:03:55		Log-Likelihood:	50.805		
No. Observations:	82		AIC:	-87.61		
Df Residuals:	75		BIC:	-70.76		
Df Model:	6					
Covariance Type:	nonrobust					
=====						
	coef	std err	t	P> t	[0.025	0.975]


const	0.5729	0.299	1.918	0.059	-0.022	1.168
rpr_mmbv	-0.1887	0.159	-1.183	0.240	-0.506	0.129
industry	-0.0136	0.033	-0.419	0.676	-0.078	0.051
listed	0.0020	0.039	0.052	0.959	-0.077	0.081
ratio	0.0389	0.054	0.724	0.471	-0.068	0.146
ln_size	-0.0225	0.012	-1.802	0.076	-0.047	0.002
ln_deal	0.0072	0.011	0.669	0.506	-0.014	0.029
=====						
Omnibus:	22.028	Durbin-Watson:	2.554			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	65.906			
Skew:	0.764	Prob(JB):	4.88e-15			
...						

Fig. 5. A Model for Testing the Significance of the Market Anchoring Effect

Source: author's calculations.

REFERENCES

1. He Yu. The Trap of Anchoring Effect: A Study on the Impact of Anchoring Effect on Decision-Making. *BCP Business & Management*. 2023;38:1629-1633. URL: <https://doi.org/10.54691/bcpbm.v38i.3942>
2. Chen S., Wang W., Zhong L. Anchoring Effect in Chinas Real Estate Market. *Advances in Economics, Management and Political Sciences*. 2023;14(1):174-181. URL: <https://doi.org/10.54254/2754-1169/14/20230815>
3. Kazak Ja.K., Zarębska W., Sadowski A., Kamińska J.A. The Anchoring Effect in Real Estate Decisions. *Real Estate Management and Valuation*. 2025;34(1):53-62. URL: <https://doi.org/10.2478/remav-2026-0005>
4. Wei X. Practical Application of Anchoring Effect Based on Different Mechanisms. *Advances in Economics, Management and Political Sciences*. 2023;14(1):339-344. URL: <https://doi.org/10.54254/2754-1169/14/20230849>
5. Yue Zh. Discussion on Anchoring Effect in Our Real Life. *Advances in Education, Humanities and Social Science Research*. 2023;4(1):388. URL: <https://doi.org/10.56028/aehtsr.4.1.388.2023>
6. Ruan Sh. Study on the Influence of Anchoring Effect on Consumer Behavior and Consumer Phycology. *Highlights in Business, Economics and Management*. 2024;45:593-599. URL: <https://doi.org/10.54097/egvbkv90>



7. Zhang Ch. Overview and application of Endowment Effect, Anchoring and Hindsight Bias. *Finance & Economics*. 2025;1(6). URL: <https://doi.org/10.61173/0nrgh963>
8. Ceravolo M. G., Farina V., Fattobene L., et al. Anchoring effect in visual information processing during financial decisions: An eye-tracking study. *Journal of Neuroscience, Psychology, and Economics*. 2022;15(1):19-30. URL: <https://doi.org/10.1037/npe0000153>
9. Limpaphayom P., Sarajoti P., Stotz A. Anchoring effect and long-horizon analysts' forecast errors. *Cogent Economics and Finance*. 2025;13(1):2598189. URL: <https://doi.org/10.1080/23322039.2025.2598189>
10. Zhu S. Anchoring Effect in Capital Market. *Highlights in Business, Economics and Management*. 2022;1:66-70. URL: <https://doi.org/10.54097/hbem.v1i.2320>
11. Chen Yu. The Role of Anchoring Effect in the Stock Market Investment Decisions. *Advances in Economics, Management and Political Sciences*. 2023;29(1):48-54. URL: <https://doi.org/10.54254/2754-1169/29/20231349>
12. MacKinlay A. C. Event studies in economics and finance. *Journal of economic literature*. 1997;35(1):13-39. URL: <http://www.e-jel.org/archive/mar1997/Mackinla.pdf>
13. George T. J., Hwang C. Y. The 52-week high and momentum investing. *The Journal of Finance*. 2004;59(5):2145-2176. URL: <https://doi.org/10.1111/j.1540-6261.2004.00695.x>
14. Ma Q., Whidbee D. A., Zhang W. A. Anchoring and Acquisitions. 2016. URL: https://cba.lmu.edu/media/lmucoллегеofbusinessadministration/responsivesite/research/Ma_Anchoring%20and%20acquisitions.pdf
15. Tversky A., Kahneman D. Judgement Under Uncertainty: Heuristics and Biases. *Science, New Series*. 1974;185(4157):1124-1131. URL: <https://pdodds.w3.uvm.edu/files/papers/others/1974/tversky1974a.pdf>
16. Jacowitz K. E., Kahneman D. Measures of anchoring in estimation tasks. *Personality and Social Psychology Bulletin*. 1995;21(11):1161-1166. URL: <https://www.elibrary.ru/jpanph>
17. Mussweiler T., Strack F. Numeric judgments under uncertainty: The role of knowledge in anchoring. *Journal of experimental social psychology*. 2000;36(5):495-518. URL: <https://doi.org/10.1006/jesp.1999.1414>

ABOUT THE AUTHORS / ИНФОРМАЦИЯ ОБ АВТОРАХ

Alexey A. Malyshev — Master Student, Department of Sustainable Development Finance, Higher School of Finance (Faculty), Plekhanov Russian University of Economics, Moscow, Russian Federation

Алексей Андреевич Малышев — студент магистратуры, кафедра финансов устойчивого развития, Высшая школа финансов (факультет), Российский экономический университет им. Г. В. Плеханова, Москва, Российская Федерация

<https://orcid.org/0009-0005-3563-303X>

malishev.a3@edu.rea.ru

Svetlana R. Muminova — Cand. Sci. (Eng.), Assoc. Prof., 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

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

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

Corresponding author / Автор для корреспонденции:

srmuminova@fa.ru

Authors' declared contributions / Заявленный вклад авторов:

A.A. Malyshev — writing all sections except abstract.

S.R. Muminova — writing abstract, translation into English, formatting.

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

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

The article was submitted on 02.04.2026; revised on 13.04.2026 and accepted for publication on 22.04.2026.

Статья поступила 02.04.2026; после рецензирования 13.04.2026; принята к публикации 22.04.2026.

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

Авторы прочитали и одобрили окончательный вариант рукописи.