

ЦИФРОВЫЕ РЕШЕНИЯ И ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Научно-практический рецензируемый журнал
Издаётся с 2025 г.

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

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

Периодичность издания – 4 номера в год

Журнал ориентирован на научное обсуждение актуальных проблем
по научным специальностям:

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

Электронная версия журнала на русском и английском языках

находится в открытом доступе на сайте digitari.ru

Журнал публикует материалы на условиях лицензии

Creative Commons Attribution 4.0 International (CC BY 4.0).

DIGITAL SOLUTIONS AND ARTIFICIAL INTELLIGENCE TECHNOLOGIES

Scientific and practical peer-reviewed journal
Published since 2025



**ЦИФРОВЫЕ РЕШЕНИЯ
И ТЕХНОЛОГИИ
ИСКУССТВЕННОГО
ИНТЕЛЛЕКТА**

Научно-практический
журнал
Том 1, № 4, 2025

Главный редактор
Феклин
Вадим Геннадьевич

Заведующий редакцией
научных журналов
Головатенко
Валерий Иванович

Выпускающий редактор
Шишкова
Эвелина Юрьевна

Переводчик
Мельникова
Елизавета Сергеевна

Корректор
Михайлова
Светлана Феодосиевна

Верстальщик
Смирнова
Елена Анатольевна

**Адрес издателя
и редакции:**
125167, Москва,
Ленинградский пр-т, 53
Тел.: 8 (499) 553-10-71
(вн. 10-83)
E-mail: vgolovatenko@fa.ru
Сайт: digitari.ru

Подписано в печать:
25.12.2025
Формат 60 x 84 1/8.
Объем 11 п.л.

Отпечатано в ООО «СТ»,
г. Воронеж
Заказ № 2508803
Выход в свет 30.01.2026
© Финансовый университет
при Правительстве
Российской Федерации, Москва

**ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ
И МАШИННОЕ ОБУЧЕНИЕ**

Болтачев Э.Ф., Тюляков А.И.

Современные методы обработки документов
для расчета биржевых индикаторов. 6

Горбунова Е.А., Кочкаров Р.А., Окунева Э.А.

Анализ тональности пользовательского текста
методами машинного обучения. 16

Бердюгин А.А., Муминова С.Р.

Эволюция и перспективы развития видеоигр
приключенческого жанра в России. 26

**МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ, ЧИСЛЕННЫЕ
МЕТОДЫ И КОМПЛЕКСЫ ПРОГРАММ**

Гисин В.Б.

Динамическая модель внимания в трансформерах. 35

Tulipova O.P., Zhlobova G.N.

Gaussian Process Regression
for Product Geometry Prediction in CAE Modeling. 43

**МЕТОДЫ И СИСТЕМЫ ЗАЩИТЫ ИНФОРМАЦИИ,
ИНФОРМАЦИОННАЯ БЕЗОПАСНОСТЬ**

**Семухин С.Д., Пахолюк В.В., Осина П.Д., Кочкаров Р.А.,
Резниченко С.А., Окунева Э.А.**

Безопасность несовершеннолетних пользователей
в информационно-коммуникационной среде. 51

Рыженко А.А., Козьминых С.И.

Недекларируемые возможности файловой архитектуры.
Автоматизированный офис, текстовый редактор,
формат DOCX. 60

**МАТЕМАТИЧЕСКИЕ, СТАТИСТИЧЕСКИЕ
И ИНСТРУМЕНТАЛЬНЫЕ МЕТОДЫ В ЭКОНОМИКЕ**

Магомедов Р.М.

Влияние искусственного интеллекта
на цифровую трансформацию бизнеса в России. 69

Шайтура С.В., Семичевская Н.П., Шайтура Н.С.

Прогнозирование урожайности в регионах юга России
с использованием инструментов искусственного
интеллекта. 76

Варьяш И.Ю., Климонов Д.В.

Теоретическое решение модели неопределенности
опережающих данных. 86



ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING

Boltachev E.F., Tyulyakov A.I.

Modern Methods of Document Processing
for Calculating Stock Market Indicators 6

Gorbunova E.A., Kochkarov R.A., Okuneva E.A.

Sentiment Analysis of User Texts
with Machine Learning Methods 16

Berdyugin A.A., Muminova S.R.

Evolution and Opportunities of Adventure Videogames
in the Russian Federation 26

MATHEMATICAL MODELING, NUMERICAL METHODS AND SOFTWARE PACKAGES

Gisin V.B.

Dynamic Model of Attention in Transformers 35

Tulupova O.P., Zholobova G.N.

Gaussian Process Regression
for Product Geometry Prediction in CAE Modeling 43

METHODS AND SYSTEMS OF INFORMATION PROTECTION, INFORMATION SECURITY

**Semukhin S.D., Pakholyuk V.V., Osina P.D., Kochkarov R.A.,
Reznichenko S.A., Okuneva E.A.**

Safety of Underage Users in the Information
and Communication Environment 51

Ryzhenko A.A., Kozminych S.I.

Undeclared File Architecture Features.
Automated Office, Text Editor, Docx Format 60

MATHEMATICAL, STATISTICAL AND INSTRUMENTAL METHODS IN ECONOMICS

Magomedov R.M.

Impact of Artificial Intelligence
on the Digital Transformation of Business in Russia 69

Shaitura S.V., Semichevskaya N.P., Shaitura N.S.

Predicting Crop Yields in the Southern Regions of Russia
with Artificial Intelligence Tools 76

Varjas I.Yu., Klimonov D.V.

Solving an Uncertainty Model
Using Leading Data Synthesis 86

DIGITAL SOLUTIONS AND ARTIFICIAL INTELLIGENCE TECHNOLOGIES

Scientific and practical journal

Vol. 1, No. 4, 2025

Editor-in-Chief

Vadim G. Feklin

Head of Scientific Journals

Editorial Department

Valery I. Golovatenko

Managing Editor

Evelina Yu. Shishkova

Translator

Elizaveta S. Melnikova

Proofreader

Svetlana F. Mikhaylova

Design, make up

Elena A. Smirnova

Publisher & Editorial
address:

53, Leningradsky Avenue,
Moscow, 125167

tel.: +7 (499) 553-10-71
(internal 10-83)

E-mail: vgolovatenko@fa.ru

Site: digitari.ru

Signed off to printing:
25.12.2025

Format 60 x 84 1/8.

Size 10 printer sheets.

Printed by ST Ltd, Voronezh
Order № 2508803

Publication date 30.01.2026

© 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, Российской Федерации

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, Российской Федерации

ЧЛЕНЫ РЕДАКЦИОННОЙ КОЛЛЕГИИ

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

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, Российской Федерации

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

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

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

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

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

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

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

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, Российской Федерации

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, Российской Федерации

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

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

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

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

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

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

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

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

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

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

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

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

Рукописи принимаются vfeclin@fa.ru

Требования к оформлению авторских материалов:

<https://disk.yandex.ru/i/4TYJzMLvb1gQ-Q>

Редакция в обязательном порядке осуществляет экспертизу оценку (рецензирование), научное, литературное и техническое редактирование всех материалов, публикуемых в журнале.

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

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

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

NEIZVESTNYJ 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

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

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



Современные методы обработки документов для расчета биржевых индикаторов

Э.Ф. Болтачев, А.И. Тюляков

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

В данной статье рассматриваются современные методы экстраполяции предобученных трансформеров, направленные на повышение их способности обрабатывать длинные, а также короткие текстовые последовательности на русском языке в финансовой сфере. Особое внимание уделяется задаче классификации текстов, отражающих ожидания брокерских аналитиков относительно движения рынка (ожидание роста, падения либо неопределенности изменения). Для решения данной задачи исследуется применение облегченных языковых моделей ruBERT-tiny1 и ruBERT-tiny2, адаптированных для эффективной работы с большим объемом входных данных при сохранении качества предсказаний. В работе анализируются различные подходы к расширению контекстного окна моделей, включая методы экстраполяции, а также рассматривается влияние стратегий токенизации, векторизации и эмбеддингов на итоговые результаты классификации. Дополнительно обсуждаются особенности применения трансформеров в условиях повышенной волатильности рынка и изменяющихся новостных потоков, что позволяет глубже оценить устойчивость предлагаемых решений. Кроме того, предлагается и обсуждается формула расчета опережающего индикатора для биржевых рынков, демонстрирующая практическую значимость использования трансформерных моделей в анализе финансовых текстов и формировании аналитических метрик. **Представленные результаты** подчеркивают перспективность применения компактных трансформеров в задачах предиктивной финансовой аналитики. Пул брокеров образует выборку мнений в виде текста с определенным смыслом, последовательность слов позволяет оценивать возможные ожидания на финансовом рынке совершенно нелинейным методом. Решение задачи обработки длинных последовательностей токенов актуально, конкретного универсального метода решения данной проблемы нет. Одним из вариантов решения задачи обработки естественного языка NLP на практике является ряд предобученных языковых моделей. Применение предобученных языковых моделей позволяет решать различные задачи классификации, исследуя тексты различных контекстов. В рамках исследования применяется метод экстраполяции предобученных трансформеров для изучения точности классификации и времени обучения, в зависимости от количества токенов в контекстном окне модели. Полученные данные могут быть использованы для дальнейших исследований и построения математической модели расчета опережающих индикаторов на рынке.

Ключевые слова: токенизация; токены; языковые модели; экстраполяция; последовательность; векторизация; эмбеддинги

Для цитирования: Болтачев Э.Ф., Тюляков А.И. Современные методы обработки документов для расчета биржевых индикаторов. Цифровые решения и технологии искусственного интеллекта. 2025;1(4):6-15. DOI: 10.26794/3033-7097-2025-1-4-6-15

ORIGINAL PAPER

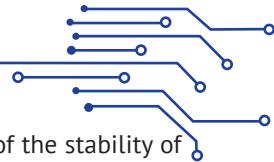
Modern Methods of Document Processing for Calculating Stock Market Indicators

E.F. Boltachev, A.I. Tyulyakov

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

ABSTRACT

This article discusses modern methods of extrapolating pre-trained transformers aimed at improving their ability to process long and short text sequences in Russian in the financial sector. Particular attention is paid to the task of classifying texts that reflect broker analysts' expectations regarding market movements (expectations of growth, decline, or uncertainty of change). To solve this problem, the application of lightweight language models ruBERT-tiny1 and ruBERT-tiny2 is investigated, which are adapted to work effectively with large amounts of input data while maintaining prediction quality. The paper analyzes various approaches to expanding the contextual window of models, including extrapolation methods, and considers the impact of tokenization, vectorization, and embedding strategies on the final classification results. Additionally, the paper discusses the peculiarities of using transformers in conditions of



increased market volatility and changing news flows, which allows for a more in-depth assessment of the stability of the proposed solutions. Furthermore, a formula for calculating a leading indicator for stock markets is proposed and discussed, demonstrating the practical significance of using transformer models in the analysis of financial texts and the formation of analytical metrics. **The presented results** highlight the promising application of compact transformers in predictive financial analytics tasks.

Keywords: tokenization; tokens; language models; extrapolation; sequence; vectorization; embeddings

For citation: Boltachev E.F., Tyulyakov A.I. Modern methods of document processing for calculating stock market indicators. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(4):6-15. DOI: 10.26794/3033-7097-2025-1-4-6-15

ВВЕДЕНИЕ

В последние годы технологии обработки естественного языка (Natural Language Processing, NLP) все более прочно интегрируются в процессы анализа и обработки данных в режиме реального времени. Данная технология применяется в различных сферах, где требуется анализ и классификация текста, а также регрессия на основе текстовых данных. Спектр применения достаточно широкий, начиная от образовательной сферы и заканчивая финансовой [1–4].

Особенно предметом интереса выступает финансовая сфера применения ML в целом и NLP-методологии в отдельности. Однако в данной статье не стоит вопрос решения задачи регрессии на примере расчета возможной стоимости акции. Вместо этого есть возможность использовать индикаторы, которые будут выполнять задачу описания возможных ожиданий, связанных с изменениями стоимости акций.

Основной гипотезой выступает доверие брокерскому сообществу, которое в режиме реального времени пишет, анализирует и выкладывает свои оценки в открытом доступе. Данный пул брокеров образует выборку мнений. При этом каждый текст несет в себе определенный смысл, последовательность слов позволяет оценивать возможные ожидания на рынке совершенно нелинейным методом.

Решение задачи обработки длинных последовательностей токенов актуально, конкретного универсального метода решения данной проблемы нет. Одним из вариантов решения задачи NLP на практике является ряд предобученных языковых моделей. Предобученные трансформеры имеют возможность долговременного анализа ряда токенов, подающихся на вход модели. Применение предобученных языковых моделей позволяет решать различные задачи классификации, исследуя тексты различных контекстов. Языковые модели позволяют решать ряд сложных задач при использовании определенного количества ресурсов, зависящих от задачи.

Однако возникают ограничения, препятствующие реализации ряда задач, в которых число токенов имеет большую размерность, чем позволяет

обрабатывать модель. Также бывает обратная ситуация, когда мощная модель принимает порядка 2048 входных последовательностей токенов, а в самих текстах число токенов меньше. Классификация данных оценок позволит сделать агрегацию значений по временным рядам. Полученные данные могут быть использованы для дальнейших исследований и построения математической модели расчета опережающих индикаторов на рынке.

Целью настоящей работы является анализ современных методологий токенизации и классификации русскоязычных текстов финансовых новостей, подготовленных биржевыми аналитиками, с использованием моделей ruBERT-tiny-1 и ruBERT-tiny-2. В рамках исследования применяется метод экстраполяции предобученных трансформеров для изучения точности классификации и времени обучения в зависимости от количества токенов в контекстном окне модели.

МЕТОДОЛОГИЯ ТОКЕНИЗАЦИИ ТЕКСТОВЫХ ДОКУМЕНТОВ

При решении задачи NLP общим алгоритмом действий является первоначальная обработка данных, а именно заключение текстовых данных в токены с последующей векторизацией для подачи в модель. Данный этап не имеет универсального решения, и зачастую проводятся эмпирические эксперименты, которые изучают эффективность тех или иных методов. Сам процесс сильно влияет на производительность обучения, как на точность метрик, так и на количество требуемых ресурсов для обучения.

Токенизация текста — первоначальная задача при реализации NLP. Она является фундаментальным этапом работы. В общем случае токенизация представляет собой процедуру разбиения текстовых данных на подмножества, или токены. От специфики задачи методы токенизации варьируются [2]. В качестве типичного примера токенизации можно привести разбиение текста на слова, под слова, символы. Данный метод является простейшим по реализации и во многих случаях с помощью него можно добиться высокой предиктивной способности модели. Однако избыточное количество сформиро-



ванных токенов приводит к повышенным вычислительным затратам и во многих случаях оказывается нерациональным с точки зрения эффективности обработки данных. К базовым методам токенизации также относится разбиение текстовых данных на n -граммы. Такой подход нередко рассматривается как эффективное средство сохранения семантического содержания последовательности слов.

После проведения ряда процессов по обработке текстов выбранными методами токенизации возникает проблема использования получившихся токенов в языковых моделях. Данную проблему решают методы векторизации токенов. Для решения задач обработки естественного языка (NLP) применяются современные методы токенизации, среди которых наиболее распространены явления BPE (Byte-Pair Encoding), WordPiece и Unigram Tokenization.

Алгоритм BPE представляет собой последовательное обучение на символах корпуса текста [5]. Изначально токеном является символ, затем производится подсчет частот биграмм, наиболее часто встречающаяся биграмма становится новым токеном. Таким образом, в процессе итеративного обучения модели словарный запас расширяется, тогда как количество токенов, необходимых для представления текста, уменьшается. Главный плюс такого подхода состоит в возможности работать с неизвестными словами. Данный алгоритм позволяет обрабатывать неизвестные слова разбиением на токены (символы) и повторением процедуры. Алгоритм BPE обеспечивает адаптивность и эффективность работы. Он предоставляет возможность обрабатывать редкие слова, поддерживая подсловные единицы (суффиксы, префиксы и т.д.).

Алгоритм WordPiece является основой метода BPE, имеющий аналогичный механизм действий [6]. Unigram отличается от приведенных выше алгоритмов токенизации [7] — он считает каждый токен независимым от токенов до него. Это самая простая языковая модель, в том смысле, что вероятность токена X , учитывая предыдущий контекст, является просто вероятностью токена X . На каждом этапе обучения алгоритм Unigram вычисляет потери по корпусу с учетом текущей лексики. Затем для каждого символа в словаре алгоритм вычисляет, насколько увеличится общая потеря, если символ будет удален, и ищет символы, которые увеличат ее меньше всего.

В конкретных задачах Unigram в сравнении с BPE может оказаться лучше, однако его наибольшими минусами является проблема с пунктуацией и потеря семантического контекста. В целом данный алгоритм встречается редко.

Существуют основные подходы к токенизации, предусматривающие использование плотных векторных представлений, которые позволяют сохранять семантическую информацию о словах [8]. Использование эмбеддингов решает ряд задач, преобразуя категориальные признаки — текст в числовой формат для использования при обучении модели. Основным преимуществом эмбеддингов является возможность обучения модели пониманию смыслового содержания текста за счет захвата семантических отношений между токенами. При этом производительность модели увеличивается за счет снижения размерности. Однако часто возникает проблема несоответствия количества токенов, которые необходимо обработать, с максимальным числом токенов, которые подаются в языковую модель. Это связано со сложностью вычислений, поскольку стандартные архитектуры трансформеров имеют главную уязвимость — квадратичную сложность вычислений. Отсюда идея применения предобученных трансформеров в задачах с ограниченными ресурсами становится непрактичной.

Существует ряд известных методов по борьбе с данной проблемой. Примерами более универсальных методов являются чанкинг (chunking), иерархический подход с разными уровнями абстракции. Чанкинг (chunking) в NLP — это задача разделения последовательности слов (обычно предложения) на фрагменты (chunks), которые представляют собой синтаксически связанные группы слов, например именные группы (noun phrases, NP), глагольные группы (verb phrases, VP) и предложные группы (prepositional phrases, PP). Это промежуточный этап между токенизацией (разбиением текста на отдельные слова) и синтаксическим анализом (полным построением дерева разбора). Чанкинг обычно используется для извлечения информации, анализа настроений и других задач NLP.

Правильный чанкинг (rule-based chunking). Этот подход использует заранее определенные правила, основанные на грамматических знаниях и лексических признаках слов (часть речи, суффиксы и т.д.). Правила могут быть представлены в виде набора продукции (productions) в формализме контекстно-свободных грамматик (CFG).

Пример CFG правил для чанкинга:

- NP — Det N (именная группа состоит из определятеля и существительного);
- NP — Adj N (именная группа состоит из прилагательного и существительного);
- NP — N (именная группа состоит из одного существительного);
- VP — V NP (глагольная группа состоит из глагола и именной группы);



PP — P NP (предложная группа состоит из предлога и именной группы),

где NP — именная группа; VP — глагольная группа; PP — предложная группа; Det — определитель (например, «the», «a»); Adj — прилагательное; N — существительное; V — глагол; P — предлог.

Иерархический подход к обработке токенов в NLP предполагает построение представлений на разных уровнях абстракции, начиная от отдельных токенов и заканчивая сложными семантическими единицами. Каждый уровень использует информацию с предыдущих уровней для создания более богатого и контекстуально-зависимого представления. Рассмотрим несколько уровней.

1. Уровень токенов (Word Embeddings).

На данном уровне каждый токен (слово) представляется вектором, как правило, сформированным с использованием моделей word2vec, GloVe или FastText.

2. Уровень n-грамм (N-gram embeddings).

Этот уровень объединяет последовательности из n токенов. Простейший подход — усреднение векторов токенов. Более сложные подходы могут использовать рекуррентные нейронные сети (RNN) или сверточные нейронные сети (CNN) для получения более контекстно-зависимых представлений n-грамм.

3. Уровень предложений (Sentence Embeddings).

Предложение представляется как последовательность токенов или n-грамм. Для получения векторного представления предложения можно использовать усреднение векторов токенов или n-грамм. Рекуррентные нейронные сети (RNN, LSTM, GRU) формируют представление предложения путем последовательной обработки токенов, при этом конечное скрытое состояние используется в качестве его векторного отображения. В архитектурах на основе трансформеров взаимосвязь между всеми токенами учитывается посредством механизма самовнимания, а итоговое представление предложения часто задается вектором специального токена [CLS].

4. Семантический уровень (Semantic Role Labeling, Relation Extraction).

Информация данного уровня ориентирована на извлечение семантических отношений между словами и предложениями. В частности, она включает идентификацию ролей участников ситуации — таких как субъект, объект и предикат (Semantic Role Labeling), а также выявление отношений между сущностями в тексте (Relation Extraction). Это часто включает использование графов знаний или обучение моделей классификации. Математическое описание на данном этапе определяется

используемым методом, однако в типичном случае включает меры подобия или вероятностные модели. Этот иерархический подход позволяет эффективно использовать информацию на разных уровнях абстракции для решения различных задач NLP, таких как классификация текста, машинный перевод, извлечение информации и понимание естественного языка. Выбор конкретных методов на каждом уровне зависит от задачи и доступных ресурсов.

С другой стороны, решением данной задачи является методология экстраполяции предобученных трансформеров для обработки длинных последовательностей текстов [7]. Данный подход позволит наиболее корреляционным образом сократить количество токенов, не потеряв основные семантические связи. Реализация методологии экстраполяции осуществлена с использованием метода lsg converter [7].

ОПИСАНИЕ ДАТАСЕТА

Датасет обучения включает в себя 30 780 записей биржевых аналитиков об ожидании изменения индекса Мосбиржи, brent, золота. Однако в каждой статье аналитика встречается множество смежных областей биржи, дополняющих семантическое поле модели.

Таргетом является один из трех классов. В рассматриваемой задаче количество классов составляет три. Два из них отражают прогнозируемое направление изменения показателя: рост и снижение, что позволяет модели различать позитивные и негативные ожидания участников рынка. Третий класс обозначает неопределенность, учитывая случаи, когда прогноз не позволяет однозначно отнести событие к росту или снижению. Включение данного класса обеспечивает более точное моделирование реальных рыночных условий и позволяет анализировать ситуацию с учетом степени прогнозной неопределенности. Данные классы сигнализируют модели анализ текста для определения будущих изменений, а не текущих. Это позволяет агрегировать предсказанные таргеты во временных рядах с расчетом определенных лагов в прогнозировании во времени на этапе применения математической модели расчета опережающих индикаторов на бирже.

Записи датасета, собранные парсером из открытых источников, таких как investing.com, а также finam.ru, представлены в табл. 1. Разметка классов датасета проводилась вручную.

В датасете имеется дизбалансировка классов (см. табл. 1), класс понижения заключает в себе на 15–20% меньше количества записей от других



Таблица 1 / Table 1

Балансировка классов / Class Balancing

Класс / Class	Количество записей / Number of Data Points
0 (повышение)	10787
1 (неопределенность)	11263
2 (понижение)	8730

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

классов. Также проблемой является большое количество токенов, поскольку записи с парсеров не являются детерминированными и включают в себя весь текст аналитика на определенную тему, а также на смежные сферы биржи.

Необходимо сформировать корпус текстов аналитических статей, опубликованных в открытых источниках, таких как Finam и Investing. Для каждой статьи предполагается последующее присвоение классовой метки, отражающей ожидаемое направление динамики рынка: рост, понижение или отсутствие существенных изменений.

В итоговом датасете, на котором будет проводиться обучение и анализ предиктивной способности модели, каждый текстовый документ имеет в среднем 265 слов, медианно 240 слов, количество токенов в среднем составляет 345.

УСЛОВИЯ ПРОВЕДЕНИЯ ЭКСПЕРИМЕНТА

Текст должен быть очищен от лишних символов, HTML-тегов и прочих артефактов. Можно использовать стандартные методы предобработки текста: токенизация, лемматизация, удаление стоп-слов. Однако для BERT-ru лемматизация необязательна, поскольку модель уже учитывает морфологические особенности слов.

Данные нужно разделить на три части: тренировочный набор (например, 70–80%); валидационный набор (10–15%) и тестовый набор (10–15%). Валидационный набор используется для настройки гиперпараметров модели и предотвращения переобучения.

Используем BERT-ru модель, например ‘ruBERT-tiny2’, ‘bert-base-russian-case-sensitive’ или ‘sberbank-ai/ruBert-base’. Выбор зависит от доступных ресурсов (памяти и вычислительной мощности) и ожидаемого качества. Обучение и анализ полученных метрик будет осуществлен путем использования моделей ‘ruBERT-tiny2’, а также ‘ruBERT-tiny1’. Необходимо подобрать оптимальные значения гиперпараметров, такие как размер батча, скорость обучения, количество эпох обучения. Это

делается с помощью экспериментального поиска на валидационном наборе.

В данном случае это будет модель классификации текста на основе BERT. Выходной слой состоит из трех нейронов (по числу классов: рост; понижение; неизменность), с функцией активации softmax для получения вероятностей принадлежности к каждому классу. Процесс обучения заключается в подаче тренировочного набора данных в модель BERT и корректировке весов модели с целью минимизации функции потерь (например, кросс-энтропии). В процессе обучения необходимо отслеживать показатели на валидационном наборе, чтобы избежать переобучения. Метрики: accuracy, precision, recall, F1-score. В качестве основной метрики качества модели выступает F1-score.

ПРОВЕДЕНИЕ ЭКСПЕРИМЕНТОВ
С ИСПОЛЬЗОВАНИЕМ МЕТОДАЭКСТРАПОЛЯЦИИ ПРЕДОБУЧЕННОЙ
МОДЕЛИ RUBERT-TINY2, RUBERT-TINY1

В ходе исследования метода экстраполяции предобученных трансформеров был проведен ряд экспериментов на модели ruBERT-tiny2 с различным количеством входной последовательности токенов модели. Эксперименты проводились с использованием облачных вычислений в среде разработки Google Colab, с использованием графического процессора T4. Сама модель ruBERT-tiny2 [10] имеет входную последовательность 2048 токенов, а также мощный семантический словарь в 83828 токенов.

Выбор данной модели обусловлен релевантным соотношением качества и затрачиваемых ресурсов для обучения. На примере описываемой задачи NLP в статье рассмотрены случаи с использованием 128, 512, 1024 входных токенов вместо 2048.

При использовании оригинального количества входных токенов были достигнуты следующие метрики (табл. 2).

Модель с 2048 входными токенами (см. табл. 2) достигла метрики 0,675, в рамках данного датасета это удовлетворительный результат, однако само обучение модели проводилось 55 мин 42 с. В контексте решения рассматриваемой задачи при ограниченном объеме ресурсов данная модель демонстрирует низкую эффективность. В связи с этим следующим этапом эксперимента стало сокращение числа входных токенов с использованием библиотеки LSG Converter до 1024 токенов. В результате полученная метрика составила 0,669, что ниже точности модели с 2048 входными токенами. Тем не менее время обучения модели уменьшилось с 55 мин 42 с до 28 мин 58 с.

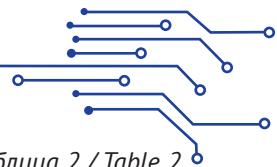


Таблица 2 / Table 2

Результаты экспериментов на модели ruBERT-tiny2 с различным количеством входной последовательности токенов / Experimental Results for the RuBERT-tiny2 Model with Different Quantity of Input Length of the Sequence

Выборки / Splits*	Метрики / Metrics				
	Eval loss	Eval accuracy	Eval F1	Eval Precision	Eval Recall
Модель с 2048 входными токенами					
Train	0,559016	0,765646	0,758698	0,765958	0,756780
Val	0,714382	0,674119	0,667998	0,675303	0,666474
Test	0,704781	0,679361	0,675110	0,681473	0,674465
Модель с 1024 входными токенами					
Train	0,563955	0,764347	0,761114	0,764576	0,763576
Val	0,709973	0,673729	0,670612	0,673790	0,672578
Test	0,704570	0,672082	0,669810	0,674300	0,671864
Модель с 512 входными токенами					
Train	0,577549	0,763447	0,757664	0,762728	0,756614
Val	0,710775	0,671650	0,666917	0,671849	0,665786
Test	0,695135	0,681180	0,676933	0,683720	0,676570
Модель с 128 входными токенами					
Train	0,599955	0,739195	0,735903	0,736832	0,736963
Val	0,756285	0,640322	0,638574	0,639775	0,639736
Test	0,730899	0,661684	0,660281	0,660808	0,660871

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

Примечание / Note: * Выборки: обучающая, валидационная и тестовая / Splits: train, validation and test.

Метод экстраполяции предобученных трансформеров позволяет варьировать значение количества входных токенов модели в зависимости от задачи.

Следующим экспериментом является сокращение до 512 входных токенов. Метрика качества равна 0,676 (см. табл. 2), время обучения модели 15 мин 19 с. В данном случае удалось добиться незначительно большей метрики, чем на модели с 2048 входными токенами, а также ускорить процесс обучения в 3,6 раза.

Также рассматривалась модель с 128 входными токенами. Для данной конфигурации значение метрики F1-score составило 0,66, что ниже по сравнению с предыдущими вариантами, тогда как время обучения модели сократилось до 2 мин 59 с (см. табл. 2).

Согласно полученным данным после проведения эксперимента экстраполяции предобученных трансформеров (рис. 1, 2, табл. 3) немодифициро-

ванная модель трансформеров ruBERT-tiny2 (2048 входных токенов) при решении данной задачи не является оптимальной. В данном случае наиболее удачным решением стала модель с 512 токенами входной последовательности. Она сочетает качество модели, а также удовлетворительное количество затраченных ресурсов при обучении.

В табл. 4 представлены результаты экспериментов, проведенных на моделях ruBERT-tiny1 и ruBERT-tiny2. Модель ruBERT-tiny1 отличается меньшей сложностью, обладая сокращенным словарем и входной последовательностью длиной 512 токенов. В ходе эксперимента получены данные, свидетельствующие о возможности увеличения контекстного окна с использованием метода LSG Converter, что сопровождается ростом значения метрики F1-score за счет экстраполяции. Это указывает на то, что даже без применения метода чанкинга модели LLM с расширенным контекстным окном способны эффективно захватывать

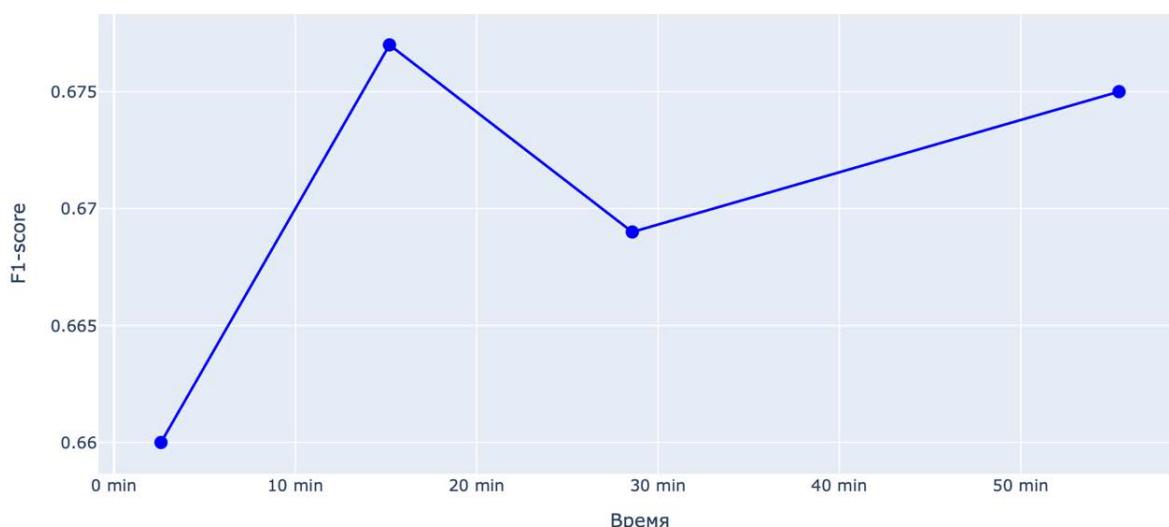
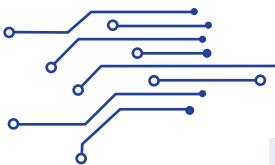


Рис. 1 / Fig. 1. Зависимость метрик качества от времени обучения / The Relationship between Quality Metrics and Training Time

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

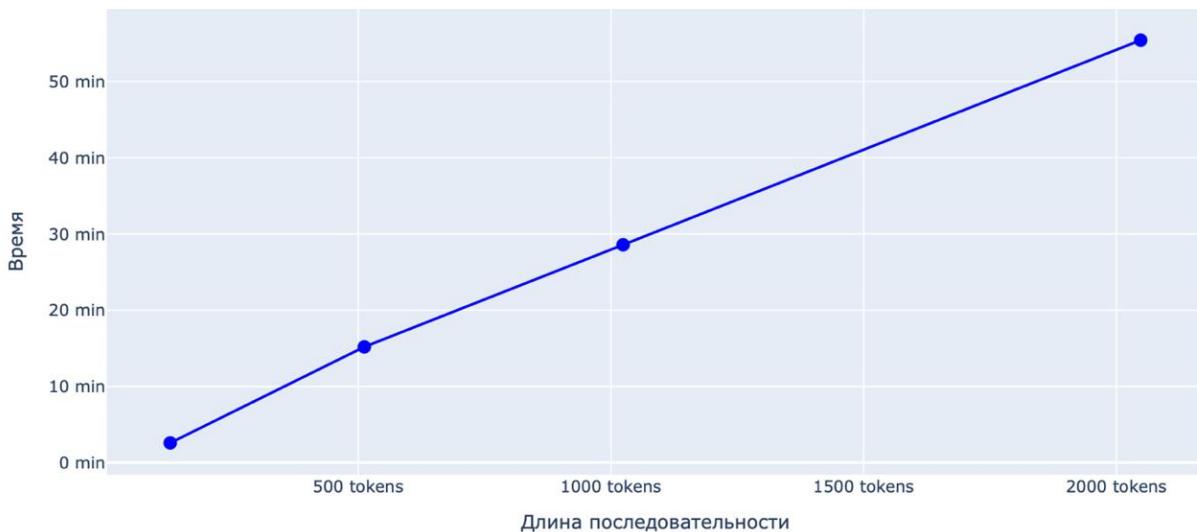


Рис. 2 / Fig. 2. Зависимость времени обучения от входной длины последовательности / The Relationship between the Training Time and the Input Length of the Sequence

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

Таблица 3 / Table 3

Зависимость метрики качества F1-score и времени обучения модели RuBert-tiny2 от входной длины последовательности токенов / The Relationship between F1-score and the Training Time, and the Input Length of the Sequence for the RuBERT-tiny2 Model

Входная длина последовательности / Input length of the sequence	F1-score	Время обучения, мин / Training time, min
128	0,660	2,59
512	0,677	15,19
1024	0,669	28,58
2048	0,675	55,42

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

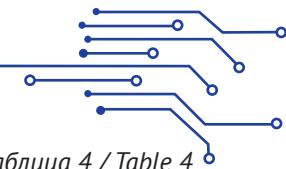


Таблица 4 / Table 4

Данные экспериментов для моделей ruBERT-tiny1 и ruBERT-tiny2 при различной входной длине последовательности / Experimental Results for the RuBERT-tiny1 and RuBERT-tiny2 Models at Different Input Length of Sequence

Входная длина последовательности / Input length of the sequence	RuBERT-tiny1 (512)		RuBERT-tiny2 (2048)	
	F1-score	Время обучения, мин / Training time, min	F1-score	Время обучения, мин / Training time, min
128			0,6602	2,59
512	0,6486	13,48	0,6769	15,19
1024	0,6608	26,48	0,6698	28,58
2048	0,6681	50,53	0,6751	55,42

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

семантический контекст текстов для задач классификации в NLP, извлекая релевантную информацию при меньших затратах ресурсов.

ФОРМУЛА РАСЧЕТА ИНДИКАТОРА ОЖИДАНИЙ НА БИРЖЕ

Для количественного анализа ожиданий участников финансового рынка в рамках настоящего исследования будет использован индикатор *MEI* (Market Expectations Indicator). Данный индикатор позволяет оценить прогнозные ожидания экономических агентов относительно ключевых макроэкономических переменных и, таким образом, выступает инструментом для исследования рыночной динамики и выявления потенциальных дисбалансов. Расчет *MEI* осуществляется на основе формулы, предложенной OECD, которая учитывает структурированные данные о прогнозах участников рынка и позволяет агрегировать индивидуальные оценки в единую интегральную величину. Применение данной методики обеспечивает сопоставимость результатов между различными временными периодами и экономическими условиями, а также повышает надежность интерпретации динамики ожиданий рынка в контексте экономического анализа.

Формально расчет *MEI* представлен следующей зависимостью:

$$MEI^{di} = 50 + (G + B * K_g) * \beta - (C + B * K_d) * \beta,$$

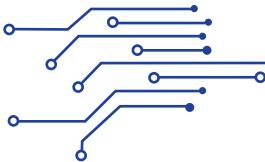
где MEI^{di} – диффузный индикатор мнений с распределенной инерцией; G – доля опрошенных респондентов, ответивших о повышении экономиче-

ского параметра в будущем периоде; B – доля опрошенных респондентов, ответивших о неопределенности экономического параметра в будущем периоде; C – доля опрошенных респондентов, ответивших о понижении экономического параметра в будущем периоде; K_g – коэффициент веса факторов повышения экономического параметра в текущем периоде; K_d – коэффициент веса факторов понижения экономического параметра в текущем периоде; коэффициент $\beta = 0,5$.

Данная формула является примером того, как можно использовать получившиеся метки классификации для расчета индикатора будущих изменений на бирже.

ВЫВОДЫ

В настоящей работе представлены методы решения задач обработки естественного языка (NLP) в финансовой сфере с использованием предобученных трансформеров. Основная гипотеза исследования заключалась в том, что для эффективного обучения модели не всегда требуется использование длинного входного контекста. Применение мощных трансформеров совместно с уменьшенным контекстным окном, реализованным путем экстраполяции, позволяет оптимизировать объем необходимых вычислительных ресурсов при сохранении качества модели. В качестве практической рекомендации предлагается адаптировать количество входных токенов модели к медианному или среднему количеству токенов в текстах, на которых проводится обучение, с возможностью последующей корректировки без необходимости полного переобучения модели.

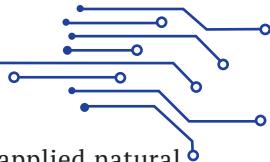


СПИСОК ИСТОЧНИКОВ

1. Липатова С.В., Бочкарева Ю.Е. Использование NLP для разработки электронных учебно-методических материалов. *Аллея науки*. 2023;4(79):926-931. URL: <https://www.elibrary.ru/item.asp?id=54082726>
2. Панкратова М.Д., Сковпель Т.Н. Модели NLP с использованием нейронных сетей в анализе тональности новостей. *Аналитические технологии в социальной сфере: Теория и Практика*. 2023;(15):97-107. URL: <https://www.elibrary.ru/ctabku>
3. Рыскин К.Э., Вечканова Ю.С., Федосин С.А. Обработка товарных номенклатур из отчетов дистрибуторов с использованием NLP. Материалы XXV научно-практической конференции молодых ученых, аспирантов и студентов Национального исследовательского Мордовского государственного университета им. Н.П. Огарёва; 2022:271-276; URL: <https://elibrary.ru/item.asp?id=54051425>
4. Дубровский В.В., Карманова Е.В. Проект разработки интеллектуального онлайн-сервиса для реферирования текстовых документов с использованием NLP. Управление проектами. Сборник статей по материалам II Всероссийской научной конференции, Магнитогорск, 01–03 декабря 2023 г. Магнитогорск: Магнитогорский государственный технический университет им. Г.И. Носова; 2024;37–45. URL: <https://elibrary.ru/item.asp?id=60647866>
5. Sennrich R., Haddow B., Birch A. Neural Machine Translation of Rare Words with Subword Units. *Proceedings of ACL*. 2016;1715–1725. DOI: 10.48550/arXiv.1508.07909
6. Song X., Salcianu A., Song Y., Dopson D., Zhou D. Fast WordPiece Tokenization. *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. 2021:2089–2103. URL: <https://aclanthology.org/2021.emnlp-main.160/>
7. Vemula S.R., Sharma D.M., Krishnamurthy P. Rethinking Tokenization for Rich Morphology: The Dominance of Unigram over BPE and Morphological Alignment. *arXiv preprint*; 2025:arXiv:2508.08424. DOI: 10.48550/arXiv.2508.08424
8. Condevaux C., Harispe S. LSG Attention: Extrapolation of Pretrained Transformers to Long Sequences. In: Kashima, H., Ide, T., Peng, WC., eds. *Advances in Knowledge Discovery and Data Mining*. PAKDD 2023. Lecture Notes in Computer Science. 2023;13935:443–454. DOI: 10.1007/978-3-031-33374-3_35
9. Марков А.К., Семеночкин Д.О., Кравец А.Г., Яновский Т.А. Сравнительный анализ применяемых технологий обработки естественного языка для улучшения качества классификации цифровых документов. *International Jurnal of Information Technologies*. 2024;12(3):66–77. URL: <https://www.elibrary.ru/tubosi>

REFERENCES

1. Lipatova S.V., Bochkareva Yu.E. Using NLP for the development of electronic teaching and methodological materials. *Alley of Science*. 2023;4(79):926-931. URL: <https://www.elibrary.ru/item.asp?id=54082726>
2. Pankratova M.D., Skovpel T.N. NLP models using neural networks in news sentiment analysis. *Analytical technologies in the social sphere: Theory and Practice*. 2023;(15):97-107. URL: <https://www.elibrary.ru/ctabku>
3. Ryskin K.E., Vechkanova Y.S., Fedosin S.A. Processing of product items from distributors' reports using NLP. Proceedings of the XXV Scientific and Practical Conference of Young Scientists, Postgraduate Students and Students of the National Research Mordovian State University. Saransk: National Research Mordovian State University named after N.P. Ogarev, 2022;271-276; URL: <https://elibrary.ru/item.asp?id=54051425>
4. Dubrovsky V.V., Karmanova E.V. Project for the Development of an Intelligent Online Service for Abstracting Text Documents Using NLP. Project Management. Proceedings of the II All-Russian Scientific Conference, Magnitogorsk, December 01–03, 2023. Magnitogorsk: Magnitogorsk State Technical University named after G.I. Nosov; 2024:37-45. URL: <https://elibrary.ru/item.asp?id=60647866>
5. Sennrich R., Haddow B., Birch A. Neural Machine Translation of Rare Words with Subword Units. *Proceedings of ACL*. 2016;1715-1725. DOI: 10.48550/arXiv.1508.07909
6. Song X., Salcianu A., Song Y., Dopson D., Zhou D. Fast WordPiece Tokenization. *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. 2021;2089-2103. URL: <https://aclanthology.org/2021.emnlp-main.160/>
7. Vemula S.R., Sharma D.M., Krishnamurthy P. Rethinking Tokenization for Rich Morphology: The Dominance of Unigram over BPE and Morphological Alignment. 2025; URL: <https://arxiv.org/abs/2508.08424>
8. Condevaux C., Harispe S. LSG Attention: Extrapolation of Pretrained Transformers to Long Sequences. In: Kashima, H., Ide, T., Peng, WC., eds. *Advances in Knowledge Discovery and Data Mining*. PAKDD 2023. Lecture Notes in Computer Science. 2023;13935:443–454. DOI: 10.1007/978-3-031-33374-3_35



9. Markov A.K., Semenochkin D.O., Kravets A.G., Yanovsky T.A. Comparative analysis of applied natural language processing technologies to improve the quality of digital document classification. *International Journal of Information Technologies*. 2024;12(3):66-77. URL: <https://www.elibrary.ru/tubosi>

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Эльдар Филаридович Болтачев – кандидат технических наук, доцент кафедры искусственного интеллекта факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Eldar F. Boltachev – Cand. Sci. (Tech.), Assoc. Prof. of Artificial Intelligence Department of the Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0002-6375-0365>

Автор для корреспонденции / Corresponding author:

efboltachev@fa.ru

Александр Игоревич Тюляков – студент программы магистратуры кафедры искусственного интеллекта факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Alexander I. Tyulyakov – Master Programme Student of Artificial Intelligence Department of the Faculty of Information Technologies and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0009-0008-0534-0342>

244447@edu.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 в редакцию 13.10.2025; принята к публикации 24.11.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 13.10.2025; accepted for publication on 24.11.2025.

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



DOI: 10.26794/3033-7097-2025-1-4-16-25
УДК 004.89(045)

Анализ тональности пользовательского текста методами машинного обучения

Е.А. Горбунова^a, Р.А. Кочкаров^b, Э.А. Окунева^c

^a ООО «Лаборатория систем автоматизации процессов», Санкт-Петербург, Российской Федерации;
^{b, c} Финансовый университет при Правительстве Российской Федерации, Москва, Российской Федерации

АННОТАЦИЯ

В статье рассматривается применение методов машинного обучения для анализа тональности текстов, опубликованных пользователями социальной сети ВКонтакте. Это дает возможность в режиме реального времени отслеживать и анализировать настроения миллионов пользователей, что способствует оперативному принятию решений и прогнозированию социальных процессов. В рамках исследования был реализован сбор текстовых данных с использованием VK API, включающих посты и комментарии пользователей. Проведена предобработка текстов: очистка, лемматизация, удаление стоп-слов и векторизация методом TF-IDF. Для классификации эмоциональной окраски были протестированы модели: логистическая регрессия, случайный лес, наивный байесовский классификатор, а также нейросетевые архитектуры LSTM и Transformers (RuBERT). Наивный байесовский классификатор показал наилучшие результаты по метрике полноты и сбалансированности по другим метрикам. Согласно результатам анализа, большинство текстов пользователей имеют нейтральную или положительную тональность, и лишь незначительная часть – негативную. Представлены визуализации и статистика распределения тональности. Работа демонстрирует эффективность применения классических методов машинного обучения для обработки и анализа текстов в русскоязычных социальных сетях.

Ключевые слова: анализ тональности; машинное обучение; социальные сети; Вконтакте; обработка естественного языка; TF-IDF; байесовский классификатор; сентимент-анализ; посты; комментарии

Для цитирования: Горбунова Е.А., Кочкаров Р.А., Окунева Э.А. Анализ тональности пользовательского текста методами машинного обучения. Цифровые решения и технологии искусственного интеллекта. 2025;1(4):16-25. DOI: 10.26794/3033-7097-2025-1-4-16-25

ORIGINAL PAPER

Sentiment Analysis of User Texts with Machine Learning Methods

Е.А. Горбунова^a, Р.А. Кочкаров^b, Э.А. Окунева^c

^a Laboratory of Process Automation Systems Limited Liability Co., Saint Petersburg, Russian Federation;
^{b, c} Financial University under the Government of the Russian Federation, Moscow, Russian Federation

ABSTRACT

This paper explores the application of machine learning methods for sentiment analysis of user-generated texts in the Russian social network VKontakte. The sentiments of millions of users could be monitored and analyzed in real time, that facilitates prompt decision making and forecasting of social processes. Textual data, including posts and comments, were collected via the VK API. The preprocessing pipeline involved text cleaning, lemmatization, stop-word removal, and TF-IDF vectorization. Several classification models were tested, including logistic regression, random forest, and naïve Bayes, as well as deep learning models such as LSTM and Transformers (RuBERT). The naïve Bayes classifier demonstrated the best performance in terms of recall and overall metric balance. Sentiment analysis results revealed that the majority of user texts were neutral or positive, with only a small portion being negative. The paper includes visualizations and statistical summaries of sentiment distribution. The study confirms the effectiveness of classical machine learning methods for processing and analyzing textual data in Russian social networks.

Keywords: sentiment analysis; machine learning; social networks; VKontakte; natural language processing; TF-IDF; naive Bayes; user-generated content; posts; comments

For citation: Gorbunova E.A., Kochkarov R.A., Okuneva E.A. Sentiment analysis of user texts with machine learning methods. Digital Solutions and Artificial Intelligence Technologies. 2025;1(4):16-25. DOI: 10.26794/3033-7097-2025-1-4-16-25

© Горбунова Е.А., Кочкаров Р.А., Окунева Э.А., 2025



ВВЕДЕНИЕ

Современные социальные сети стали важной площадкой для выражения мнений, обмена информацией и формирования общественного мнения. Миллионы пользователей ежедневно публикуют тексты, комментарии, делятся эмоциями и впечатлениями, создавая огромные объемы неструктурированных данных. Анализ тональности (sentiment analysis) — автоматическое определение эмоциональной окраски текстов — приобретает ключевое значение для понимания общественных настроений, мониторинга репутации брендов, оценки эффективности маркетинговых кампаний и выявления трендов.

Особенно актуальным анализ тональности становится в контексте социальных сетей, таких как ВКонтакте, которые являются крупнейшими платформами в русскоязычном сегменте интернета. Здесь исследователи и компании получают возможность в режиме реального времени отслеживать и анализировать настроения миллионов пользователей, что способствует оперативному принятию решений и прогнозированию социальных процессов [1].

Однако специфика русского языка, включая его морфологическую сложность и богатство форм слов, предъявляет особые требования к методам обработки и анализа текстов. Современные технологии машинного обучения и глубокого обучения, такие как наивный байесовский классификатор, рекуррентные нейронные сети (LSTM) и трансформеры (RuBERT), активно применяются для повышения точности определения тональности текстов на русском языке [2].

Таким образом, актуальность анализа тональности в социальных сетях обусловлена не только ростом объема пользовательских данных, но и необходимостью создания эффективных инструментов для их автоматической обработки и интерпретации, что имеет важное значение для бизнеса, науки и социальной сферы [3].

Цель работы — выявление эмоциональной окраски текстов пользователей сети ВКонтакте с помощью методов анализа тональности.

МЕТОДЫ ИССЛЕДОВАНИЯ

Исследование проводилось в несколько этапов:

- сбор данных из сети ВКонтакте (посты и комментарии) через API;
- предобработка текста (очистка, токенизация, лемматизация);
- векторизация методом TF-IDF;
- обучение и сравнение моделей (логистическая регрессия, случайный лес, наивный байес, LSTM, RuBERT);
- оценка моделей по метрикам (Accuracy, Precision, Recall, F1-score);

- анализ распределения тональности (позитивные, нейтральные, негативные тексты).

В рамках данного исследования для анализа тональности текстов из социальной сети ВКонтакте применялись современные методы обработки естественного языка (NLP) и машинного обучения [4]. Основная цель состояла в автоматическом определении эмоциональной окраски текстов — положительной, нейтральной или отрицательной.

Первым этапом являлась предобработка данных, которая включала очистку текста от пунктуации, специальных символов и URL, токенизацию, удаление русскоязычных стоп-слов и лемматизацию [5]. Эти шаги способствуют снижению шума в данных и повышают качество последующего анализа. Для лемматизации использовались специализированные инструменты, учитывающие особенности русского языка.

Для преобразования текстовых данных в числовую формат была применена модель TF-IDF (Term Frequency — Inverse Document Frequency), которая позволяет учитывать не только частоту слов, но и их значимость относительно всего корпуса текстов [6]. Этот подход улучшает различимость ключевых терминов в контексте тональности.

Далее были обучены и сравнены несколько моделей машинного обучения: логистическая регрессия, случайный лес и наивный байесовский классификатор [7]. Кроме классических моделей, были протестированы модели глубокого обучения — рекуррентная нейронная сеть LSTM и трансформерная модель RuBERT, специально адаптированная для русского языка. Выбор таких моделей обусловлен их способностью выявлять сложные зависимости в текстах и учитывать контекст при анализе тональности.

Оценка эффективности моделей проводилась по стандартным метрикам качества классификации — точности (Accuracy), полноте (Recall), точности классификации (Precision) и F1-мере. Анализ показал, что наивный байесовский классификатор обеспечил лучший баланс между полнотой и точностью, что важно для задач сентимент-анализа.

Таким образом, использование комплексного подхода — от тщательной предобработки до применения различных моделей машинного и глубокого обучения — позволило получить надежные результаты по определению эмоциональной окраски текстов пользователей ВКонтакте.

ОПИСАНИЕ СОЦИАЛЬНОЙ СЕТИ ВКОНТАКТЕ КАК ОБЪЕКТА ИССЛЕДОВАНИЯ

Социальная сеть ВКонтакте (VK) является одной из крупнейших и наиболее популярных плат-



Таблица 1 / Table 1

**Данные о пользователях социальной сети
Вконтакте / VKontakte Social Network User Data**

№	Обозначение / Designation	Данные / Data
1	id	Идентификационный номер пользователя
2	bdate	Дата рождения
3	city_title	Город
4	country_title	Страна
5	first_name	Имя
6	last_name	Фамилия

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

Таблица 2 / Table 2

**Данные о постах пользователей социальной
сети Вконтакте / User Post Data from VK Social
Network**

№	Обозначение / Designation	Данные / Data
1	user_id	Идентификационный номер пользователя
2	post_id	Идентификационный номер публикации пользователя
3	post_text	Текст поста
4	date_formatted	Дата публикации в формате ДД.ММ.ГГГГ
5	time	Время публикации в формате ЧЧ: ММ: СС
6	likes	Количество лайков
7	comments	Количество комментариев
8	views	Количество просмотров
9	photo_url	URL фотографии в посте, если есть
10	video_link	Ссылка на видео в посте, если есть
11	audio_link	Ссылка на аудио в посте, если есть

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

¹ Что такое ВК. Вконтакте. URL: <https://vk.com/ru/company/about/>
² API|VK для разработчиков. Вконтакте. URL: <https://dev.vk.com/ru/reference>

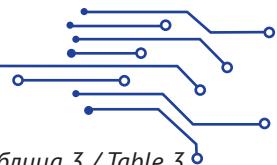


Таблица 3 / Table 3

В работе применялись ключевые методы API, такие как:

- `users.search` — метод для поиска пользователей по заданным параметрам (например, возраст, пол, город), что позволило сформировать репрезентативную выборку пользователей для анализа;
- `users.get` — предоставлял подробную информацию о конкретных пользователях, включая их демографические данные и профильные атрибуты;
- `wall.get` — метод, используемый для извлечения постов с пользовательских стен, включая тексты публикаций, время создания, количество лайков, комментариев и просмотров;
- `likes.getList` и `comments.getList` — методы для получения информации о пользователях, которые взаимодействовали с постами (ставили лайки, оставляли комментарии)³.

В результате использования методов VK API для сбора данных была сформирована серия датафреймов, представляющих собой структурированные таблицы с информацией о пользователях, их публикациях, а также взаимодействиях с этими публикациями (лайки и комментарии). Каждый из датафреймов отражает определенный аспект активности в социальной сети ВКонтакте и является основой для последующего анализа.

Данные датафрейма `df_all_users` — информация о пользователях в социальной сети Вконтакте содержит 14 711 уникальных пользователей социальной сети (табл. 1).

Для сбора данных о постах пользователей были применены методы: `users.get` и `wall.get`.

Данные датафрейма `df_all_posts` — информация о пяти последних постах пользователей в социальной сети ВКонтакте, содержат 55 589 уникальных идентификаторов постов пользователей (табл. 2).

Данные датафрейма `df_likes` — информация о людях, поставивших лайк на посты, содержат 1 191 231 записей (табл. 3).

Данные датафрейма `df_comments` содержат информацию о людях, которые оставили комментарий под постом другого пользователя, и насчитывают 23 467 записей (табл. 4).

В процессе сбора данных строго учитывался ряд ограничений, установленных платформой ВКонтакте для обеспечения стабильной работы сервиса и защиты данных пользователей.

- Ограничение по количеству запросов: API ВКонтакте накладывает лимит на количество запросов в единицу времени (например, не более трех запросов в секунду для одного токена). Для

³ Использование VK API. Вконтакте. URL: <https://dev.vk.com/ru/api/overview>

Данные о взаимных лайках пользователей социальной сети / Mutual Likes Data between Social Network Users

№	Обозначение / Designation	Данные / Data
1	<code>owner_id</code>	Идентификационный номер пользователя, кому принадлежит пост
2	<code>post_id</code>	Идентификационный номер поста
3	<code>liker_id</code>	Идентификационный номер пользователя, который поставил лайк посту

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

Таблица 4 / Table 4

Данные о комментариях пользователей социальной сети / Social Media User Comments Data

№	Обозначение / Designation	Данные / Data
1	<code>owner_id</code>	Идентификационный номер пользователя, кому принадлежит пост
2	<code>post_id</code>	Идентификационный номер поста
3	<code>commenter_id</code>	Идентификационный номер пользователя, который оставил комментарий под постом
4	<code>comment_text</code>	Текст комментария
5	<code>likes_count</code>	Количество лайков данного комментария

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

предотвращения превышения лимита запросы были организованы с использованием очередей и задержек, что обеспечило плавное и корректное взаимодействие с сервером.

- Пагинация данных: для получения больших объемов данных применялась постраничная загрузка с использованием параметров `offset` и `count`. Это позволяло эффективно обходить ограничение на максимальное количество записей, возвращаемых за один запрос.

- Этические и правовые нормы: соблюдались правила обработки персональных данных, уста-



новленные законодательством и политикой сети ВКонтакте. Данные пользователей обрабатывались анонимно и использовались исключительно в агрегированном виде с целью проведения научного анализа.

- Обновление и мониторинг API: в процессе работы регулярно отслеживались изменения в документации VK API и корректировались методы и параметры запросов для поддержания актуальности и стабильности сбора данных.

Таким образом, благодаря четкой организации процесса и соблюдению технических и этических норм был обеспечен качественный и безопасный сбор данных, необходимых для дальнейшего анализа тональности и поведения пользователей социальной сети.

ПРЕДОБРАБОТКА ДАННЫХ

Перед применением моделей машинного обучения для анализа тональности текстов необходимо провести качественную предобработку данных. Целью данного этапа является очистка текста от лишней информации, приведение его к унифицированному виду и подготовка к векторному представлению, пригодному для машинной обработки.

Первым шагом в предобработке текстов является их очистка от шумов, не несущих семантической нагрузки. Для этого были выполнены следующие действия: удаление знаков пунктуации, специальных символов, гиперссылок с использованием регулярных выражений, чисел и эмодзи, если они не несли значимой информации [9].

Все тексты были приведены к нижнему регистру, что позволяет унифицировать слова при последующей обработке и избежать дублирования лексем, различающихся только по регистру.

Следующим этапом является токенизация — процесс разбиения текста на отдельные слова (токены). Для этого использовались стандартные инструменты библиотеки nltk [10].

После токенизации из текстов были удалены стоп-слова — наиболее частотные слова в русском языке, не несущие значимой смысловой нагрузки. Удаление стоп-слов позволило сократить количество признаков в векторном пространстве и повысить значимость оставшихся слов.

Для нормализации форм слов применялась лемматизация — приведение слов к их начальной (словарной) форме. Основным инструментом для этого выступила библиотека pymorphy2, ориентированная на морфологический анализ русского языка [11].

Лемматизация позволяет сократить размер словаря признаков и устраниТЬ избыточность, вызванную грамматическими формами одного и того же слова.

Результатом предобработки стало создание новой колонки cleaned_text в каждом из датафреймов.

Для приведения текстов к числовому формату, пригодному для обучения моделей, применялась модель TF-IDF [12]. Этот метод позволяет оценить важность каждого слова в документе относительно корпуса текстов.

В результате применения TF-IDF каждый текст был представлен в виде разреженного вектора, где каждый элемент соответствует весу конкретного термина. Эти векторы стали входными признаками для дальнейшего обучения моделей классификации.

АНАЛИЗ ТОНАЛЬНОСТИ ТЕКСТА

Анализ тональности текстов — важный этап обработки пользовательского контента, позволяющий определить эмоциональную окраску сообщений. В настоящей работе были рассмотрены и обучены как классические алгоритмы машинного обучения, так и современные методы глубокого обучения [13, 14]. В данном разделе описывается архитектура использованных моделей, методы оценки и выбор финального решения на основе сравнительного анализа.

Для определения наиболее эффективной модели было проведено сравнение пяти алгоритмов: логистической регрессии, случайного леса, наивного байесовского классификатора, LSTM, Transformers (табл. 5) [15, 16].

Сравнение производилось на основе таких метрик, как точность (Accuracy), точность классификации (Precision), полнота (Recall), F1-мера (F1-Score) и площадь под кривой ошибок (ROC-AUC). В результате анализа наилучшие характеристики продемонстрировал наивный байесовский классификатор.

Он был выбран в качестве основной модели по следующим причинам:

- лучшая полнота (Recall) — важна в задачах, где необходимо минимизировать пропуск определенного класса (например, негативных комментариев);
- сбалансированное поведение по точности и F1-мере, сопоставимое с другими моделями;
- простота и высокая скорость обучения;
- стабильность при обработке разреженных данных [17].

Выбранная модель была применена к очищенным текстам постов из датасета df_all_posts. В результате каждому посту была присвоена оценка его эмоциональной окраски, которая добавлялась в датасет как новая колонка «Индекс эмоциональной оценки». Для дальнейшего анализа был рассчитан средний индекс эмоциональной оценки для каждого пользователя на основе его последних

Сравнительная характеристика моделей машинного обучения / Comparative Characteristics of Machine Learning Models

Модель / Model	Accuracy	Precision	Recall	F1-Score	ROC-AUC
Логистическая регрессия	0,73	0,73	0,73	0,73	0,81
Случайный лес	0,72	0,72	0,74	0,73	0,80
Наивный байесовский классификатор	0,73	0,74	0,72	0,73	0,81
LSTM	0,69	0,69	0,71	0,70	0,77
Transformers	0,71	0,72	0,70	0,71	0,78

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

пяти постов, результаты расчетов были добавлены в датасет `df_all_users`. Это позволило выявить общие тренды в эмоциональном состоянии пользователей и оценить динамику изменения настроения в социальной сети (рис. 1).

Визуализация эмоциональной окраски текста постов пользователей помогла проанализировать данные, по которым можно сделать вывод, что 11885 постов содержат нейтральную окраску текста, 7249 — позитивную и 655 — негативную.

Обученная модель наивного Байеса была применена к векторизованным комментариям для их классификации на положительные, негативные

и нейтральные. Результаты классификации были визуализированы для наглядности распределения эмоциональных окрасок [18]. Это позволило оценить общее настроение и реакции пользователей (рис. 2).

В результате анализа визуализации эмоциональной окраски текста комментариев можно сделать вывод, что 54% комментариев имеют нейтральную окраску текста, 42% комментариев — положительную и 4% — негативную.

Применение наивного байесовского классификатора к комментариям демонстрирует его эффективность в определении эмоциональных

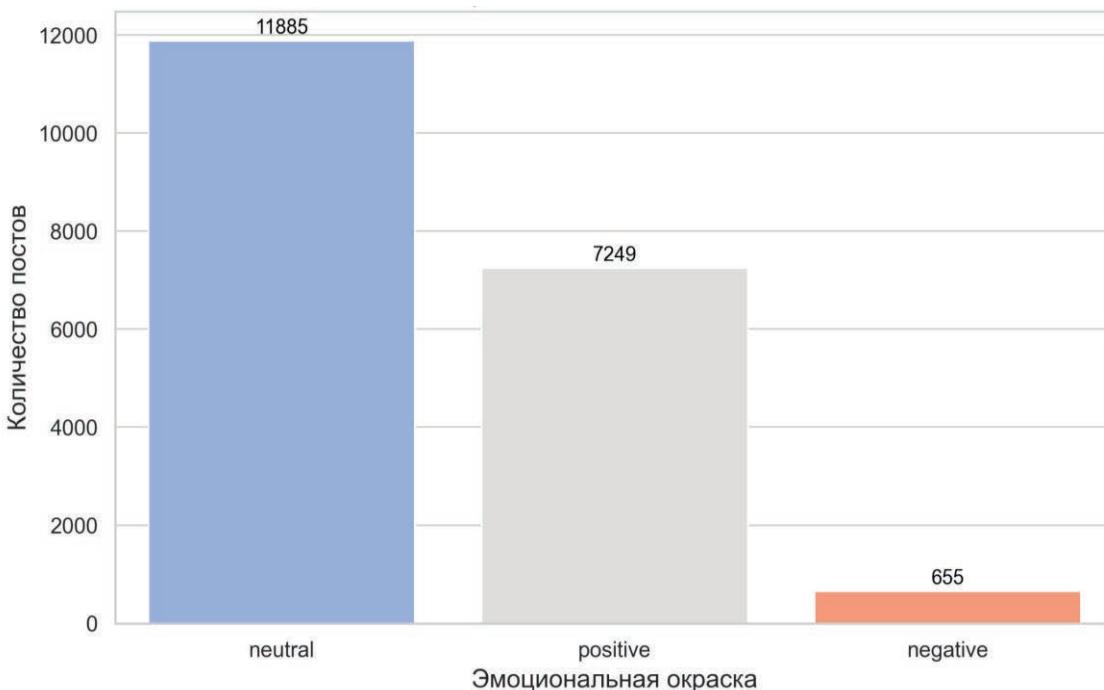


Рис. 1 / Fig. 1. Эмоциональная окраска текста пользователей / Sentiment of User-generated Text

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

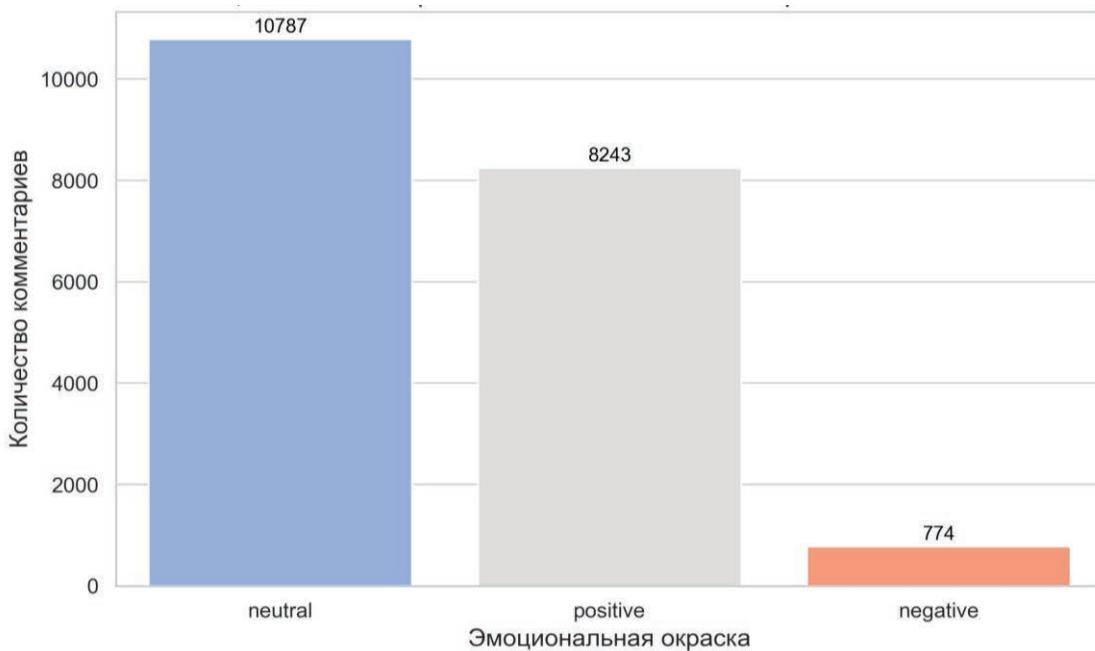


Рис. 2 / Fig. 2. Эмоциональная окраска текста всех комментариев пользователей / Sentiment Analysis of All User Comments

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

тенденций. Полученные данные могут служить основой для стратегий взаимодействия и контент-планирования.

ВЫВОДЫ

Результаты автоматизированного анализа тональности текстов позволяют не только оценить общее настроение пользователей социальной сети, но и выявить потенциальные поведенческие и психологические особенности их взаимодействия в цифровом пространстве.

На основе классификации тональности, проведенной с использованием модели наивного байесовского классификатора, были получены следующие распределения по эмоциональной окраске текстов.

Посты пользователей (всего 21 989):

- нейтральные – 11 885 постов (54%);
- положительные – 7249 постов (42%);
- негативные – 655 постов (4%).

Комментарии пользователей (всего 17 904):

- нейтральные – 10 787 комментариев (60%);
- положительные – 8243 комментария (37%);
- негативные – 774 комментария (3%).

Такая картина позволяет говорить о доминировании нейтрального и позитивного контента в обоих типах пользовательских сообщений.

• Пользователи социальной сети ВКонтакте в большей степени склонны к нейтральной или положительной тональности как в публикациях, так и в комментариях.

• Доля негативных сообщений во всех типах контента не превышает 4%, что может свидетельствовать о контролируемом 62-м уровне эмоциональной агрессии и высокой социальной нормативности в выражении мыслей.

• Посты оказываются чуть более позитивными, чем комментарии, где наблюдается большая доля нейтрального высказывания – это может указывать на более сдержаный стиль коммуникации при обсуждении чужих сообщений.

Таким образом, проведенный анализ не только выявил структуру эмоциональной окраски контента, но и открыл перспективы для дальнейших междисциплинарных исследований – в области социологии, психологии и цифровой лингвистики.

СПИСОК ИСТОЧНИКОВ

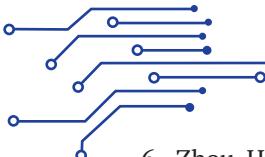
1. Rodríguez-Ibáñez M., Casanez-Ventura F., Castejón-Mateos F., Cuenca-Jiménez P.-M. A review on sentiment analysis from social media platforms. *Expert Systems with Applications*. 2023;223:119862. DOI: 10.1016/j.eswa.2023.119862
2. Wankhade M., Rao A.C.S., & Kulkarni C. A survey on sentiment analysis methods, applications, and challenges. *Artificial Intelligence Review*. 2022;55(7):5731–5780. DOI: 10.1007/s10462-022-10144-1



3. Cortis K., Davis B. Over a Decade of Social Opinion Mining: A Systematic Review. *Artificial Intelligence Review*. 2021;54(1):4873–4965. DOI: 10.1007/s10462-021-10030-2
4. Mutanov G., Karyukin A., Mamykova G. Multi-Class Sentiment Analysis of Social Media Data with Machine Learning Algorithms. *Computers, Materials & Continua*. 2021;69(1):913–930. DOI: 10.32604/cmc.2021.017827
5. Salman I.K., Feizi Derakhshi M.R., Pashazadeh S., Asadpour M. A Comprehensive Review of Visual-Textual Sentiment Analysis from Social Media Networks. *ArXiv preprint*. 2022;arXiv:2207.02160. DOI: 10.48550/arXiv.2207.02160
6. Zhou, H. Research of text classification based on TF-IDF and CNN-LSTM. *Journal of Physics: Conference Series*. 2022;2171:012021. DOI: 10.1088/1742-6596/2171/1/012021
7. Oliveira D.F., Nogueira A., Brito M. Performance comparison of machine learning algorithms in classifying information technologies incident tickets. *AI*. 2022;3(3):601–622. DOI: 10.3390/ai3030035
8. Smetanin S. The applications of sentiment analysis for Russian language texts: current challenges and future perspectives. *IEEE Access*. 2020;8:110693–110719. DOI: 10.1109/ACCESS.2020.3002215
9. Braga M., Milanese G.C., Pasi G. Investigating large language models' linguistic abilities for text preprocessing. *arXiv preprint*. 2025;arXiv:2510.11482. DOI: 10.48550/arXiv.2510.11482
10. Feng J.H., Mohaghegh M. Hybrid model of data augmentation methods for text classification task. Proceedings of the 13th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management (IC 3K 2021). 2021:194–197. DOI: 10.5220/0010688500003064
11. Гадасин Д.В., Пак Е.В., Коровушкина В.М., Мелькова Е.К. Предобработка текстовой информации на основе термов естественного языка. *REDs: Телекоммуникационные устройства и системы*. 2022;1:4-12. URL: <https://www.elibrary.ru/pdgavp>
12. Liu Y., Ott M., Goyal N., Du J., Joshi M., Chen D., Levy O., Lewis M., Zettlemoyer L., Stoyanov V. RoBERTa: A robustly optimized BERT pretraining approach. *arXiv preprint*. 2019;arXiv:1907.11692. DOI: 10.48550/arXiv.1907.11692
13. Щекотин Е.В., Гойко В.Л., Басина П.А., Бакулин В.В. Использование машинного обучения для изучения качества жизни населения: методологические аспекты. *Цифровая социология*. 2022;5(1):87–97. DOI: 10.26425/2658-347X-2022-5-1-87-97
14. Гальченко Ю.В., Нестеров С.А. Классификация текстов по тональности ML-методами. Системный анализ в проектировании и управлении. Сборник научных трудов XXVI Международной научно-практической конференции. В 3 ч. Ч. 3. Санкт-Петербург, 13–14 октября 2023 г. СПб.: ПОЛИТЕХ-ПРЕСС. 2023;26(3):369–378. DOI: 10.18720/SPBPU/2/id23-501
15. Мезенев К.А., Бадрызлова Ю.Г. Анализ эмоциональной тональности русскоязычных текстов с цифровыми методами. НИУ ВШЭ, магистерская диссертация. Москва, 2025. URL: <https://www.hse.ru/edu/vkr/1055012487>
16. Катермина Т.С., Тагиров К.М., Тагиров Т.М. Элементы ИИ в анализе текстов: LSTM-приложение к Вконтакте. *Computational Nanotechnology*. 2022;9(2):35–44. DOI: 10.33693/2313-223X-2022-9-2-35-44.
17. Челышев Э.А., Оцоков Ш.А., Раскатова М.В., Щёголев П. Сравнение методов классификации русскоязычных новостных текстов с использованием алгоритмов машинного обучения. *Вестник кибернетики*. 2022;1(45):63–71. DOI: 10.34822/1999-7604-2022-1-63-71.
18. Ивахин Д.Е., Андиева Е.Ю. Автоматический анализ текста для выявления профессиональных навыков: гибридный подход на основе TF-IDF и нейросетевых эмбеддингов. *Вестник науки*. 2025;4(85-2):685–692. URL: <https://www.вестник-науки.рф/article/22263>

REFERENCES

1. Rodríguez-Ibáñez M., Casanez-Ventura F., Castejón-Mateos F., Cuenca-Jiménez P.-M. A review on sentiment analysis from social media platforms. *Expert Systems with Applications*. 2023;223:119862. DOI: 10.1016/j.eswa.2023.119862
2. Wankhade M., Rao A.C.S., & Kulkarni, C. A survey on sentiment analysis methods, applications, and challenges. *Artificial Intelligence Review*. 2022;55(7):5731–5780. DOI: 10.1007/s10462-022-10144-1
3. Cortis K., Davis B. Over a Decade of Social Opinion Mining: A Systematic Review. *Artificial Intelligence Review*. 2021;54(6):4873–4965. DOI: 10.1007/s10462-021-10030-2
4. Mutanov G., Karyukin A., Mamykova G. Multi-Class Sentiment Analysis of Social Media Data with Machine Learning Algorithms. *Computers, Materials & Continua*. 2021;69(1):913–930. DOI: 10.32604/cmc.2021.017827
5. Salman I.K., Feizi Derakhshi M.R., Pashazadeh S., Asadpour M. A Comprehensive Review of Visual-Textual Sentiment Analysis from Social Media Networks. *ArXiv preprint*. 2022;arXiv:2207.02160. DOI: 10.48550/arXiv.2207.02160



6. Zhou, H. Research of text classification based on TF-IDF and CNN-LSTM. *Journal of Physics: Conference Series*. 2022;2171:012021. DOI: 10.1088/1742-6596/2171/1/012021
7. Oliveira D.F., Nogueira A., Brito M. Performance comparison of machine learning algorithms in classifying information technologies incident tickets. *AI*. 2022;3(3):601–622. DOI: 10.3390/ai3030035
8. Smetanin, S. The applications of sentiment analysis for Russian language texts: current challenges and future perspectives. *IEEE Access*. 2020;8:110693–110719. DOI: 10.1109/ACCESS.2020.3002215
9. Braga M., Milanesi G.C., Pasi G. Investigating large language models' linguistic abilities for text preprocessing. *arXiv preprint*. 2025;arXiv:2510.11482. DOI: 10.48550/arXiv.2510.11482
10. Feng J.H., Mohaghegh M. Hybrid model of data augmentation methods for text classification task. In Proceedings of the 13th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management (IC 3K 2021). 2021:194–197. DOI: 10.5220/0010688500003064
11. Gadasin D.V., Pak E.V., Korovushkina V.M., Melkova E.K. Natural Language Term-Based Text Information Preprocessing. *REDS: Telecommunication Devices and Systems*. 2022;1:4-12. URL: <https://www.elibrary.ru/pdgavp> (In Russ.).
12. Liu Y., Ott M., Goyal N., Du J., Joshi M., Chen D., Levy O., Lewis M., Zettlemoyer L., Stoyanov V. RoBERTa: A robustly optimized BERT pretraining approach. *arXiv preprint*. 2019; arXiv:1907.11692. DOI: 10.48550/arXiv.1907.11692
13. Shchekotin E.V., Goiko V.L., Basina P.A., Bakulin V.V. Using machine learning to study the population life quality: methodological aspects. *Digital Sociology*. 2022;5(1):87–97. (In Russ.). DOI: 10.26425/2658-347X-2022-5-1-87-97
14. Galchenko Yu.V., Nesterov S.A. Sentiment analysis with machine learning methods. *Systems Analysis in Design and Management*. Proc. Of the XXVI International scientific conference, St. Petersburg, October 13–14, 2023. St. Petersburg: Politekh-Press; 2023;3:369–378. (In Russ.). DOI: 10.18720/SPBPU/2/id23-501
15. Mezenev K.A., Badryzlova Yu.G. Sentiment Analysis of Russian-Language Texts Using Digital Methods. Master's Thesis. National Research University Higher School of Economics (HSE), Moscow. 2025. URL: <https://www.hse.ru/edu/vkr/1055012487> (In Russ.).
16. Katermina T.S., Tagirov K.M., Tagirov T.M. Elements of artificial intelligence in solving problems of text analysis. *Computational Nanotechnology*. 2022;9(2):35–44. (In Russ.). DOI: 10.33693/2313-223X-2022-9-2-35-44
17. Chelyshev E.A., Otsokov Sh.A., Raskatova M.V., Shchegolev P. Comparing classification methods for news texts in russian using machine learning algorithms. *Proceedings of Cybernetics*. 2022;1(45):63–71. (In Russ.). DOI: 10.34822/1999-7604-2022-1-63-71
18. Ivakhin D.E., Andieva E. Yu. Automatic text analysis for identifying professional skills: a hybrid approach based on TF-IDF and neural network embeddings. *Bulletin of Science*. 2025;4(85):685–692. (In Russ.). URL: <https://www.vestnik-nauki.com/article/22263>

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Екатерина Александровна Горбунова – старший разработчик программного обеспечения ООО «Лаборатория систем автоматизации процессов», Санкт-Петербург, Российская Федерация

Ekaterina A. Gorbunova – Senior Software Developer, LLC “Laboratory of Process Automation Systems”, Saint Petersburg, Russian Federation

<https://orcid.org/0009-0009-5748-9031>

kateswep@mail.ru

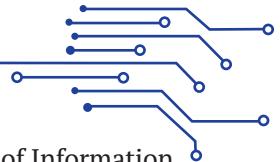
Расул Ахматович Коцкаров – кандидат экономических наук, доцент кафедры искусственного интеллекта факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Rasul A. Kochkarov – Cand. Sci. (Econ.), Assoc. Prof. of Artificial Intelligence Department, 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:

Е.А. Горбунова — разработка общей концепции статьи, разработка архитектуры эксперимента, интерпретация результатов анализа тональности и поведенческих паттернов пользователей, сбор и анализ данных, визуализация результатов.

Р.А. Кочкаров — разработка методологии, общая редакция статьи.

Э.А. Окунева — разделы введение и выводы, список литературы.

Authors' declared contributions:

E.A. Gorbunova — development of the general concept of the article, design of the experimental architecture, interpretation of sentiment analysis results and user behavioral patterns, data collection and analysis, visualization of results.

R.A. Kochkarov — development of methodology, overall editing of the article.

E.A. Okuneva — writing the Introduction and Conclusion sections, compiling the reference list.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

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

Статья поступила в редакцию 13.10.2025; принятa к публикации 24.11.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 13.10.2025; accepted for publication on 24.11.2025.

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



Эволюция и перспективы развития видеоигр приключенческого жанра в Российской Федерации

А.А. Бердюгин, С.Р. Муминова

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

Настоящее исследование посвящено анализу процесса развития видеоигр приключенческого жанра. **Цель исследования** – определение текущих тенденций к созданию текстовых квестов на основе инновационных подходов. **Задачи исследования** включают: анализ современного состояния жанра, обзор применяемых технологий в разработке видеоигр, а также социокультурные эффекты. **Научная значимость работы** обусловлена необходимостью переосмысления потенциала жанра адвентюрных игр в контексте современных условий. Практическая значимость работы подтверждается представлением конкретных примеров разработки инструментария для создания компонентов текстовых квестов с использованием искусственного интеллекта. Так, например, алгоритмы нейросетей способны генерировать не только сюжет, но и аудиовизуальный ряд видеоигры, что сокращает время ее разработки и снижает затраты на производственный процесс. Сравнительный анализ на примере игры «Far Cry» позволяет выявить пути совершенствования подходов к разработке видеоигр. Рассмотрены последствия блокировки зарубежных онлайн-платформ из-за наличия запрещенных материалов, и указаны пути решения для отечественного рынка видеоигр. **Основные выводы** исследования подчеркивают важность государственной поддержки для развития национальной платформы видеоигр, что укрепит систему ценностей и обеспечит защиту национальной культуры.

Ключевые слова: приключенческий жанр; адвентюрная игра; нейросеть; генерация сюжета; Far Cry; платформа видеоигр

Для цитирования: Бердюгин А.А., Муминова С.Р. Эволюция и перспективы развития видеоигр приключенческого жанра в Российской Федерации. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(4):26-34. DOI: 10.26794/3033-7097-2025-1-4-26-34

ORIGINAL PAPER

Evolution and Opportunities of Adventure Videogames in the Russian Federation

A.A. Berdugin, S.R. Muminova

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

ABSTRACT

The paper analyzes evolution and state-of-art of adventure videogames. **The goal** of the study is to reveal the trends in creating text quests based on innovative approaches. **These are the tasks to solve:** to analyze interactive fiction videogames, to make a review of the technologies employed in videogames development, to highlight social and cultural effects. **The scientific value** is the evaluation of the potential of adventure games in present-day conditions. The practical applicability is proved by real examples demonstrating the AI-tools used for creating elements of text quests. For example, neural networks are employed both to generate the plot of the quests and audio and visual content. That shortens development time and reduces the cost of production process. The comparative analysis performed for the game “Far Cry” allows revealing the ways for further improvements in the development process. The authors also consider the situation concerning blocking foreign online-platforms in Russia due to the disallowed content and map out the ways for domestic videogame market. **The outcome of the study** emphasizes the importance of government support for establishing national game-platform to reinforce state values and provide the protection of national culture. **Keywords:** interactive fiction; adventure game; neuro network; plot generation; Far Cry; videogame platform

For citation: Berdugin A.A., Muminova S.R. Evolution and opportunities of adventure videogames in the Russian Federation. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(4):26-34. DOI: 10.26794/3033-7097-2025-1-4-26-34



ВВЕДЕНИЕ

В современном мире, где технологии и медиа играют все более значимую роль, индустрия компьютерных игр приобрела огромный масштаб. Одним из значимых результатов этого процесса стало появление киберспорта, а также науки о компьютерных играх — Game Studies. Эта междисциплинарная наука изучает видеоигры как культурный феномен. Многие отечественные работы посвящены исследованию отдельных аспектов приключенческих игр. В частности, большая часть публикаций посвящена эстетике дизайна графической составляющей [1–3]. Но следует отметить, что успех игры в большей степени определяется сюжетом и игровым процессом — геймплеем (от англ. game play), нежели графическими возможностями. Геймплей включает в себя игровые механики, такие как динамика, управление и развитие персонажа, определяющие интерес игрока к игре. Практика показывает, что успех игры напрямую зависит от ее способности удерживать интерес аудитории, причем качество графики играет второстепенную роль [4].

Одним из самых увлекательных жанров, который несправедливо забыт, является «Interactive Fiction» — текстовые квесты, в которых игрок взаимодействует с текстовым окружением, выбирая действия и решения, которые влияют на ход игры. Этот жанр зародился во второй половине XX в., в эпоху текстовых интерфейсов и первых персональных компьютеров. Он остается актуальным благодаря своему потенциалу для развития креативного мышления и воображения. Сегодня этот жанр требует переосмысления в контексте новейших технологий, доступных для разработчиков [5–8].

В программировании интерфейсы — это не только графический интерфейс пользователя [от англ. Graphical User Interface (GUI)], но и конструкции, которые определяют, как взаимодействуют различные компоненты программы в самой системе компьютера. В адвентюрных (приключенческих) играх концепция интерфейса принимает форму командной строки или CLI (от англ. Command Line Interface). В данной статье рассматриваются игровые интерфейсы без традиционного GUI, где графическим интерфейсом служит обычный текст.

Интерактивную беллетристику и текстовые квесты можно рассматривать как взаимосвязанные категории текстовых игр, акцентирующих внимание на повествовании и взаимодействии с игровым миром, но при этом различающихся по сложности и механике. Поэтому в статье эти понятия считаются эквивалентными.

Цель исследования — определение текущих тенденций к созданию текстовых квестов на основе инновационных подходов. **Задачи исследования** включают: анализ современного состояния жанра,

обзор применяемых технологий в разработке видеоигр, а также социокультурные эффекты.

ГЕЙМИФИКАЦИЯ ЛИТЕРАТУРЫ В АДВЕНТЮРНЫХ ИГРАХ

Адвентюрные игры представляют собой один из наиболее популярных жанров компьютерных игр, привлекающих широкую аудиторию по всему миру. Они напоминают литературные произведения, но отличаются тем, что игрок становится героем истории, формируя локации и события, а также определяя исход рассказа своими действиями, хотя возможные концовки предопределены автором игры. В процессе прохождения игрок сталкивается с различными вызовами: преодоление препятствий, решение логических задач, взаимодействие с игровыми персонажами, поиск необходимых предметов. Эти элементы требуют от игрока применения логики, креативности и внимательности к деталям, что делает игровой процесс увлекательным и захватывающим. Причем к решению любой задачи нужно прийти путем логических рассуждений.

Игра «Colossal Cave Adventure» положила начало текстовым квестам и всему приключенческому жанру в 1970-х гг. Эта игра посвящена Мамонтовой пещере с историей, насчитывающей более 230 лет — от наполеоновских войн до 90-х гг. XX в. Ученый и программист Уильям Краутер создал компьютерную программу с моделью этой пещеры, после чего вместе с другом Доном Вудсом, поклонником творчества Джона Р.Р. Толкина, они наполнили модель волшебными существами и предметами. В те годы не было компьютерной графики, взаимодействие происходило через ввод команд с клавиатуры телетайпа, а ответы компьютер печатал на бумаге. Играющий вводил команды для героя, а компьютер описывал результат. Выглядело это примерно так, как изображено на рис. 1.

Несмотря на кажущуюся простоту, игра оказалась сложной и увлекательной. Компьютерные игры в то время были доступны только программистам, и даже опытные специалисты тратили недели на прохождение игры. Таким образом программа «Colossal Cave Adventure» стала первой текстовой адвентурной игрой в мире [9].

Золотой период текстовых игр пришелся на первую половину 1980-х гг., когда компании Infocom и Level 9 выпустили множество успешных проектов. Марк Бланк и создатели серии текстовых игр «Zork» (компания Infocom) признавали «Colossal Cave Adventure» источником вдохновения. Несмотря на отсутствие графики в этих играх, продукты Infocom издавались и переиздавались вплоть до начала 2000-х гг. Этим занималась компания Activision, которая приобрела Infocom в 1989 г.

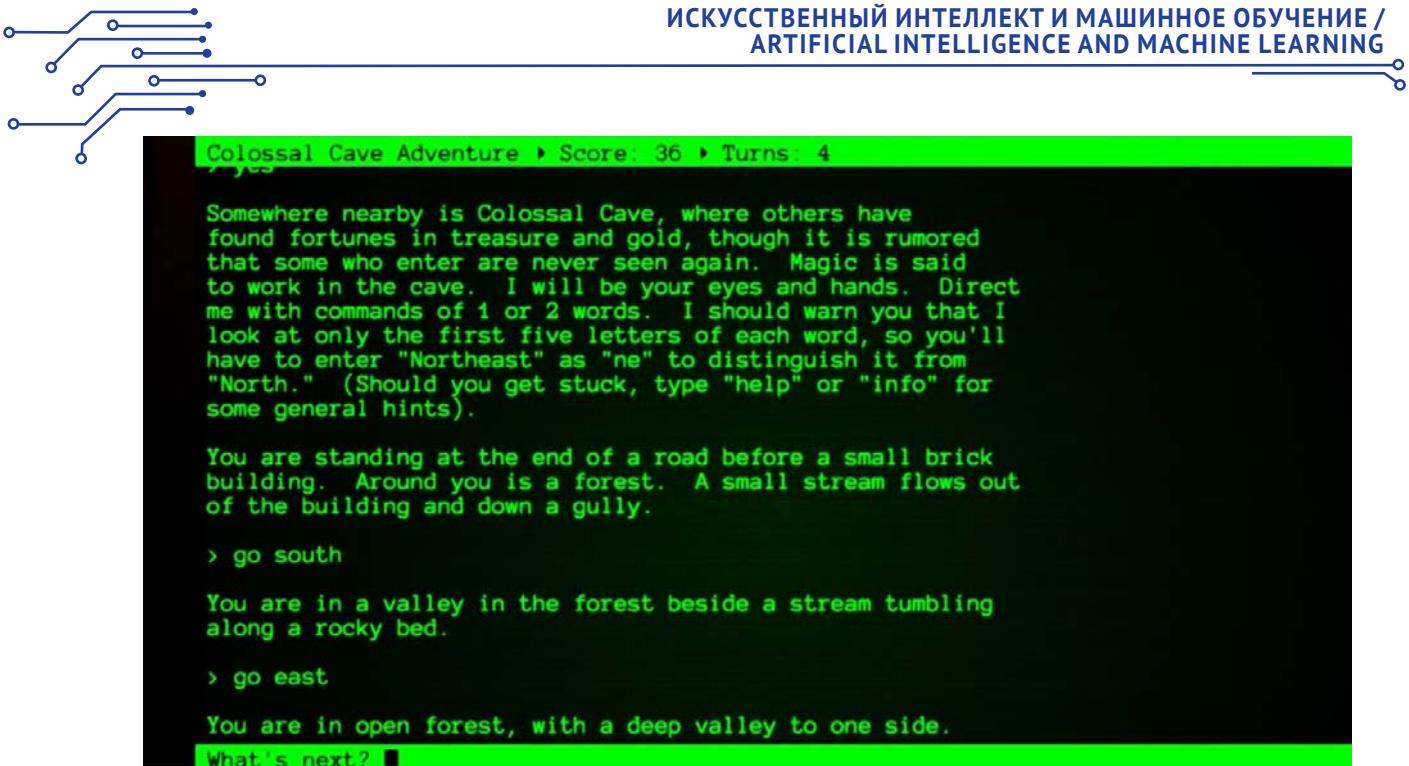


Рис. 1 / Fig. 1. Интерфейс игры «Colossal Cave Adventure» / Interface of the Game “Colossal Cave Adventure”

Источник / Source: игра «Colossal Cave Adventure» в интернете / The game “Colossal Cave Adventure” in Internet.

Следует отметить, что из существующих на сегодняшний день трудов наиболее подробное руководство по созданию интерактивной беллетристики представлено в разделе «Глава 14. Генерация текста» книги [10].

В 1980 г. вышла в свет игра «Mystery House», использовавшая векторную графику без цвета и анимации (текст и белые линии на черном фоне¹), а в 1984 г. компания Sierra Online выпустила первую в своем роде графическую игру в жанре «King's Quest» («Королевское приключение», рис. 2). Эта игра стала первой по-настоящему графической игрой жанра, после чего жанр «Interactive Fiction» постепенно утратил популярность.

В 1990-х гг. поклонники жанра создавали, распространяли на дискетах и совместно проходили такие игры, а также выпускали электронные журналы, посвященные интерактивной литературе. Тем не менее текстовые приключенческие игры имеют место и в настоящее время, но чаще создаются любителями для смартфонов и распространяются через интернет.

«INTERACTIVE FICTION» В СОВРЕМЕННЫХ ВИДЕОИГРАХ

В первой части игры «Космические рейнджеры» российской студии Elemental Games представлено 120 обычных (графических) и 26 текстовых заданий. Та часть геймплея, которая отвечает за сюжетные

повороты, реализована через выбор подходящего варианта ответа. При описании игры всегда акцентируется внимание на наличие элементов текстового квеста и по отзывам игроков, данный аспект является одним из наиболее увлекательных.

С накоплением знаний и опыта в программировании пришло понимание, что создание подобной игры в одиночку нереализуемо — необходима команда разработчиков: программисты, тестировщики, литераторы для создания сюжета, а также проект- и продакт-менеджер (продуктолог) [11] для организации работы и выстраивания процесса создания продукта. Несмотря на простой вид кадра, представленного на рис. 3, разработка второй части игры «Космические рейнджеры 2: Доминаторы» (2004 г.) осуществлялась усилиями около 30 специалистов — 10 сотрудников в офисе и около 20 удаленных специалистов, включая программистов, композиторов, художников, сценаристов и писателей квестов. Тогда команда полностью сосредоточилась на этом проекте, не отвлекаясь на другие разработки.

Интеграция элементов «Interactive Fiction» в современные видеоигры значительно расширяет потенциал текстовых квестов в плане обогащения игрового опыта. С развитием инновационных технологий, таких как большие языковые модели [от англ. Large Language Model (LLM)], системы диалогов в играх могут стать более гибкими и реалистичными, и этот аспект также активно изучается с точки зрения машинного обучения.

¹ Classic Retro Gaming. Mystery House (1980 On-Line Systems) (Apple2) [Видеозапись]. RUTUBE. URL: <https://rutube.ru/video/544673810b103b3974635d781e52e8e6> (дата обращения: 16.05.2025).



Рис. 2 / Fig. 2. Первая графическая адвентюрная игра «King's Quest». Под изображением – строка для ввода пользовательской команды на английском языке / The First Graphical Adventure Game “King's Quest”. The Black Line under the Picture is Used for Entering User Commands in English

Источник / Source: игра «King's Quest» в интернете / The game “King's Quest” in Internet.

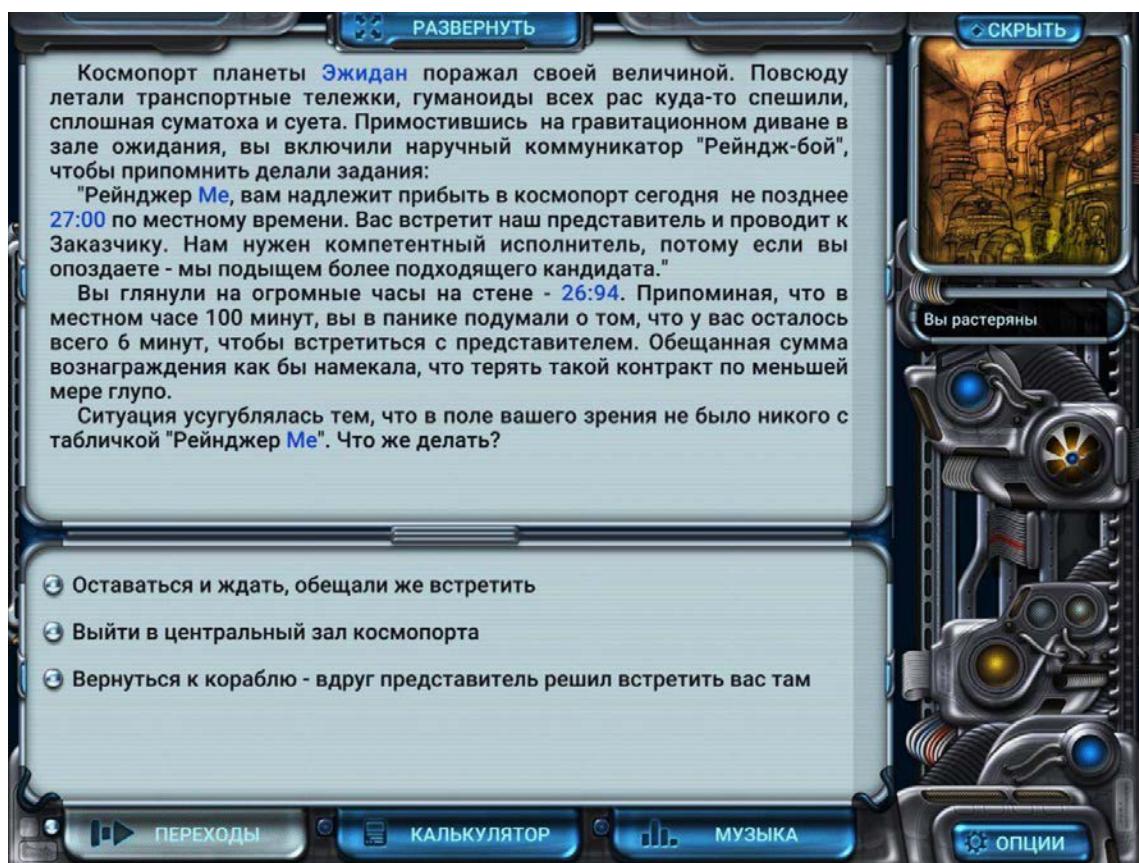


Рис. 3 / Fig. 3. Элементы интерактивной литературы в игре «Космические рейнджеры» / Elements of Interactive Literature in the Game “Space Rangers”

Источник / Source: игра «Космические рейнджеры» в интернете / The game “Space Rangers” in Internet.



ПЕРСПЕКТИВЫ РАЗВИТИЯ

«Interactive Fiction» и ремейки: вдохновение для новых игровых миров

В продолжение предыдущего раздела статьи авторы предлагают дополнить элементами «Interactive Fiction» видеоигру «Far Cry 2», действие которой разворачивается в африканской стране, чтобы разнообразить монотонный сюжет, сохранив и улучшив при этом высокое качество визуальной составляющей. Благодаря этому данная часть станет столь же значимой, как и предыдущая, а насыщенность игрового процесса и рейтинги игры существенно возрастут. Французская компания Ubisoft может выпустить обновленную версию игры «Far Cry 2004 remastered», которая стала бы ценным подарком адептам олдскула² (как в случае с игрой «Duke Nukem 3D» от 1996 г. и «Duke Nukem Forever» от 2011 г. или фильмом «Терминатор: Тёмные судьбы» от 2019 г. с отсылками ко второй части франшизы, вышедшей в 1991 г.), а затем — «Far Cry 2 remake» с элементами логического квеста.

Уточним, что ремастер представляет собой обновленное переиздание игры с измененной структурой и интерфейсом, но с сохранением оригинального сюжета. Ремейк подразумевает глубокую переработку игрового процесса, но при этом сохраняются узнаваемые черты оригинала. Для классификации игры как ремейка требуется использование новой игровой платформы или движка. Оба подхода начинаются с обратной разработки (reverse engineering), в ходе которой разработчики декомпилируют оригинальную игру, анализируя взаимосвязи, логику кода и ключевые метрики геймплея³.

В африканской части игры отсутствуют запоминающийся сюжет и выразительные персонажи (за исключением антагониста — аморального манипулятора), в отличие от игры «Far Cry 2004», после которой главный protagonист стал харизматичным злодеем сиквела (рис. 4). Несмотря на анархичную обстановку в вымышленной стране, представленную в сюжете, логика игрового процесса должна присутствовать и сохраняться, а не сводиться к выполнению бессмысленных однообразных заданий.

Механика в игре «Far Cry 2» отличается высокой степенью реализма и детальной проработкой, что



Рис. 4 / Fig. 4. Джек Карвер и Jackal (Шакал) — это одно лицо. Необычный ход / Jack Carver and Jackal are the Same Person. An Unusual Move

Источник / Source: Официальное заявление Ubisoft от 2021 г. / Ubisoft's official statement from 2021. Бэй А. Ubisoft официально подтвердили, что Шакал — это Джек Карвер. GamerBay. URL: <https://gamerbay.ru/games/Ubisoft-oficialno-podtverdila-cto-shakal-dzhek-karver>.

делает игру хорошей основой для ремейка и значительно расширяет возможности для дальнейших творческих решений. При этом элементы интерактивной повествовательности в «Far Cry 2» могут добавить глубину и уникальность, которые реализованы недостаточно полно.

Включение элементов именно текстового (а не графического) квеста позволит не менять игровой процесс кардинально, а сохранить его почти в прежнем виде и освежить только графическую часть. Такой подход может стать нетривиальным дополнением для многих ремейков игр. При этом квест на фоне гражданской войны, развязанной в игре, может иметь русские корни: например, описания из романа Николая Островского «Как закалялась сталь» и загадки из серии игр «Петя и Василий Иванович»⁴. Использование мотивов русской классики добавят уникальности игровому процессу.

Таким образом, возврат к основам серии (первым двум частям игры «Far Cry») мог бы способствовать восстановлению репутации Ubisoft в индустрии развлечений, которая частично утрачена. Здесь проведем параллель с тем фактом, что ключом к процветанию компаний Tesla, SpaceX и SolarCity Илона Маска стала приверженность их основателя идеи конструирования на основе первых принципов (first principles), что отличается

² От англ. old school gaming, classic gaming, retrogaming — определение, подразумевающее ностальгическое увлечение старыми компьютерными играми.

³ Лычак С. Ремейки и ремастеры: чем они различаются и как создаются. Skillbox. URL: <https://skillbox.ru/media/gamedev/remeyki-i-remastery-chem-oni-razlichayutsya-i-kak-sozdayutsya/> (дата обращения: 21.05.2025).

⁴ Но в случае такой интеграции крайне важно учитывать аспекты национальной идентичности, чтобы не получилось, как с запрещенной в России игрой «Call of Duty: Modern Warfare III» за наличие сцен с насилием в отношении россиян. Здесь будут полезны знания истории Отечества и классической русской литературы.



от проектирования по аналогии (итеративного проектирования).

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ КАК НОВЫЙ ИНСТРУМЕНТ РАЗРАБОТЧИКА ВИДЕОИГР

Как было указано ранее, основными компонентами любой игры являются ее сюжет и игровой процесс. Качество сценариев квестов является ключевым фактором успеха, ведь именно они задают цели и задачи для игроков, предоставляя им структуру и направление в игре. Однако создание интересных, нетривиальных и увлекательных сценариев — это по-настоящему творческая задача, которая не всегда может быть решена самостоятельно разработчиком. Для решения подобного класса задач можно использовать такую технологию искусственного интеллекта, как языковую модель (ЯМ) нейронной сети. Эти модели предназначены для обработки и генерации естественного текста. Они обучаются на больших объемах текстовых данных, чтобы понять структуру языка и генерировать новый текст, который соответствует обучающим данным. В работе [12] было проведено сравнение различных типов нейронных сетей на основе ряда сформулированных критериев, чтобы выявить наиболее эффективные из них для генерации сценариев квестов. В результате был сделан вывод о том, что нейронные сети типа «трансформер», а также чат-боты Gigachat, Wordify и ChatGPT наилучшим образом справляются с вышеупомянутой задачей.

Одним из самых актуальных методов создания игровых сюжетов является генерация процедурных сюжетов. Суть этого подхода заключается в том, что сюжеты создаются динамически во время игры, и они могут быть уникальными для каждой новой сессии. Генерация процедурных сюжетов также использует алгоритмы и нейросетевые технологии для создания разнообразных и интересных историй, подстраиваясь под действия и решения игроков [13].

Дизайн, наряду с сюжетной линией, напрямую влияет на впечатления и эмоции, которые вызовет продукт — игра — у потенциальных пользователей. Нейросети, по сути, стали полноценным помощником дизайнеров. Для генерации изображений удобно использовать специальные чат-боты (например, Bing, MI Journey и др.), которые создают изображения на основе общего описания персонажа. Такой подход полностью изменяет этап создания концепт-арта и исключает необходимость участия концепт-художника⁵. Это позволяет сократить рас-

⁵ Концепт-арт представляет собой процесс визуального воплощения идей и концепций игрового мира, персонажей, предметов и окружения еще до начала детальной разработки графики. Концепт-художник является ключевым

ходы и время, а также увеличить вариативность эскизов, что является немаловажным конкурентным преимуществом компаний в этой сфере [14].

Для музыкального сопровождения видеоигр нейросети способны разрабатывать уникальные композиции, которые адаптируются к игровому процессу и действиям игрока. Например, алгоритм OpenAI MuseNet способен генерировать сложные музыкальные произведения, объединяя элементы различных жанров и стилей. Искусственный интеллект (ИИ) также обеспечивает генерацию «звуковых ландшафтов», т.е. совокупности звуковых эффектов, таких как: фоновый шум, звуки природы, городские звуковые эффекты. Так, для игры «Hellblade: Senua's Sacrifice» ИИ создал сложные звуковые «текстуры» [15].

РАЗРАБОТКА НАЦИОНАЛЬНОЙ ПЛАТФОРМЫ ВИДЕОИГР

Вideoигры с высокой популярностью способны оказывать сильный социокультурный эффект. Если в них содержатся элементы, противоречащие государственной системе ценностей и национальной культуре, то это вызывает справедливый гнев со стороны общества, и государство не может не отреагировать на подобное положение дел.

Например, 8 мая 2024 г. Президент Российской Федерации Владимир Путин утвердил основы государственной политики России в области исторического просвещения, которые подразумевают создание «механизмов государственного и общественного контроля» за рынком видеоигр⁶. Согласно документу, такие механизмы должны будут не допускать «неконтролируемое распространение» игр, которые создают «искаженное представление о событиях отечественной и мировой истории, а также о месте и роли России в мире» (пример игры серии «Call of Duty» приведен выше).

С другой стороны, острую социальную реакцию также может вызвать блокировка популярного сервиса. Так произошло 3 декабря 2025 г., когда Роскомнадзором была заблокирована игровая онлайн-платформа «Roblox» за использование запрещенного контента. Реакция оказалась настолько сильной, что даже пресс-секретарь президента России Дмитрий Песков подтвердил многочисленные обращения в Кремль от детей⁷. И здесь важно

специалистом, ответственным за создание первого представления будущего продукта.

⁶ URL: <https://www.kommersant.ru/doc/6689328?ysclid=mj6nt7h5i9495396396>

⁷ В Кремле сообщили о множестве детских обращений из-за блокировки «Roblox». URL: <https://www.rbc.ru/politics/09/12/2025/6937f4619a794716c9fa8270?ysclid=mj2qltxjm8893662405> (дата обращения: 10.12.2025).



определить причину жалоб: у российских пользователей указанной онлайн-платформы нет полноценного аналога «Roblox» с подобным функционалом (платформа-песочница, инструмент для создания собственной игры) и возможностями (социальное взаимодействие, коммерциализации).

Дело в том, что компьютерные игры с достаточной силой влияют на мировоззрение людей, что особенно касается так называемых миллениалов (поколение, родившееся с 1981 по 1996 г.), зумеров (родились в период 1997–2012 гг.) и представителей поколения «Альфа» родились с 2010 по 2024 г.).⁸ Для них игры имеют не менее важное значение в формировании политических убеждений, моральных принципов, понимания собственной роли в жизни, чем литература, телевидение и кино. Часто компьютерные игры и интернет предлагают молодым людям сложные нравственные дилеммы, заставляют их думать — особенно тех, кто склонен к подобным размышлениям [16].

Вышеизложенную ситуацию можно рассматривать как окно возможностей для отечественных ИТ-компаний в области производства видеоигр. В настоящее время в России создана полноценная инфраструктура для разработки отечественных цифровых решений. В частности, в таких технополисах, как Сколково или Иннополис, резиденты получают значительные налоговые льготы и доступ к акселерационным программам. Московский инновационный кластер поддерживает молодые компании в сфере креативных индустрий, включая игровые проекты через грантовые конкурсы.

⁸ Указанные временные рамки являются приблизительными и могут варьироваться в зависимости от исследовательских подходов.

Помимо этого, ведется подготовка специалистов по востребованным ИТ-направлениям в вузах, зачастую в тесном сотрудничестве с ведущими отраслевыми компаниями.

Все это позволяет предположить, что сложились благоприятные условия для масштабной разработки национальной платформы видеоигр, которая сможет не только заменить заблокированный сервис, но и обеспечить безопасность ее пользователей в виртуальном пространстве. Очевидно, такая цель потребует немало ресурсов и времени, но преимущества, в том числе нематериальные (защита от пропаганды насилия и искажения исторической правды), оправдывают потраченные средства.

ВЫВОДЫ

Учитывая стабильно высокий интерес к играм приключенческого жанра, а также доступность ИИ для их разработки, можно предположить, что в ближайшее время рынок будет расти за счет новых игроков. Искусственный интеллект стал неотъемлемой частью производственного процесса создания видеоигр, вследствие чего обязательными компетенциями разработчиков станут навыки и умения по применению конкретных технологий ИИ на всех этапах разработки, так как от этого напрямую зависит качество финального продукта и главное — скорость его вывода на рынок.

Государственная политика наряду с обеспеченностью необходимыми ресурсами позволяют инициировать создание национальной игровой платформы, которая призвана восполнить потребность пользователей в мультифункциональных игровых сервисах и обеспечить при этом высокий уровень безопасности.

СПИСОК ИСТОЧНИКОВ

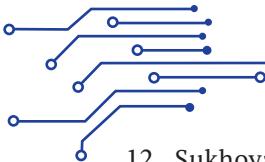
1. Шибаев М.В. Живопись сквозь призму виртуальной графики игрового пространства. *Коммуникации. Медиа. Дизайн.* 2021;4:5–28. URL: https://elibrary.ru/download/elibrary_47926988_98627755.pdf
2. Кучма А.В. Эстетика и визуальные особенности в различных жанрах компьютерных игр. *Вестник науки.* 2025;6(87):2259–2266. URL: https://elibrary.ru/download/elibrary_82388059_99137246.pdf
3. Андреева В.В. Репрезентация эмоций игровых персонажей видеоигр жанра action-adventure в период с 2000-х годов по 2020-е через цветокоррекцию. *Бизнес и дизайн ревю.* 2024;2(34):42–53. URL: <https://elibrary.ru/item.asp?id=67904224>
4. Фленов М.Е. Искусство программирования игр на С++. СПб.: БХВ-Петербург; 2006. 256 с. URL: https://books.4nmv.ru/books/iskusstvo_programmirovaniya_igr_na_s_3642769.pdf
5. Yusuf Pisan. Twisty Little Passages: An Approach to Interactive Fiction. *Artificial Intelligence.* 2007;18:1124–1126. DOI: 10.1016/j.artint.2007.10.004
6. Иванов Р.М. Видеоигры в жанре «квест»: история и развитие. *Вестник молодых ученых Санкт-Петербургского государственного университета технологии и дизайна.* 2022;2:234–240. URL: <https://elibrary.ru/item.asp?id=50738515>
7. Klaehn J. Making digital adventure games: a conversation with Mark Yohalem. *Creative Industries Journal.* 2022;3:332–341. DOI: 10.1080/17510694.2021.1939543



8. Ranjis K.D. Design and Build a 2D Mobile-Based Adventure Game Named “Astronaut Go”. *Procedia of Engineering and Life Science*. 2022;2(2). DOI: 10.21070/pels.v2i2.1208
9. Симонович С.В., Евсеев Г.А. Занимательный компьютер: книга для детей, учителей и родителей. М.: ACT-Пресс; Инфорком-Пресс; 1999. 368 с. URL: <https://nzdr.ru/data/media/biblio/games/nauka/Занимательный%20компьютер%20-%20Симонович,%20Евсеев.pdf?ysclid=mj634kj3j356740720>
10. Ламот А. Программирование игр для Windows: советы профессионала. Пер. с англ. М.: Издательский дом «Вильямс»; 2004. 880 с.
11. Волчек А.И., Сагун А.Е. Путь в ИТ: узнайте все про мир информационных технологий и смените сферу деятельности. М.: ООО GeekBrains; 2022. 90 с. URL: <https://gbcdn.mrgcdn.ru/uploads/staticpage/435/asset/95fe3ce883dbb232d0b03747a4059418.pdf> (дата обращения: 10.12.2025).
12. Сухоярский Д.И., Маевский И.А., Савельев И.М. Исследование языковых моделей нейронных сетей для генерации сценариев игрового квеста. *Оригинальные исследования*. 2023;13(12):146–155. URL: <https://elibrary.ru/item.asp?id=60030465>
13. Федонкин А.А. Роль генерации сюжетов в развитии компьютерных игр приключенческого жанра. Цифровое будущее: социальные и экономические проблемы, вызовы и возможности. Сборник статей круглого стола, Москва, 16 ноября 2023 г. М.: КДУ; Добросвет; 2024;417–423. URL: <https://elibrary.ru/item.asp?id=60234591>
14. Годин В.В., Терехова А.Е., Булатов Д.Н., Заремба Ю.А. Использование нейронных сетей в видеоигровой индустрии. *Вестник университета*. 2024;8:23–33. DOI: 10.26425/1816-4277-2024-8-23-33
15. Кильдюшов Л.С., Могилевская Г.И. Искусственный интеллект в разработке видеоигр. Технические исследования и разработки: новые парадигмы современности. Сборник научных статей. Ульяновск: Зебра; 2025;70–73. URL: <https://elibrary.ru/item.asp?id=82428159>
16. Гринвальд Г. Негде спрятаться. Эдвард Сноуден и зоркий глаз Дядюшки Сэма. Пер. с англ. СПб.: Питер; 2015. 320 с. URL: https://royallib.com/read/grinvald_glenng/negde_spryatatsya_edvard_snouden_i_zorkiy_glaz_dyadyushki_sema.html#0

REFERENCES

1. Shibaev M.V. Painting in terms of virtual graphics of the game space. *Communications. Media. Design*. 2021;(4):5–28. URL: https://elibrary.ru/download/elibrary_47926988_98627755.pdf (In Russ.).
2. Kuchma A.V. Estetika i vizualnye osobennosti v razlichnykh zhanrakh kompyuternykh igr. *Vestnik nauki*. 2025;1(6)(87):2259–2266. URL: https://elibrary.ru/download/elibrary_82388059_99137246.pdf (In Russ.).
3. Andreeva V.V. Representation of emotions of game characters in action-adventure video games from the 2000s to the 2020s through color correction. *Business and Design Review*. 2024;2(34):42–53. URL: <https://elibrary.ru/item.asp?id=67904224> (In Russ.).
4. Flenov M.E. The Art of Game Programming in C++. St. Petersburg: BHV-Petersburg; 2006. 256 p. URL: https://books.4nmv.ru/books/iskusstvo_programmirovaniya_igr_na_s_3642769.pdf (In Russ.).
5. Yusuf Pisan. Twisty Little Passages: An Approach to Interactive Fiction. *Artificial Intelligence*. 2007;171(18):1124–1126. DOI: 10.1016/j.artint.2007.10.004
6. Ivanov R.M. Adventure video games: history and evolution. *Vestnik molodykh uchenykh Sankt-Peterburgskogo gosudarstvennogo universiteta tekhnologii i dizayna*. 2022;(2):234–240. URL: <https://elibrary.ru/item.asp?id=50738515> (In Russ.).
7. Klaehn J. Making digital adventure games: a conversation with Mark Yohalem. *Creative Industries Journal*. 2022;15(3):332–341. DOI: 10.1080/17510694.2021.1939543
8. Ranjis K.D., Taurusta C. Design and Build a 2D Mobile-Based Adventure Game Named “Astronaut Go”. *Procedia of Engineering and Life Science*. 2022;2(2). DOI: 10.21070/pels.v2i2.1208
9. Simonovich S.V., Evseev G.A. Fascinating Computer: A Book for Children, Teachers, and Parents. Moscow: AST-Press; Inforcom-Press; 1999. 368 p. URL: <https://nzdr.ru/data/media/biblio/games/nauka/Занимательный%20компьютер%20-%20Симонович,%20Евсеев.pdf?ysclid=mj634kj3j356740720> (In Russ.).
10. LaMothe A. Tricks of the Windows Game Programming Gurus. Transl. from Eng. Moscow: Williams Publishing House; 2004. 880 p. URL: https://vk.com/wall-206723877_9683 (accessed on 25.06.2025).
11. Volchek A.I., Sagun A.E. Path to IT: Learn Everything About the World of Information Technology and Change the Field of Activity. Moscow: GeekBrains (GeekBrains, LLC); 2022. 90 p. URL: <https://gbcdn.mrgcdn.ru/uploads/staticpage/435/asset/95fe3ce883dbb232d0b03747a4059418.pdf> (accessed on 17.08.2025). (In Russ.).



12. Sukhoyarsky D.I., Mayevsky I.A., Savylyev I.M. The research of neural network language models for generating game quest scenarios. *Originalnye issledovaniia*. 2023;13(12):146–155. URL: <https://elibrary.ru/item.asp?id=60030465> (In Russ.).
13. Fedonkin A.A. The role of plot generation in the development of computer games of the adventure genre. *Tsifrovoe budushchchee: sotsial'nye i ekonomicheskie problemy, vyzovy i vozmozhnosti*. Collection of articles Round Table, Moscow, November 16, 2023. Moscow: KDU; Dobrosvet; 2024:417–423. URL: <https://elibrary.ru/item.asp?id=60234591> (In Russ.).
14. Godin V.V., Terekhova A.E., Bulatov D.N., Zaremba Yu.A. Neural networks utilization in the video game industry. *Vestnik Universiteta*. 2024;(8):23–33. (In Russ.). DOI: 10.26425/1816-4277-2024-8-23-33
15. Kil'dyushov L.S., Mogilevskaya G.I. Artificial intelligence in video game development. *Tekhnicheskie issledovaniya i razrabotki: novye paradigmy sovremennosti*. Ul'yanovsk: IP Kenshenskaya Viktoriia Valer'evna (Publishing House "Zebra"); 2025:70–73. URL: <https://elibrary.ru/item.asp?id=82428159> (In Russ.).
16. Greenwald G.E. *No Place to Hide: Edward Snowden, the NSA, and the U.S. Surveillance State*. Transl. from Eng. Saint Petersburg: Peter; 2015. 320 p. URL: https://royallib.com/read/grinvald_glen/negde_spryatatsya_edward_snouden_i_zorkiy_glaz_dyadyushki_sema.html#0 (In Russ.).

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Александр Александрович Бердюгин — младший научный сотрудник кафедры информационной безопасности факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Alexander A. Berdyugin — Junior Researcher, Information Security Department, Faculty of Information Technologies and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0003-2301-1776>

aaberdyugin@fa.ru

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

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

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

Автор для корреспонденции / Corresponding author:

srmuminova@fa.ru

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

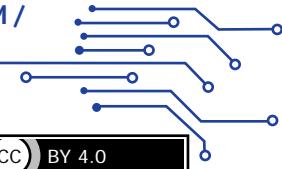
Conflicts of Interest Statement: The authors have no conflicts of interest to declare.

Статья поступила в редакцию 13.10.2025; принята к публикации 24.11.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 13.10.2025; accepted for publication on 24.11.2025.

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



ОРИГИНАЛЬНАЯ СТАТЬЯ

(CC) BY 4.0

DOI: 10.26794/3033-7097-2025-1-4-35-42
УДК 004.85(045)

Динамическая модель внимания в трансформерах

В.Б. Гисин

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

Механизм внимания является основой трансформеров, ключевого компонента современных искусственных нейронных сетей, используемых при работе с данными различной природы. В статье изучается динамическая модель механизма внимания. В рамках этой модели внимание описывается как движение взаимодействующих токенов. Показано, что при подходящих предположениях внимание непрерывно по Липшицу. В частности, непрерывность по Липшицу обеспечивает нормирование токенов. Это служит основанием для исследования решений систем дифференциальных уравнений, описывающих динамику трансформеров. Целью исследования является изучение особенностей поведения токенов, составляющих промт, при неограниченном увеличении числа слоев трансформера. В одномерном случае приведено качественное описание траекторий токенов и динамики матрицы внимания. Показано, что если токен в некоторый момент времени выходит за границу достаточно узкого коридора (ширины порядка логарифма размера промт), то этот токен в дальнейшем стремится к бесконечности (положительной или отрицательной в зависимости от того, через какую границу произошел выход). Методология исследования базируется на непрерывной параметризации матрицы внимания. Распространенное представление динамики трансформеров разностными уравнениями заменено представлением с помощью систем обыкновенных дифференциальных уравнений. Описанию и изучению трансформеров посвящено огромное число публикаций, но большинство из них не содержат точных математических описаний архитектуры. В этой статье сделана попытка дать математически точное и при этом достаточно простое описание динамики трансформеров. Динамика токенов в одномерном случае, безусловно, значительно проще, чем динамика многомерных токенов. Тем не менее она дает представление о поведении трансформеров и в более общей ситуации создает каркас из точных формулировок.

Ключевые слова: искусственный интеллект; нейронная сеть; трансформер; механизм внимания; траектория; взаимодействие токенов

Для цитирования: Гисин В.Б. Динамическая модель внимания в трансформерах. Цифровые решения и технологии искусственного интеллекта. 2025;1(4):35-42. DOI: 10.26794/3033-7097-2025-1-4-35-42

ORIGINAL PAPER

Dynamic Model of Attention in Transformers

V.B. Gisin

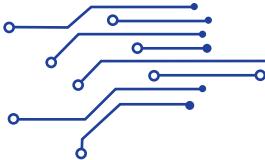
Financial University under the Government of the Russian Federation, Moscow, Russian Federation

ABSTRACT

The attention mechanism is a key component of modern artificial neural networks designed to process data of various nature. The article examines the dynamic of attention using a continuous model. In this model, attention is described as the movement of interacting tokens. It is shown that, under suitable assumptions, attention is Lipschitz continuous. In particular, Lipschitz continuity may be ensured by token normalization. The dynamics of transformers is modelled by a system of differential equations. Lipschitz continuity guarantees that there exists a solution to this system. The purpose of the study is to investigate the behavior of tokens that make up prompt under an unlimited increasing in the number of transformer layers. For one-dimensional tokens, a qualitative description of the trajectories of tokens and the dynamics of the attention matrix is given. It is shown that if a token goes beyond a fairly narrow corridor at some point (the width is on the order of the logarithm of the prompt size), this token tends to infinity (positive or negative, depending on which border the exit occurred). The research methodology is based on continuous parameterization of the attention matrix. The common representation of transformer dynamics by difference equations has been replaced by a representation using systems of ordinary differential equations. A huge number of publications are devoted to the description and study of transformers, but most of them do not contain accurate mathematical descriptions of architecture. This article attempts to give a mathematically meaningful and at the same time fairly simple description of attention. The description dynamics of 1-d tokens is certainly much simpler than the dynamics of multidimensional tokens. Nevertheless, this description gives an idea of the behavior of transformers in a more general situation creates a framework for future investigation.

Keywords: artificial intelligence; neural network; transformer; mechanism of attention; trajectory; interaction of tokens

For citation: Gisin V.B. Dynamic model of attention in transformers. Digital Solutions and Artificial Intelligence Technologies. 2025;1(4):35-42. DOI: 10.26794/3033-7097-2025-1-4-35-42



ВВЕДЕНИЕ

За последние несколько лет произошел невероятный прогресс в обработке естественного языка и в искусственном интеллекте. Модели последних поколений состоят из глубоких нейронных сетей. Их сложная архитектура основана на трансформерах с механизмами внимания [1]. Обучение на огромных по объему и разнородных по составу наборах данных позволило этим моделям достичь беспрецедентных результатов [2, 3].

Несмотря на их определяющую роль в успехе моделей искусственного интеллекта, трансформеры остаются изученными лишь частично. Технологии, связанные с искусственным интеллектом в общем и трансформерами в частности бурно развиваются [4–7]. Архитектура трансформеров совершенствуется и адаптируется к новым задачам [8, 9]. С учетом этого представляется полезным взгляд на трансформеры с точки зрения математики. Такой взгляд позволяет зафиксировать математические идеи, общие для трансформеров разной архитектуры, и наметить рамки, в которых эмпирическое изучение трансформеров может получить математическое обоснование. Одной из (пока отдаленных) целей этого подхода является создание объяснимых моделей искусственного интеллекта [10].

Целью настоящей статьи является создание математически точного и при этом достаточно простого описания динамики трансформеров.

ОСНОВА РАБОТЫ ТРАНСФОРМЕРОВ

Определяющим для трансформеров является механизм внимания [1, 3]. Он позволяет трансформерам обрабатывать не один входной вектор (токен) $x(0)$, а набор токенов

$$(x_1(0), \dots, x_N(0)) \in (R^D)^N,$$

где D – размерность токена; N – число токенов, обрабатываемых трансформером.

Такие наборы называют промтами. При работе с естественным языком каждый токен соответствует слову, а вся последовательность – предложению или другому фрагменту текста. Таким образом промт представляет собой слова вместе с их контекстом.

Слои трансформера $t = 1, 2, \dots, T$ последовательно преобразуют промт в выходной набор токенов

$$(x_1(T), \dots, x_N(T)) \in (R^D)^N.$$

Представим набор токенов $(x_1(t), \dots, x_N(t)) \in (R^D)^N$ матрицей $X(t) \in R^{N \times D}$, в которой строка $X_i(t)$ соответствует токену $x_i(t) \in R^D$, так что $X_i(t) = x_i^T(t)$. Тогда работу трансформера можно представить как

последовательность отображений пространства $R^{N \times D}$ в себя. Основой трансформера служит механизм самонаблюдения (self-attention), который корректирует координаты токена в зависимости от контекста: относительно усиливаются те признаки, которые в большей степени связаны с контекстом.

Преобразование матрицы X , выполняемое слоем трансформера, имеет вид

$$\Phi(X) = [\Phi^1(X), \dots, \Phi^H(X)]W^O, \quad (1)$$

где H – делитель D ; $\Phi^h(X) \in R^{N \times D/H}$ при всех $h = 1, \dots, H$, и $W^O \in R^{D \times D}$.

Преобразования $X \mapsto \Phi^h(X)$ выполняются наблюдателями (в англоязычной литературе используется термин «head»):

$$\Phi^h(X) = P^h X V^h, \quad (2)$$

где $P^h \in R^{N \times N}$ – матрица «сходства» токенов (вообще говоря, не симметричная), а $V^h \in R^{N \times D/H}$ – матрица значений, получаемых при обучении.

В простейшем случае, когда W^O – единичная матрица, и при одном наблюдателе соотношение (1) может выглядеть следующим образом:

$$\Phi(X) = \text{Softmax}[XX^T]X \quad (3)$$

(опущены указания на слой t).

В этом случае

$$P_{ij} = \frac{\exp x_i, x_j}{\sum_{j'=1}^N \exp x_i, x_{j'}}. \quad (4)$$

Более гибкое самонаблюдение получается, если $H > 1$ и

$$P^h = \text{Softmax} \left[\frac{XQ^h(XK^h)^T}{\sqrt{D/H}} \right],$$

где Q^h (запросы) и K^h (ключи) – матрицы размерности $D \times D/H$, формируемые при обучении.

Чтобы учесть взаимное расположение токенов в последовательности, используется механизм позиционирования. К вектору x_i добавляется вектор r_i , содержащий информацию о месте i токена x_i в промте. Один из получивших распространение подходов использует векторы r_i , такие что

$$r_{i,m} = \sin \left(\frac{i}{L^{m/D}} \right)$$

для четных значений m , и

$$r_{i,m} = \cos \left(\frac{i}{L^{(m-1)/D}} \right)$$

для нечетных $m = 1, \dots, D$, где L – достаточно большое число.



При таком подходе модель обучается ориентироваться по относительному расположению токенов [11]. Позиционирование токенов позволяет рассматривать промт как неупорядоченный набор векторов. Поскольку информация о позиции токена включается в токен, она учитывается при обучении.

Как уже было отмечено, отображение, задаваемое трансформером, является функцией не отдельного входного сигнала, а (упорядоченного) набора D -мерных токенов. Эти токены эволюционируют во времени, взаимодействуя друг с другом в соответствии с механизмом самонаблюдения [12].

НЕПРЕРЫВНАЯ МОДЕЛЬ МЕХАНИЗМА ВНИМАНИЯ

Следуя работе [13], можно рассматривать токены как частицы, а динамику трансформера — как систему взаимодействующих частиц, которая описывается уравнениями вида

$$\dot{x}_i(t) = \sum_{j=1}^N \frac{\exp \beta \langle Q(t)x_i(t), K(t)x_j(t) \rangle}{Z_i(t)} V(t)x_j(t), \quad (5)$$

где

$$Z_i(t) = \sum_{l=1}^N \exp \beta \langle Q(t)x_i(t), K(t)x_l(t) \rangle — (6)$$

нормирующий множитель.

Следуя распространенной практике, будем считать, что $\beta = 1/\sqrt{D/H}$.

Уравнение (5) позволяет рассматривать самонаблюдение как нелинейный механизм взаимодействия в системе токенов. Коэффициенты в уравнении (5) соответствуют относительному вниманию, которое токен i уделяет токену j . В частности, токен обращает внимание на своих «соседей», а «соседство» определяется матрицами Q и K .

При таком подходе «классические» блоки механизма самонаблюдения

$$x_i \leftarrow x_i + \sum_{j=1}^N \frac{\exp \beta \langle Qx_i, Kx_j \rangle}{Z_i(t)} Vx_j,$$

аппроксируют решение уравнения (5).

Для трансформера с H наблюдателями уравнение (5) приобретает следующий вид:

$$\dot{x}_i(t) = \sum_{h=1}^H \sum_{j=1}^N \frac{\exp \beta \langle Q^h(t)x_i(t), K^h(t)x_j(t) \rangle}{Z_i^h(t)} V^h(t)x_j(t). \quad (7)$$

УСЛОВИЯ ЛИПШИЦА

Решение уравнения (5) или (7) может рассматриваться как своеобразная компонента объяснения

функционирования трансформера. Для существования решения уравнения (7) достаточно, чтобы функция в правой части уравнения удовлетворяла условию Липшица. В общем случае это уже не так.

Чтобы не усложнять обозначения, рассмотрим в качестве примера случай, когда $D = 1, N = 2$ и $H = 1$. Соответственно, $Q, K, V \in R$.

Пусть $x_1, x_2 \in R$ — токены. Тогда $X = (x_1, x_2)^T$,

$$a \dot{x}_i = \frac{V}{Z_i(t)} (\exp(QKx_i x_1) x_1 + \exp(QKx_i x_2) x_2).$$

Далее P — матрица второго порядка, такая, что

$$P_{11} = \frac{e^{\alpha x_1^2}}{e^{\alpha x_1^2} + e^{\alpha x_2^2}}, \quad P_{12} = \frac{e^{\alpha x_1 x_2}}{e^{\alpha x_1^2} + e^{\alpha x_2^2}},$$

$$P_{21} = \frac{e^{\alpha x_1 x_2}}{e^{\alpha x_1 x_2} + e^{\alpha x_2^2}}, \quad P_{22} = \frac{e^{\alpha x_2^2}}{e^{\alpha x_1 x_2} + e^{\alpha x_2^2}},$$

где $\alpha = QK$. Положим,

$$f_1(X) = P_{11}x_1 + P_{12}x_2,$$

$$f_2(X) = P_{21}x_1 + P_{22}x_2.$$

Тогда уравнение (7) приобретает следующий вид:

$$\begin{pmatrix} \dot{x}_1 \\ \dot{x}_2 \end{pmatrix} = \begin{pmatrix} f_1(X) \\ f_2(X) \end{pmatrix} V.$$

Если функция

$$X \mapsto f(X) = \begin{pmatrix} f_1(X) \\ f_2(X) \end{pmatrix}$$

из R^2 в R^2 удовлетворяет в некоторой области условию Липшица, то частные производные $\frac{\partial f_i}{\partial x_j}$ должны быть ограничены.

В качестве примера найдем $\frac{\partial f_1}{\partial x_1}$ (можно заметить, что $f_1: R^D \rightarrow R^D$, так что якобиан $\frac{\partial f_1}{\partial x_1}$ представляет собой квадратную матрицу порядка D).

Имеем:

$$\begin{aligned} \frac{\partial f_1}{\partial x_1} &= \\ &= P_{11} + \alpha P_{11}x_1 \left[x_1 - (P_{11}x_1 + P_{12}x_2) \right] + \\ &+ \alpha \left[(P_{11}x_1^2 + P_{12}x_2^2) - (P_{11}x_1 + P_{12}x_2)^2 \right]. \end{aligned}$$

Последнее слагаемое представляет собой дисперсию единственного признака, который имеют оба токена и принимающий значение x_1 с вероятностью P_{11} и значение x_2 с вероятностью P_{12} .



В общем случае несложные, но довольно громоздкие вычисления показывают, что

$$\frac{\partial f_1}{\partial x_1} = P_{11} \cdot I_D + P_{11} \left[x_1 - \sum_{k=1}^N P_{1k} x_k \right] x_1^T Q K^T + \\ + [X^T C X] K Q^T,$$

где I_D — единичная матрица порядка D , а матрица C имеет следующий вид:

$C_{jj} = P_{1j} - P_{1j}^2$, $C_{ij} = -P_{1i}P_{1j}$ при $i \neq j$
(чтобы не усложнять обозначений, опущено указание на номер наблюдателя h).

Следовательно,

$$\begin{aligned} [X^T C X]_{kl} &= (x_{1k}, \dots, x_{Nk}) C (x_{1l}, \dots, x_{Nl})^T = \\ &= \sum_{j=1}^N (P_{1j} - P_{1j}^2) x_{jk} x_{jl} - \sum_{i,j=1, i \neq j}^N P_{1i} P_{1j} x_{ik} x_{jl} = \\ &= \sum_{j=1}^N P_{1j} x_{jk} x_{jl} - \sum_{i,j=1}^N P_{1i} P_{1j} x_{ik} x_{jl} = \\ &= \sum_{j=1}^N P_{1j} x_{jk} x_{jl} - \left(\sum_{j=1}^N P_{1j} x_{jk} \right) \cdot \left(\sum_{j=1}^N P_{1j} x_{jl} \right). \end{aligned}$$

Таким образом, $[X^T C X]_{kl}$ — ковариация признаков k и l , которые принимают с вероятностью P_{1j} значения, соответственно, x_{jk} и x_{jl} , $x_{jk}, j = 1, \dots, N$.

Чтобы не усложнять обозначений, вычисления приведены для f_1 и x_1 .

Вычисление $\frac{\partial f_i}{\partial x_j}$ для других индексов осуществляется так же.

Если ковариация какой-либо пары признаков или дисперсия какого-то одного признака может быть неограниченно большой, то условие Липшица может не выполняться. Например, если $x_1 = 0$, то, как легко заметить, $P_{1j} = 1/N$ для всех $j = 1, \dots, N$, и ковариация признаков оказывается просто выборочной дисперсией этих признаков. В то же время умножение на матрицу V может «погасить» признаки с большой дисперсией. С учетом этого заключение теоремы 3.1 в работе [14] оказывается верным лишь при выполнении указанных выше условий.

В приложениях часто применяется нормализация токенов [15]. В этом случае можно считать, что векторы $x_i(t)$ находятся на единичной сфере, так что $X(t) \in (S^{D-1})^N$. Можно показать, что при этих условиях отображение $X \mapsto f(X)$ удовлетворяет условию Липшица.

Это можно проиллюстрировать для случая $D = 2, N = 2$ при единичных матрицах Q, K и V .

В самом деле, для

$$X = \begin{pmatrix} x_{11} & x_{12} \\ x_{21} & x_{22} \end{pmatrix} \in S^2$$

имеем

$$XX^T = \begin{pmatrix} 1 & \cos \varphi \\ \cos \varphi & 1 \end{pmatrix},$$

где φ — угол между векторами x_1 и x_2 . Соответственно,

$$P = \frac{1}{e + e^{\cos \varphi}} \begin{pmatrix} e & e^{\cos \varphi} \\ e^{\cos \varphi} & e \end{pmatrix},$$

и

$$PX = \frac{1}{e + e^{\cos \varphi}} \begin{pmatrix} x_{11}e + x_{21}e^{\cos \varphi} & x_{12}e + x_{22}e^{\cos \varphi} \\ x_{21}e + x_{11}e^{\cos \varphi} & x_{22}e + x_{12}e^{\cos \varphi} \end{pmatrix}.$$

Матрица Y получается делением элементов первой строки матрицы PX на длину первого вектора, второй строки — на длину второго вектора. В частности, имеем:

$$y_{11} = \frac{e^2 + e^{1+\cos \varphi}}{e^2 + 2e^{1+\cos \varphi} \cos \varphi + e^{2\cos \varphi}}.$$

Далее

$$\begin{aligned} \frac{\partial y_{11}}{\partial x_{11}} &= \\ &= \frac{e^{1+\cos \varphi} \sin \varphi (e^2 + 4e^{1+\cos \varphi} + 2e^2 \cos \varphi + e^{2\cos \varphi})}{(e^2 + 2e^{1+\cos \varphi} \cos \varphi + e^{2\cos \varphi})^2} x_{12}. \end{aligned} \quad (8)$$

Так как наименьшее значение знаменателя дроби (8) равно $e^{-2} + e^2 - 2$, а компонента x_{12} вектора на единичной сфере не превосходит по абсолютной

величине единицу, производная $\frac{\partial y_{11}}{\partial x_{11}}$ ограничена.

Точно так же оказываются ограниченными остальные компоненты якобиана.

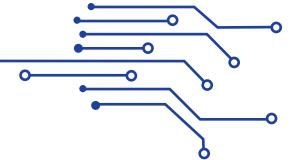
При нормализации промту $X(t) \in (S^{D-1})^N$ можно сопоставить вероятностную меру на S^{D-1} , сосредоточенную в токенах x_i :

$$\mu(t, \cdot) = \frac{1}{N} \sum_{i=1}^N \delta_{x_i}(\cdot),$$

где $\delta_{x_i}(x) = 1$ при $x = x_i$ и $\delta_{x_i}(x) = 0$ при $x \neq x_i$. Тогда динамика трансформера может быть описана в терминах мер на S^{D-1} [15].

ТРАЕКТОРИИ ТОКЕНОВ

Динамика $X(t)$ может быть достаточно сложной. Далее рассмотрим упрощенный вариант, когда размерность токена равна единице, так что промт представляет собой набор чисел



$X = (x_1, \dots, x_N) \in R^N$. Дополнительно будем предполагать, что $QK = 1$ и $V = 1$. Эти предположения не принципиальны, но упрощают выкладки и позволяют более наглядно описать динамику трансформера. Под динамикой трансформера имеется в виду не только (и не столько) траектория токенов $x_i(t)$, но и поведение матрицы

$$P(t) = (P_{ij}(t)) \in R^{N \times N}.$$

Динамика трансформера $X(t)$ с одномерными токенами описывается системой обыкновенных дифференциальных уравнений:

$$\dot{x}_i = \sum_{j=1}^N P_{ij} x_j; \quad P_{ij} = \frac{e^{x_i x_j}}{\sum_{k=1}^N e^{x_i x_k}}. \quad (9)$$

Покажем сначала, что траектории токенов не сближаются. В самом деле,

$$\frac{d}{dt} (x_i(t) - x_j(t))^2 = 2(x_i(t) - x_j(t))(\dot{x}_i(t) - \dot{x}_j(t)).$$

Заметим, что $\dot{x}_i(t) = f'(x_i(t))$,
где $f(x) = \ln \left(\sum_{j=1}^N e^{x_i x_j} \right)$.

Тогда

$$\frac{d}{dt} (x_i(t) - x_j(t))^2 = 2(x_i(t) - x_j(t))(f'(x_i) - f'(x_j)).$$

Функция $f(x)$ выпукла, поэтому $x_i(t) - x_j(t)$ и $f'(x_i) - f'(x_j)$ имеют один и тот же знак, и, значит,

$$\frac{d}{dt} (x_i(t) - x_j(t))^2 \geq 0.$$

Следовательно, величина $|x_i(t) - x_j(t)|$ не убывает при любых $i, j = 1, \dots, N$.

Если $x_i(0) = x_l(0)$, система уравнений (9) не изменится при перестановке токенов с номерами i и l , а траектории $x_i(t)$ и $x_l(t)$ будут одинаковыми. Поэтому, не ограничивая общности, можно считать, что все токены разные. Позиционирование позволяет включить информацию о взаимном расположении токенов в «содержимое» токена. С учетом этого можно считать, что токены занумерованы в порядке возрастания их значений в начальный момент времени:

$$x_1(0) < x_2(0) < \dots < x_N(0).$$

Оценим $x_N(t)$. Покажем, что при достаточно больших положительных значениях $x_N(t)$ производная $x_N(t)$ растет не менее быстро, чем $x_N(t)$, при $x_N(t) \rightarrow \infty$.

Имеем

$$\dot{x}_N(t) = \sum_{j=1}^{N-1} \frac{e^{x_N(t)x_j(t)}}{\sum_{k=1}^N e^{x_N(t)x_k(t)}} x_j(t) + \frac{e^{x_N^2(t)}}{\sum_{k=1}^N e^{x_N(t)x_k(t)}} x_N(t). \quad (10)$$

Второе слагаемое в правой части уравнения (10) можно переписать в виде $\frac{1}{Z_N} x_N(t)$, где

$$Z_N(t) = \sum_{k=1}^N e^{-x_N(t)(x_N(t) - x_k(t))}.$$

Так как $x_N(0) - x_k(0) > 0$ при $k < N$ и величина $(x_N(0) - x_k(0))^2$ не убывает, $x_N(t) - x_k(t) > 0$ для всех t . Рассмотрим случай, когда $x_N(t) \geq 0$. Тогда

$$e^{-x_N(t)(x_N(t) - x_k(t))} \leq 1,$$

и, значит,

$$Z_N(t) = \sum_{k=1}^{N-1} e^{-x_N(t)(x_N(t) - x_k(t))} + 1 \leq (N-1) + 1 = N.$$

Следовательно,

$$\frac{e^{x_N^2(t)}}{\sum_{k=1}^N e^{x_N(t)x_k(t)}} x_N(t) = \frac{1}{Z_N} x_N(t) \geq \frac{1}{N} x_N(t).$$

Оценим первое слагаемое в правой части уравнения (10). Отбрасывая неотрицательные слагаемые, получаем:

$$\sum_{j=1}^{N-1} \frac{e^{x_N(t)x_j(t)}}{\sum_{k=1}^N e^{x_N(t)x_k(t)}} x_j(t) \geq \sum_{x_j(t) < 0} \frac{e^{x_N(t)x_j(t)}}{e^{x_N^2(t)} Z_N(t)} x_j(t).$$

Так как $Z_N(t) > 1$, при $x_j(t) < 0$ имеем:

$$\begin{aligned} \frac{e^{x_N(t)x_j(t)}}{e^{x_N^2(t)} Z_N(t)} x_j(t) &= \\ &= -\frac{e^{-x_N(t)|x_j(t)|}}{e^{x_N^2(t)} Z_N(t)} |x_j(t)| \geq -\frac{x_N(t) \cdot |x_j(t)|}{x_N(t) \cdot e^{x_N(t)|x_j(t)|}}. \end{aligned}$$

Но $\frac{a}{e^a} < 1$ для любого $a > 0$. Поэтому

$$-\frac{x_N(t) \cdot |x_j(t)|}{x_N(t) \cdot e^{x_N(t)|x_j(t)|}} \geq -\frac{1}{x_N(t)}.$$



Окончательно получаем:

$$\sum_{j=1}^{N-1} \frac{e^{x_N(t)x_j(t)}}{\sum_{k=1}^N e^{x_N(t)x_k(t)}} x_j(t) \geq -\frac{N}{x_N(t)}$$

и

$$\dot{x}_N(t) \geq \frac{x_N(t)}{N} - \frac{N}{x_N(t)}. \quad (11)$$

Таким образом, если $x_N(t_0) > N$ в какой-то момент времени t_0 , то в дальнейшем $x_N(t)$ устремится к $+\infty$ экспоненциально быстро.

Точно так же, если $x_1(t_0) < -N$ в какой-то момент времени t_0 , то в дальнейшем $x_1(t)$ экспоненциально быстро устремится к $-\infty$. Это утверждение получается просто переменой знаков токенов:

$$-x_N(0) < -x_{N-1}(0) < \dots < -x_1(0).$$

При этом уравнения (10) не меняются.

Замечание. Оценку (11) несложно существенно уточнить. В самом деле, если $x_i(t) > 0$ для некоторого $i = 1, \dots, N$, то $x_N(t) > 0$. Для j такого, что $x_i(t) < 0$, получаем:

$$\begin{aligned} & \frac{e^{x_i(t)x_j(t)}}{\sum_{k=1}^N e^{x_i(t)x_k(t)}} x_j(t) = \\ & = -\frac{e^{-x_i(t)|x_j(t)|}}{e^{x_i(t)x_N(t)} \sum_{k=1}^N e^{-x_i(t)(x_N(t)-x_k(t))}} |x_j(t)| \geq \\ & \geq -\frac{|x_j(t)| \cdot e^{-x_i(t)|x_j(t)|}}{e^{x_i(t)x_N(t)}}. \end{aligned}$$

Далее

$$\begin{aligned} & -\frac{|x_j(t)| \cdot e^{-x_i(t)|x_j(t)|}}{e^{x_i(t)|x_j(t)|}} = \\ & = -\frac{e^{-x_i(t)x_N(t)}}{x_i(t)} \cdot \frac{x_i(t)|x_j(t)|}{e^{x_i(t)|x_j(t)|}} \geq \\ & \geq -\frac{e^{-x_i(t)x_N(t)}}{x_i(t)}. \end{aligned}$$

Таким образом,

$$\begin{aligned} \dot{x}_i(t) &= \sum_{j=1}^N P_{ij}(t) x_j(t) \geq \\ &\geq \frac{1}{N} x_N(t) - \frac{N-1}{e^{x_i(t)x_N(t)}} \cdot \frac{1}{x_i(t)}. \end{aligned} \quad (12)$$

В частности,

$$\dot{x}_N(t) \geq \frac{1}{N} x_N(t) - \frac{N-1}{e^{x_N^2(t)}} \cdot \frac{1}{x_N(t)}.$$

Это означает, что $x_N(t)$ экспоненциально быстро стремится к бесконечности.

Пусть v_0 — решение уравнения

$$\frac{v}{N} - \frac{N-1}{e^{v^2}} \cdot \frac{1}{v} = 0. \quad (13)$$

Заметим, что v_0 растет с увеличением N не быстрее, чем $\sqrt{2 \ln N}$.

Неравенство (12) показывает, что аналогичное рассуждение применимо к любому токену. Таким образом, для токенов возможны три типа траекторий: траектория может находиться внутри некоторого коридора; если траектория выходит из коридора через верхнюю границу, она устремляется к $+\infty$; если траектория выходит из коридора через нижнюю границу, она устремляется к $-\infty$.

Коридор, о котором идет речь, находится внутри полосы $[-v_0, v_0] \times R_{\geq 0}$ плоскости (x, t) , где v_0 — положительное решение уравнения (13).

Рассмотрим теперь поведение элементов матрицы $P(t)$. Предположим, что $i < N$ и $x_i(t) \rightarrow +\infty$ при $t \rightarrow \infty$. В этом случае также и $x_N(t) \rightarrow +\infty$. Кроме того, если $c > 0$ таково, что $c < x_N(0) - x_{N-1}(0)$, то $x_N(t) - x_j(t) > c$ для любого $j < N$.

Следовательно,

$$P_{ij}(t) = \frac{e^{x_i(t)x_j(t)}}{\sum_{k=1}^N e^{x_i(t)x_k(t)}} = \frac{e^{-x_i(t)(x_N(t)-x_j(t))}}{\sum_{k=1}^N e^{-x_i(t)(x_N(t)-x_k(t))}} \leq e^{-cx_i(t)}$$

при $j < N$. Таким образом, $P_{ij}(t) \rightarrow 0$ при $t \rightarrow \infty$. Соответственно,

$$P_{iN} = 1 - \sum_{k=1}^{N-1} P_{ij} \rightarrow 1.$$

Аналогичным образом, если $i > 1$ и $x_i(t) \rightarrow -\infty$ при $t \rightarrow \infty$, то $P_{ij}(t) \rightarrow 0$ для $j > 1$ и $P_{i1}(t) \rightarrow 1$.

Согласно работе [16], трансформеры могут рассматриваться как универсальные аппроксиматоры дифференциальных уравнений. С этой точки зрения переход к пределу при $t \rightarrow \infty$ соответствует неограниченному увеличению числа слоев. Таким образом, увеличение числа слоев трансформера может привести к вырождению матрицы внимания, когда все внимание будет сосредоточиваться на паре признаков с экстремальными значениями в промте.

В статье рассмотрена простейшая одномерная ситуация. Анализ проблемы во всей ее общности — задача дальнейших исследований.



ВЫВОДЫ

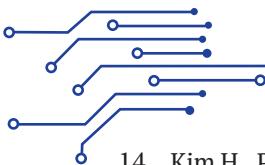
Несмотря на центральную роль трансформеров в успехе моделей искусственного интеллекта, теоретические основы, управляющие работой трансформеров, остаются изученными лишь частично. В статье предпринята попытка представить теоретическое осмысление механизмов внимания с использованием математического аппарата «непрерывной» математики. Информационный поток между слоями трансформера естественно описывать с помощью разностных уравнений. Использование в статье дифференциальных уравнений в определенной степени упрощает анализ. В то же время этот анализ остается корректным с учетом аппроксимирующих свойств нейронных сетей. Моделирование механизма внимания с помощью дифференциальных уравнений позволяет говорить об этом механизме в терминах развитой математической теории. Например, естественным образом возникает вопрос об асимптотическом поведении

и т.п. Поиск ответов на подобные вопросы может оказаться сложным, но ясно и точно поставленные общие вопросы намечают пути решения проблем.

Когда речь идет об искусственном интеллекте, баланс общности и привязки к конкретной архитектуре в значительной степени должен обуславливаться объяснимостью. С этой точки зрения представляются оправданными сделанные в статье упрощающие предположения относительно размерности и т.п. Используя несложный математический аппарат, они позволяют понять некоторые особенности механизма внимания и динамики трансформеров, которые могут быть использованы при изучении современных моделей искусственного интеллекта во всей их сложности. Дальнейшее исследование пока необъяснимой эффективности трансформеров может быть связано с поиском некоторых общих принципов их работы, сформулированных в рамках развитых математических теорий.

REFERENCES

1. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N. Kaiser Ł., Polosukhin I. Attention is all you need. In: Guyon I., Von Luxburg U., S. Bengio, et al, eds. *Neural Information Processing Systems*. 2017;30:5998–6008. URL: <https://proceedings.neurips.cc/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf>
2. Rambelli G., Chersoni E., Testa D., Blache, P., Lenci A. Neural generative models and the parallel architecture of language: A critical review and outlook. *Topics in Cognitive Science*. 2024;17(4):948–961. DOI: 10.1111/tops.12733
3. Turner R. E. An introduction to transformers. *ArXiv preprint*. 2023; arXiv:2304.10557. DOI: 10.48550/arxiv.2304.10557
4. Amatriain X., Sankar A., Bing J., Bodugutla P.K., Hazen T.J., Kazi M. Transformer models: an introduction and catalog. *ArXiv preprint*. 2023; arXiv:2302.07730. DOI: 10.48550/arXiv.2302.07730
5. He S., Sun G., Shen Z., Li A. What matters in transformers? Not all attention is needed. *ArXiv preprint*. 2024; arXiv:2406.15786. DOI: 10.48550/arXiv.2406.15786
6. Passi N., Raj M., Shelke N.A. A review on transformer models: applications, taxonomies, open issues and challenges. 4th Asian Conference on Innovation in Technology (ASIANCON). IEEE, 2024;1–6. DOI: 10.1109/ASIANCON62057.2024.10838047
7. Joshi S. Evaluation of Large Language Models: Review of Metrics, Applications, and Methodologies. *Preprint*. 2025; DOI: 10.20944/preprints202504.0369.v1
8. Sajun A.R., Zualkernan I., Sankalpa D. A historical survey of advances in transformer architectures. *Applied Sciences*. 2024;14(10):4316. DOI: 10.3390/app14104316
9. Canchila S., Meneses-Eraso C., Casanoves-Boix J., Cortés-Pellicer P., Castelló-Sirvent F. Natural Language Processing: An Overview of Models, Transformers and Applied Practices. *Computer Science and Information Systems*. 2024;21(3):1097–1145. DOI: 10.2298/CSIS 230217031C
10. Ali A., Schnake T., Eberle O., Montavon G., Müller K.R., Wolf L. XAI for transformers: Better explanations through conservative propagation. International Conference on Machine Learning. Proceedings of Machine Learning Research (PMLR). 2022;435–451. DOI: 10.48550/arXiv.2202.07304
11. Dufter P., Schmitt M., Schütze H. Position information in transformers: An overview. *Computational Linguistics*. 2022;48(3):733–763. DOI: 10.1162/coli_a_00445
12. Geshkovski B., Letrouit C., Polyanskiy Y., Rigollet P. The emergence of clusters in self-attention dynamics. *Advances in Neural Information Processing Systems*. 2023;36:57026–57037. DOI: 10.48550/arXiv.2305.05465
13. Sander M.E., Ablin P., Blondel M., & Peyré G. Sinkformers: Transformers with doubly stochastic attention. International Conference on Artificial Intelligence and Statistics. Proceedings of Machine Learning Research, 2022;3515–3530. DOI: 10.48550/arXiv.2110.11773



14. Kim H., Papamakarios G., Mnih A. The Lipschitz constant of self-attention. International Conference on Machine Learning. Proceedings of Machine Learning Research. 2021;5562–5571. DOI: 10.48550/arXiv.2006.04710
15. Geshkovski B., Letrouit C., Polyanskiy Y., Rigollet P. A mathematical perspective on transformers. *Bulletin of the American Mathematical Society*. 2025;62(3):427–479. DOI: 10.1090/bull/1863
16. Lu Y., Li Z., He D., et al. Understanding and improving transformer from a multi-particle dynamic system point of view. *ArXiv preprint*. 2019; arXiv:1906.02762. DOI: 10.48550/arXiv.1906.02762

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Владимир Борисович Гисин — кандидат физико-математических наук, профессор, профессор кафедры математики и анализа данных факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Vladimir B. Gisin — Cand. Sci. (Phys. and Math.), Professor of the Mathematics and Data Analysis Department of the Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0002-7269-0587>

vgisin@fa.ru

Конфликт интересов: автор заявляет об отсутствии конфликта интересов.

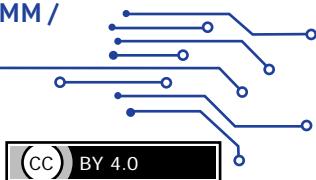
Conflicts of Interest Statement: The author has no conflicts of interest to declare.

Статья поступила 13.10.2025; принята к публикации 24.11.2025.

Автор прочитал и одобрил окончательный вариант рукописи.

The article was received on 13.10.2025; accepted for publication on 24.11.2025.

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



Gaussian Process Regression for Product Geometry Prediction in CAE Modeling

O.P. Tulupova, G.N. Zholobova

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

ABSTRACT

Superplastic forming is an advanced technology used in the aerospace and automotive industries, as well as in the medical sector, for fabricating complex seamless components. However, its application is limited by high costs and the extended duration of the process. While finite element analysis in CAE systems such as ANSYS provides accurate results, it is computationally expensive. While finite element analysis performed in CAE systems such as ANSYS provides high-fidelity results, its computational expense creates a need for fast and accurate predictive models capable of supplementing or replacing this approach in multi-criteria analysis tasks. Despite the increasing adoption of machine learning across various disciplines, the development of reliable predictive models for specific geometric characteristics of superplastically formed components remains an understudied research area. **The purpose of this study is** to develop and verify a Gaussian process based model for predicting key geometric parameters of a hemisphere during the superplastic forming. An additional objective was to create an initial dataset using data generated from numerical simulations. The Latin Hypercube Sampling method was employed to design the experiment and generate the initial dataset, enabling efficient variation of material parameters K, m and pressure regime within ranges typical for aluminum alloys. Based on data from 50 numerical simulations, a predictive model for the hemisphere's geometric characteristics was developed with Gaussian Process Regression with a composite kernel. Model hyperparameter optimization was performed using RandomizedSearchCV. The developed Gaussian Process Regression model demonstrated high accuracy, achieving a coefficient of determination greater than 0.90 on the validation set for all target variables: thickness at the pole, average height, and height difference. Analysis of the Mean Squared Error confirmed the models generalization capability and absence of overfitting. **This research is aimed** at integrating the model into a digital twin system for real-time optimization of process parameters. The main challenge in scaling this approach is the computational cost associated with generating the required training data.

Keywords: ANSYS; predictive modeling; machine learning; Gaussian process regression (GPR); mean squared error (MSE); finite element simulation; finite element method (FEM); superplastic forming (SPF)

For citation: Tulupova O.P., Zholobova G.N. Gaussian process regression for product geometry prediction in CAE modeling. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(4):43-50. DOI: 10.26794/3033-7097-2025-1-4-43-50

ОРИГИНАЛЬНАЯ СТАТЬЯ

Гауссовская регрессия для прогнозирования геометрии изделия по данным CAE-моделирования

О.П. Тулупова, Г.Н. Жолобова

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

Для создания сложных бесшовных деталей в аэрокосмической промышленности, автомобилестроении и медицине перспективной технологией является сверхпластическая формовка. Однако применение технологии ограничено высокой стоимостью и длительностью технологического процесса. Применение конечно-элементного моделирования в CAE-системах типа ANSYS дает точный результат, но вычислительно затратное, потому возникает потребность в быстрых и точных моделях прогнозирования, способных заменить или дополнить данный метод в задачах многокритериального анализа. Несмотря на растущее применение машинного обучения в различных областях, построение надежных моделей прогнозирования для конкретных геометрических характеристик деталей, полученных в результате сверхпластической формовки, остается малоизученным. **Целью данного исследования** является разработка и верификация модели прогнозирования на основе гауссовского процесса для предсказания ключевых геометрических параметров полусферы, получаемой в процессе сверхпластической формовки. Дополнительная задача состояла в создании исходного набора данных на основе результатов численного моделирования. Для формирования исходного набора данных использовался метод выборки латинского гиперкуба, позволивший эффективно варьировать параметры материала K, m и режим давления в типичных для алюминиевых сплавов диапазонах. С помощью 50 симуляций была



разработана модель прогнозирования геометрических характеристик полусферы, основанная на методе регрессии гауссовского процесса с использованием составного ядра. Для оптимизации параметров модели применялся метод RandomizedSearchCV. Разработанная модель регрессии гауссовского процесса показала высокую точность, продемонстрировав коэффициент детерминации $R^2 > 0,90$ на валидационной выборке для всех целевых переменных (толщина в полюсе купола, средняя высота, разность высот). Анализ значения среднеквадратичной ошибки подтвердил обобщающую способность и отсутствие переобучения. **Проведенное исследование направлено** на интеграцию модели масштабирования — это создание данных для обучения, которое требует больших вычислительных ресурсов.

Ключевые слова: ANSYS; модель прогнозирования; машинное обучение; регрессия гауссовского процесса (GPR); MSE; конечно-элементное моделирование; МКЭ; процесс сверхпластической формовки (СПФ)

Для цитирования: Тулупова О.П., Жолобова Г.Н. Гауссовская регрессия для прогнозирования геометрии изделия по данным САЕ-моделирования. Цифровые решения и технологии искусственного интеллекта. 2025;1(4):43-50. DOI: 10.26794/3033-7097-2025-1-4-43-50

INTRODUCTION

Superplastic forming (SPF) is recognized as an advanced technology in industries such as aerospace, automotive, and medical manufacturing. SPF is a materials processing technique that enables extremely high plastic deformation without failure. It serves as an optimal solution for fabricating complex, seamless components. Recent reviews [1–3] discuss the increasing relevance of SPF across industries and summarize latest advancements.

The principal advantages of superplastic forming (SPF) include the capability to manufacture structurally complex components in a single operation and the potential for producing parts with larger overall dimensions.

Given the costs associated with tooling, materials, and energy, as well as the duration of the part manufacturing cycle, the application of preliminary computer simulation becomes evident. Conducting virtual trials helps to optimize process parameters and reduce the probability of defects in actual production.

During the virtual design phase, a critical task is the prediction of key output parameters, particularly the thickness distribution of the final product. To address this, the Finite Element Method (FEM) [4–6], implemented in specialized CAE software packages, is traditionally employed. For instance, using the ANSYS system enables the construction of a detailed mathematical model for investigation. However, despite its high accuracy, detailed finite element modeling is characterized by significant computational expense and long simulation times, which limits its applicability for tasks requiring rapid optimization and the analysis of extensive parameter sets. Consequently, a relevant and promising development direction is the application of machine learning methods as an alternative or supplement to the classical FE modeling.

The developed predictive models, trained on limited datasets obtained from preliminary high-fidelity FE simulations or physical experiments, are capable of identifying complex non-linear relationships between process input parameters (geometry, material properties, pressure regime) and output characteristics. Machine

learning algorithms, such as artificial neural networks, support vector machines, and ensembles of decision trees, enable the construction of predictive models that are orders of magnitude faster than traditional approaches in forecasting key process outcomes. This capability establishes the foundation for developing digital twins of the manufacturing process.

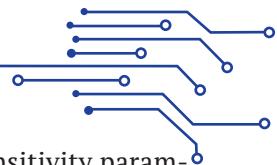
Machine learning algorithms demonstrate effectiveness in solving complex metal processing challenges, including defect prediction, rheological parameter identification, and process optimization [7].

The practical significance of applying machine learning algorithms is supported by the results of recent research. For instance, in the paper [8], the authors successfully employed machine learning methods, including artificial neural networks, to accurately predict the superplastic behavior of new multi-component alloys, such as Al-Mg-Fe-Ni-Zr-Sc. In the work [9], the authors demonstrate an approach where a multilayer feedforward neural network is used to establish correlative relationships between a wide spectrum of process parameters chemical composition, modifying additives, production methods, heat treatment regimes and the complex of mechanical properties in aluminum alloys.

The potential of machine learning is realized not only in predicting material behavior but also in solving applied technological challenges, such as product geometry control. A case in point is the research [10], where the authors demonstrated that a hybrid PSO-BP algorithm, used for predicting a thickness distribution in stiffening ribs after SPF, provides higher accuracy compared to a standard BP network. This underscores the practical value of employing machine learning methods for process optimization.

Thus, the analysis of research [7–10] reveals the advantages of integrating machine learning into the optimization of the SPF process.

The aim of the research is to develop and verify a Gaussian process-based prediction model for forecasting the geometric characteristics of a hemisphere produced by the SPF process. Primary focus is placed on predicting the thickness in the most critical area the pole of the



hemispherical dome. A dataset for training and validation was created based on the results of numerical modeling using the finite element method.

INITIAL DATASET FORMATION METHODOLOGY

To train the machine learning model, the source data comprised both experimental data from study [4] and the results of numerical modeling of the SPF process in ANSYS. The experimental data from [4] represent the results of a series of experiments on the superplastic forming of hemispherical domes from an aluminum alloy. The hemisphere was molded to a height of 50 mm, the initial thickness of the blank sheet was 1.2 mm. The molding was carried out through a cylindrical die with constant pressure of an inert gas. During the research, various pressure values were considered, including $p = 0.29$ MPa and $p = 0.56$ MPa.

In the research, the results of numerical modeling were used as the main data source, since conducting technological experiments is costly, and data from literary sources is insufficient to form a training sample.

To generate initial dataset, 50 solutions were performed in ANSYS. For each of the two pressure values [4], a series of calculations was performed with various combinations of key material parameters K and m included in the superplasticity equation and determining its deformation behavior:

$$\sigma = K \cdot \xi^m,$$

where σ is the flow stress, ξ is the strain rate, K is the strength parameter, and m is the strain rate sensitivity parameter.

To create combinations of parameters K and m , the Latin Hypercube Sampling (LHS) method was used, which showed higher efficiency compared to the standard Monte Carlo sampling [11].

The initial data in the LHS method used were the ranges of parameter values $K = 100\text{--}300$ MPa·s m , $m = 0.3\text{--}0.7$, which correspond to typical values for aluminum alloys. A sample size of 50 parameter combinations was selected as a compromise between model accuracy and computational cost.

To form the initial data set (training, validation and test samples) from the results of numerical modeling, not only the final, but also intermediate values of the process parameters were used, such as time (t , sec), dome height (h , m) and thickness at the pole (s , m) to take into account the dynamics of the SPF molding for predicting changes in geometric parameters over time during the SPF process.

Dome height was measured at two distinct points: on the inner (UY_1) and outer (UY_111) surfaces at the pole of the hemispherical dome.

The following values were determined as input parameters (features) in the sample:

- 1) m — the material's strain rate sensitivity parameter;
- 2) K — the material's strength coefficient, MPa·s m ;
- 3) p — pressure, MPa;
- 4) t — time, sec.

The output parameters (target variables) are:

- 1) s — thickness at the pole, m;
- 2) UY_1 — height at point 1 (inner surface), m;
- 3) UY_111 — height at point 111 (outer surface), m.

FINITE ELEMENT MODELING OF HEMISPHERE SUPERPLASTIC FORMING USING ANSYS

The simulation of the hemispherical SPF process was performed using the ANSYS CAE system. To reduce computational cost while maintaining result accuracy, a simplified axisymmetric model was used.

The mathematical model was implemented as a boundary value problem of creep theory based on the Norton model, which describes the dependence of the strain rate on stress. According to the chosen model, the parameters of the K and m models were adjusted to describe the superplastic behavior of the material.

The Latin Hypercube Sampling (LHS) method was used to determine the values of the material parameters K and m , essential for the model, within ranges typical for aluminum alloys.

The following mechanical properties of the aluminum alloy were used to determine its elastic characteristics:

- 1) Young's modulus (E) = 70 GPa;
- 2) Poisson's ratio (μ) = 0.34.

To implement the numerical model in ANSYS, solid models of the blank and the die were created. The blank was modeled as a deformable shell, while the cylindrical die was defined as a rigid tool that determines the final shape of the product. The modeling process began by defining their geometric dimensions. The modeling scheme is presented below (Fig. 1).

Compliance with the limitations of the student version of ANSYS 10 required optimization of the finite element mesh. For the blank model, 2112 four-node elements were determinate, distributed across four layers with 278 elements per layer. In the clamping zone, where deformations are insignificant, the mesh density was reduced to 25 elements per layer.

The initial mesh configuration (Fig. 2a) and its final state (Fig. 2b) after completion of the superplastic forming process through the cylindrical die are presented below (Fig. 2).

As can be seen from the Creep Strain Intensity distribution, the most critical zone in terms of localization of thinning is the dome pole (Fig. 3) of the hemisphere.

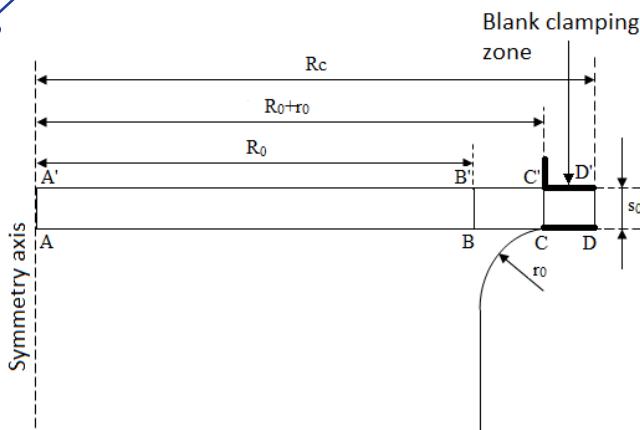
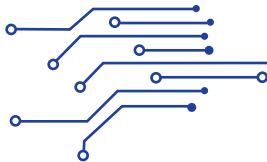


Fig. 1. Schematic Model of the Blank and Cylindrical Die: ACCA' – the Deformable Zone, CDD'C' – the Clamping Zone, R_0 – the Die Radius, r_0 – the Die Entrance Radius, R_c – the Blank Radius, s_0 – the Initial Blank Thickness

Source: Complied by the authors.

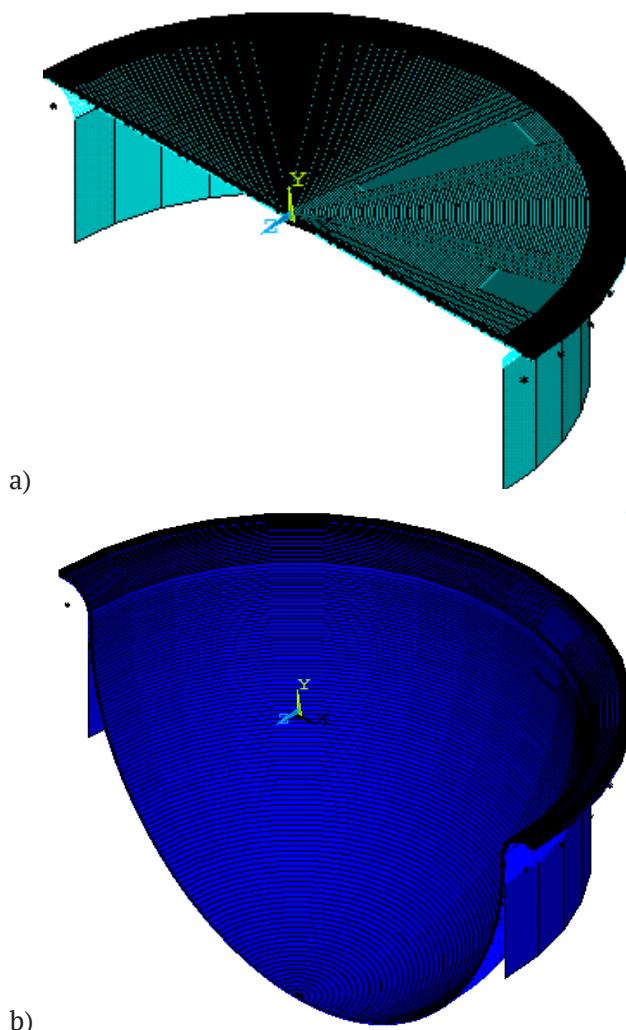


Fig. 2. Finite Element Mesh: a) in the Initial Configuration, and b) in the Final Deformed State

Source: Complied by the authors.

SELECTION AND APPLICATION OF THE MACHINE LEARNING METHOD

To develop a predictive model for the geometric characteristics of a hemisphere produced by the SPF process, the following machine learning methods were considered: artificial neural networks [12, 13], random forest [14], and Gaussian Process Regression (GPR) [15, 16].

The GPR method was selected for predicting the geometric characteristics of the hemisphere for the following reasons:

- It provides not only a point prediction but also a variance estimate, enabling the construction of confidence intervals and quantitative assessment of the model's reliability, which is crucial in engineering applications.
- Nonlinear dependencies between material parameters, process conditions, and the resulting geometry are effectively approximated by GPR through the selection of an appropriate kernel function.
- The method demonstrates high accuracy for interpolation within the researched parameter range.
- The algorithm is suitable for training a model in conditions of a limited amount of data, which is typical for resource-intensive CAE simulations and shows more stable performance than deep neural networks.

To model complex relationships in the data, a kernel composed of the following components was selected [17]:

1. Radial Basis Function (RBF) kernel was used to model smooth, non-linear dependencies. This is appropriate because the SPF process is continuous, and its characteristics evolve smoothly with changes in input parameters.
2. ConstantKernel allows the model to automatically adjust the prediction scale to account for the actual variance in the data. This is necessary because the target parameters (height, thickness) vary within specific ranges.
3. WhiteKernel was incorporated to account for random errors inherent in the finite element modeling results, which are influenced by mesh density, time step, numerical solution methods, and other factors.

The kernels hyperparameters were optimized using the RandomizedSearchCV algorithm, which performed ten iterations with 2-fold cross-validation for the initial exploration of the parameter space.

The following methodology was applied to ensure the stability of the model:

1. RobustScaler was applied to scale all input features and output target variables to a comparable range. Unlike StandardScaler, it is more resistant to abnormal values, which are often found in real data and CAE simulations due to the use of median and interquartile range.

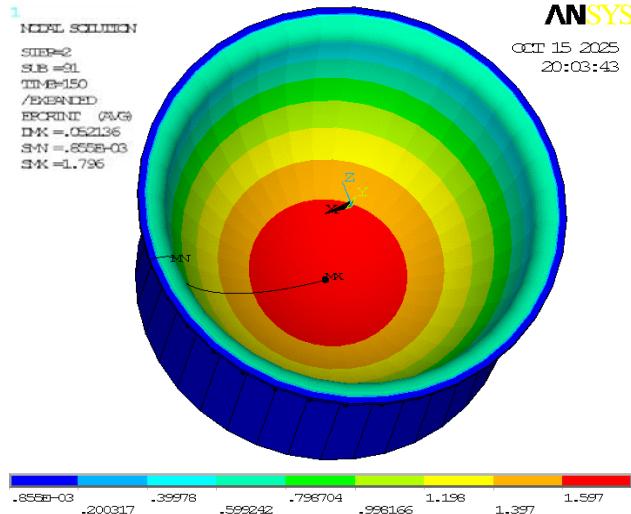


Fig. 3. Localization of Deformation and Thinning in the Pole of the Hemisphere Dome

Source: Complied by the authors.

2. A combination of the alpha parameter (from $1e-8$ to $1e-2$) to protect against overfitting and the WhiteKernel trainable core so that the algorithm can independently estimate the noise level in the data during training.

3. The optimizer was configured with multiple restarts (`n_restarts_optimizer=5`). This strategy initializes the optimization process from different starting points to increase the probability of locating the global maximum of the likelihood function.

4. Three-stage data separation: creation of a training sample (60% of the total data), a validation sample (20%) and a test sample (20%).

5. Cross-validation to assess the generalizing ability of the model and its ability to predict on new data.



RESEARCH RESULTS

The effectiveness of the developed Gaussian process model was evaluated using standard regression analysis metrics: Mean Squared Error (MSE) and the coefficient of determination (R^2).

These metrics were calculated using the following formulas:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2,$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2},$$

where y_i — is the actual value of the target variable; \hat{y}_i — is the value predicted by the model; \bar{y}_i — is the mean of the actual y values, calculated for the same sample used to compute R^2 .

The total initial dataset comprised 6250 samples, which were partitioned into three subsets:

- 1) 3750 samples (60%) for training;
- 2) 1250 samples (20%) for validation;
- 3) 1250 samples (20%) for testing.

Following hyperparameter optimization, the final Gaussian process kernel was determined as:

$$5.382 \times \text{RBF}(\text{length_scale} = 0.145) + \text{WhiteKernel}(\text{noise_level} = 1e-05).$$

The results of the evaluation of the forecasting model based on training, validation, and test samples are shown in *Table*.

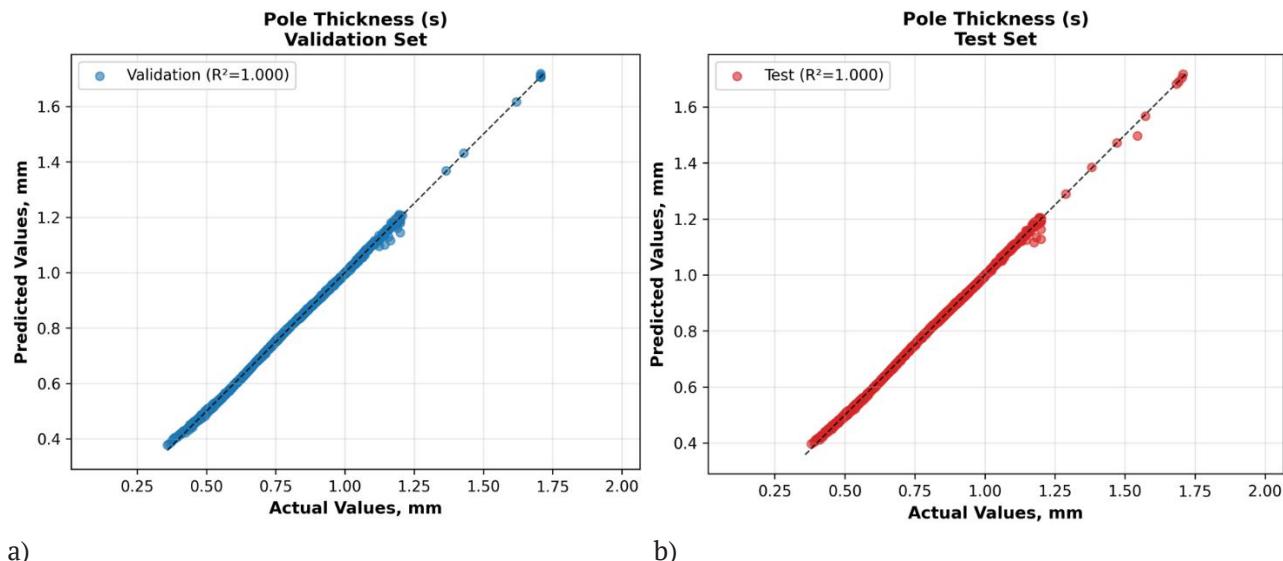
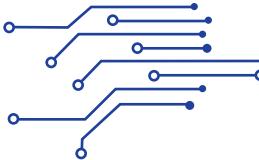
The models performance during each hyperparameter optimization stage was assessed based on the coefficient of determination (R^2) calculated on the validation dataset. The model's final predictive

Table

Results of Gaussian Process Prediction for Hemispherical Geometric Characteristics

Target variable	Dataset	MSE, mm^2	R^2
Thickness (s)	Training	1.44×10^{-5}	—
	Validation	2.56×10^{-5}	0.9996
	Test	2.84×10^{-5}	—
Average height (h_{avg})	Training	0.065	—
	Validation	0.112	0.9994
	Test	0.124	—
Height difference (Δh)	Training	1.44×10^{-5}	—
	Validation	2.35×10^{-5}	0.9996
	Test	2.46×10^{-5}	—

Source: Complied by the authors.

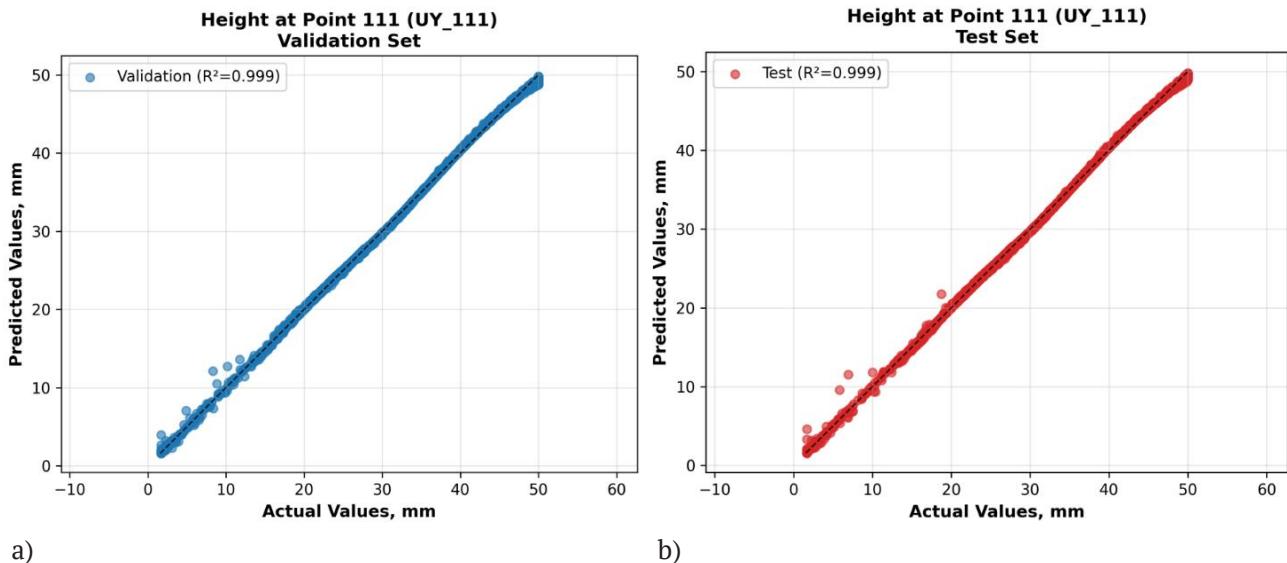


a)

b)

Fig. 4. Comparison of Actual Versus Predicted Thickness Values, s (mm): a) Validation Set, b) Test Set

Source: Complied by the authors.



a)

b)

Fig. 5. Comparison of Actual Versus Predicted Height Values at Point UY 111: a) Validation Set; b) Test Set

Source: Complied by the authors.

ability was evaluated on the test set using the mean squared error (MSE).

Prediction accuracy was visualized using scatter plots (Figs. 4, 5), comparing actual (x-axis) versus GPR-predicted (y-axis) values. The proximity of points to the $y=x$ bisector indicates model performance, with separate validation and test plots for thickness (Fig. 4) and height (Fig. 5). Point color intensity represents absolute error magnitude.

Two GPR prediction plots with confidence intervals were generated to visualize model uncertainty:

- 1) thickness (s) with confidence intervals (Fig. 6a);
- 2) height UY_1 with confidence intervals (Fig. 6b).

Both plots display time on a logarithmic scale.

DISCUSSION OF RESULTS

The results presented in *Table* demonstrate the performance of the GPR model for predicting the geometric characteristics of a hemisphere after superplastic forming. Analysis of the metrics reveals the following:

1. The MSE on the training set is slightly lower than on the validation and test sets, which is normal and indicates some degree of memorization of the training data. The nearly identical MSE values on the validation and test sets signify that the model has learned the underlying patterns rather than merely memorizing noise or specific cases from the training set.

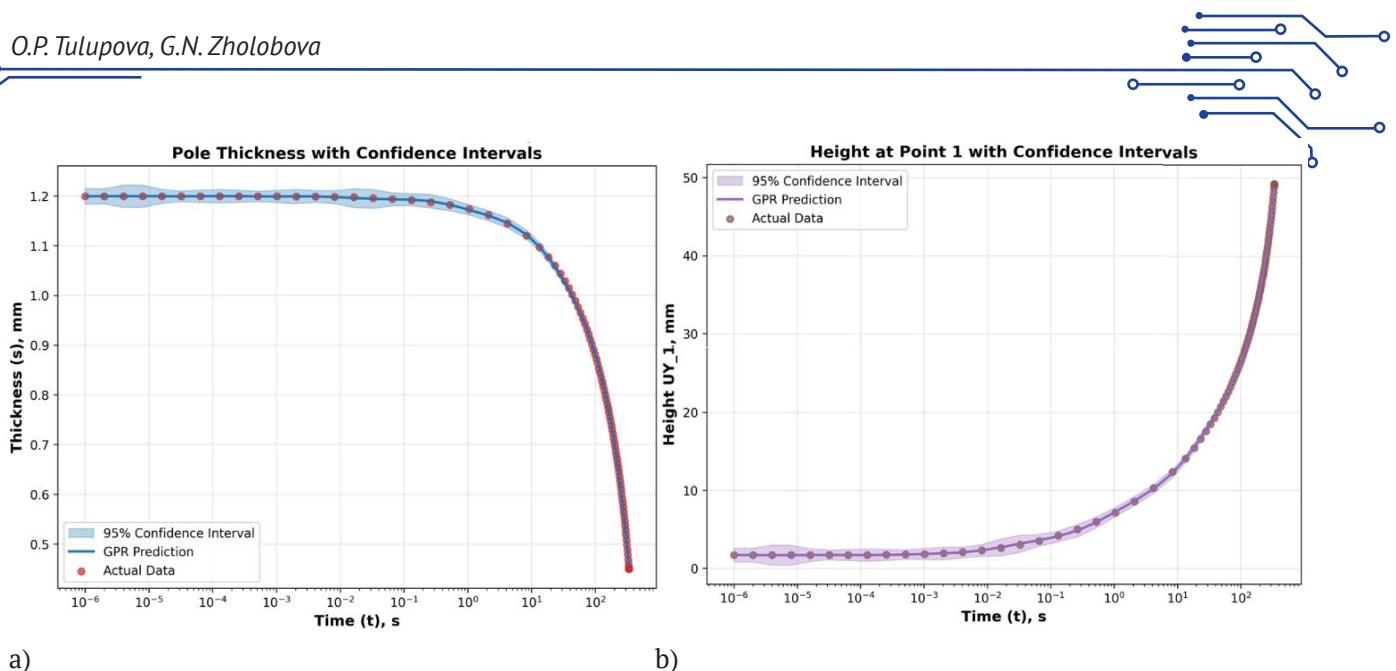


Fig. 6. GPR Uncertainty Plots for a Test Dataset Instance with Parameters $m = 0.471$, $K = 203.0 \text{ MPa}\cdot\text{s}^m$, $p = 0.29 \text{ MPa}$: a) Thickness Confidence Interval at Dome Pole; b) Height Confidence Interval at Location UY_1

Source: Complied by the authors.

2. Analysis by target variables thickness (s), average height (h_{avg}), and height difference (Δh) with a validation set score of $R^2 \approx 0.9996$, indicates that the model explains approximately 99.96% of the variance in the target variable.

Analysis of the scatter plots (Figs. 4, 5) demonstrates that the GPR model is generally accurate and adequate, as evidenced by the dense point cloud along the bisector down to a thickness of 1.2 mm, which corresponds to the initial blank thickness.

The confidence intervals (Fig. 6) reveal a technological window where stable results can be expected. The consistent positioning of actual data points within the central region of these intervals indicates a controllable and robust process.

The wider confidence interval at the process onset likely reflects inherent uncertainty during the initial stage, potentially associated with challenges in simula-

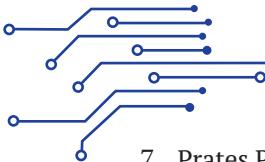
ting the early phase where plastic deformation just begins to develop in the material. The subsequent narrowing of the interval suggests that the deformation process has stabilized, exhibiting highly predictable behavior that is well-captured by the selected material model.

CONCLUSIONS

The developed Gaussian process model demonstrated high accuracy and reliability in predicting the geometry of hemispheres produced by superplastic forming. The high values $R^2 \approx 0.9996$ and the close agreement between errors on the validation and test sets confirm that the model successfully learned the underlying physical relationships without overfitting. Analysis of scatter plots and confidence intervals indicates a controllable and robust process, with the model adequately capturing its physics, particularly during the stable deformation phase.

REFERENCES

1. Sorgente D.S. Superplasticity and Superplastic Forming. *Metals*. 2021;1(6):946. DOI: 10.3390/met11060946
2. Aksenov S.A., Mikolaenko V. Accurate determination of uniaxial flow behaviour of superplastic materials. *European Journal of Mechanics, A/Solids*. 2025;(109):105469. DOI: 10.1016/j.euromechsol.2024.105469
3. Mahajan A., Badheka V. Engineering Applications of Superplasticity of Metals: Review. In: Bhingole P., Joshi K., Yadav S.D., Sharma A., eds. *Advances in Materials Engineering. ICFAMMT 2024. Lecture Notes in Mechanical Engineering*. Select Proceedings of ICFAMMT 2024, Springer, Singapore. 2025;245-257. DOI: 10.1007/978-981-97-7114-1_20
4. Tulupova O.P., Gumerova C. et al. Improving the accuracy of finite element modeling of superplastic forming processes. *Lett. Mater.* 2022;12(2):142-147. DOI: 10.22226/2410-3535-2022-2-142-147
5. Murzina G.R., Ganieva V.R., Enikeev F.U., Tulupova O.P. Software for calculating technological and geometric characteristics of the superplastic forming process. *International Journal of Open Information Technologies*. 2024;12(11):35-41. URL: <https://elibrary.ru/eibdia> (In Russ.).
6. Giuliano G., Polini W. FEM Analysis of Superplastic-Forming Process to Manufacture a Hemispherical Shell. *Appl. Sci.* 2025;15(14):8080. DOI: 10.3390/app15148080



7. Prates P.A., Pereira A.F. Recent advances and applications of machine learning in metal forming processes. *Metals*. 2022;12(8):1342. DOI: 10.3390/met12081342
8. Mosleh A.O., Kotov A.D. et al. Characterization of Superplastic Deformation Behavior for a Novel Al-Mg-Fe-Ni-Zr-Sc Alloy: Arrhenius-Based Modeling and Artificial Neural Network Approach. *MDPI Applied Sciences*. 2021;11(5):2208. DOI: 10.3390/app11052208
9. Mishra S.K., Brahma A., Dutta K. Prediction of mechanical properties of Al-Si-Mg alloy using artificial neural network. *Sādhanā*. 2021;46:139. URL: <https://link.springer.com/article/10.1007/s12046-021-01660-x>
10. Sun M., Xiong C., Zhou Y. et al. Thickness Distribution Prediction of Superplastic Forming Parts Based on Machine Learning and Computer Aided Engineering. 2024 4th International Symposium on Artificial Intelligence and Intelligent Manufacturing (AIIM), Chengdu, China, 2024. 2024;827-830. DOI: 10.1109/AIIM64537.2024.10934610
11. Zogu P., Schäfer M. Reliability assessment of composite column according to Monte Carlo Simulation and Latin Hypercube Sampling. *E 3S Web of Conferences*. 2024;550(1):01037. DOI: 10.1051/e3sconf/202455001037
12. Lourenço R., Andrade-Campos A., Georgieva P. The Use of Machine-Learning Techniques in Material Constitutive Modelling for Metal Forming Processes. *Metals*. 2022;12:427. DOI: 10.3390/met12030427
13. Munzone F., Hazrati J., Hakvoort W., & van den Boogaard, T. Comparative study of artificial neural network and physics-informed neural network application in sheet metal forming. *Material Forming – ESAFORM 2024. Materials Research Proceedings*, 2024. 2024;41:2278-2288. DOI: 10.21741/9781644903131-251
14. Salman H.A., Kalakech A., Steiti A. Random forest algorithm overview. *Babylonian Journal of Machine Learning*. 2024;2024:69-79. DOI: 10.58496/BJML/2024/007
15. Wang J. An Intuitive Tutorial to Gaussian Process Regression. *Computing in Science & Engineering*. 2023;25(4):4-11. DOI: 10.1109/MCSE.2023.3342149
16. Zhang Z., Ikeura R., Hayakawa S., Wang Z. Ship Hull Steel Plate Deformation Modeling Based on Gaussian Process Regression. *Journal of Marine Science and Engineering*. 2024;12(12):2267. DOI: 10.3390/jmse12122267
17. Martinsen K., Hart-Rawung T., Holmestad J., Stendal, J. et al. Hybrid modelling predicting forming behavior with variations in AlMgSi1 alloys. *CIRP Annals*. 2025;74(1):369-373. DOI: 10.1016/j.cirp.2025.03.005

ABOUT THE AUTHORS / ИНФОРМАЦИЯ ОБ АВТОРАХ

Olga P. Tulupova — Cand. Sci. (Tech.), Assoc. Prof. of Artificial Intelligence Department of the Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

Ольга Павловна Тулупова — кандидат технических наук, доцент кафедры ИТ факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

<https://orcid.org/0000-0002-8621-0724>

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

Galina N. Zholobova — Cand. Sci. (Tech.), Assoc. Prof., Deputy Head of Artificial Intelligence Department for Academic Affairs of the Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

Галина Николаевна Жолобова — кандидат технических наук, доцент кафедры ИТ, заместитель заведующего кафедрой информационных технологий по учебной работе факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

<https://orcid.org/0009-0006-6082-1347>

gnzholobova@fa.ru

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

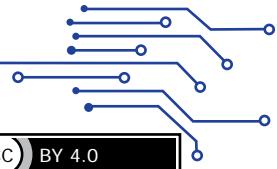
Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

The article was submitted on 13.10.2025; accepted for publication on 24.11.2025.

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

Статья поступила в редакцию 13.10.2025; принята к публикации 24.11.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.



ОРИГИНАЛЬНАЯ СТАТЬЯ



DOI: 10.26794/3033-7097-2025-1-4-51-59
УДК 004.738.5:343.62(045)

Безопасность несовершеннолетних пользователей в информационно-коммуникационной среде

С.Д. Семухин^a, В.В. Пахолюк^b, П.Д. Осина^c, Р.А. Кочкаров^d, С.А. Резниченко^e, Э.А. Окунева^f

^{a, e} Национальный исследовательский ядерный университет «МИФИ», Москва, Российская Федерация;
^{b, c, d, f} Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

Данная статья посвящена всестороннему анализу проблемы обеспечения цифровой безопасности несовершеннолетних в условиях стремительного развития информационного общества и цифровых технологий. Цель исследования состоит в выявлении нормативных, организационных и технологических механизмов защиты детей от информационных угроз, формирующихся в сети Интернет, включая деструктивный контент, кибербуллинг, вовлечение в противоправную деятельность и манипулятивные алгоритмы социальных сетей. Особое внимание уделено анализу правовых актов, регулирующих данную сферу, а также институциональной роли государственных органов и значимости образовательных инициатив. Методологическая основа исследования включает системный и междисциплинарный подходы, позволяющие учитывать юридические, социокультурные, педагогические и технологические аспекты проблемы. В процессе работы использовались методы контент-анализа нормативных документов, сравнительно-правовой анализ, а также обобщение практического опыта и данных социологических исследований. Ключевые результаты исследования заключаются в выявлении фрагментарности существующего законодательства и институциональных механизмов в сфере информационной безопасности несовершеннолетних, а также в обосновании необходимости построения комплексной многоуровневой модели защиты. Эта модель предполагает создание специализированного органа контроля, укрепление связей между школой, семьей и ребенком, а также внедрение современных технических решений для фильтрации и контроля цифрового контента. Выводы исследования подчеркивают важность комплексного подхода к решению обозначенной проблемы, необходимость скоординированного межведомственного взаимодействия, развития цифровой грамотности всех участников образовательного процесса, а также совершенствования правового регулирования. Представленные в статье рекомендации и инициативы могут быть использованы при формировании государственной политики в сфере цифровой безопасности, разработке образовательных программ и инструментов защиты детей в онлайн-среде.

Ключевые слова: цифровая безопасность; несовершеннолетние; правовое регулирование; информационные угрозы; интернет; фильтрация контента; родительский контроль

Для цитирования: Семухин С.Д., Пахолюк В.В., Осина П.Д., Кочкаров Р.А., Резниченко С.А., Окунева Э.А. Безопасность несовершеннолетних пользователей в информационно-коммуникационной среде. Цифровые решения и технологии искусственного интеллекта. 2025;1(4):51-59. DOI: 10.26794/3033-7097-2025-1-4-51-59

ORIGINAL PAPER

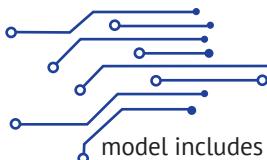
Safety of Underage Users in the Information and Communication Environment

S.D. Semukhin^a, V.V. Pakholyuk^b, P.D. Osina^c, R.A. Kochkarov^d, S.A. Reznichenko^e, E.A. Okuneva^f

^{a, e} National Research Nuclear University “MEPhI”, Moscow, Russian Federation;
^{b, c, d, f} Financial University under the Government of the Russian Federation, Moscow, Russian Federation

ABSTRACT

This article presents a comprehensive analysis of the issue of ensuring digital safety for minors in the context of the rapid development of the information society and digital technologies. The objective of the study is to identify the legal, organizational, and technological mechanisms for protecting children from informational threats emerging in the online environment, including harmful content, cyberbullying, involvement in illegal activities, and manipulative algorithms of social media platforms. Special attention is given to the analysis of legal regulations governing this area, the institutional role of state authorities, and the importance of educational initiatives. The methodological basis of the study includes a systematic and interdisciplinary approach, taking into account the legal, sociocultural, pedagogical, and technological dimensions of the problem. The research employs methods such as content analysis of legal documents, comparative legal analysis, as well as synthesis of practical experience and sociological data. The key findings of the study highlight the fragmented nature of current legislation and institutional mechanisms in the field of digital safety for minors. The study substantiates the need for the development of a comprehensive multi-level protection model. This



model includes the establishment of a specialized supervisory body, strengthening cooperation between schools, families, and children, and implementing modern technological tools for filtering and monitoring digital content. The conclusions of the article emphasize the importance of an integrated approach to addressing the identified problem, the need for coordinated interagency cooperation, the promotion of digital literacy among all participants in the educational process, and the improvement of legal frameworks. The recommendations and initiatives presented in this study may serve as a foundation for the development of public policy in the area of digital safety, the design of educational programs, and the implementation of child protection tools in the online environment.

Keywords: digital safety; minors; legal regulation; informational threats; Internet; content filtering; parental control

For citation: Semukhin S.D., Pakholyuk V.V., Osina P.D., Kochkarov R.A., Reznichenko S.A., Okuneva E.A. Safety of underage users in the information and communication environment. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(4):51-59. DOI: 10.26794/3033-7097-2025-1-4-51-59

ВВЕДЕНИЕ

Современное общество стремительно развивается в направлении цифровизации всех сфер жизнедеятельности. Особую актуальность в этом контексте приобретает проблема обеспечения информационной безопасности несовершеннолетних. С каждым годом увеличивается вовлеченность детей и подростков в интернет-пространство, что сопровождается ростом рисков, связанных с воздействием вредоносного контента, интернет-мошенничеством, психологическим манипулированием и нарушением их прав на неприкосновенность частной жизни.

Несмотря на то, что цифровые технологии представляют широкие возможности для обучения, социализации и саморазвития, они одновременно создают новые угрозы, с которыми несовершеннолетние не всегда в состоянии справиться самостоятельно. Поэтому возникает необходимость в системной защите детей в цифровой среде, включающей как нормативно-правовое регулирование, так и практические механизмы профилактики и вмешательства.

Цель исследования состоит в выявлении нормативных, организационных и технологических механизмов защиты детей от информационных угроз, формирующихся в сети Интернет.

ПРАВОВЫЕ ОСНОВЫ ЗАЩИТЫ НЕСОВЕРШЕННОЛЕТНИХ В ЦИФРОВОЙ СРЕДЕ

Правовая защита несовершеннолетних в цифровой среде в Российской Федерации опирается на комплекс федеральных законов, международных соглашений и подзаконных актов, регулирующих вопросы информационной безопасности, прав ребенка и ограничения доступа к вредоносной информации. Среди ключевых документов можно выделить:

- Федеральный закон № 149-ФЗ «Об информации, информационных технологиях и о защите информации»¹;

- Федеральный закон № 436-ФЗ «О защите детей от информации, причиняющей вред их здоровью и развитию»²;

- Федеральный закон № 124-ФЗ «Об основных гарантиях прав ребенка в Российской Федерации»³;

- Концепция информационной безопасности детей, утвержденная в 2015 году⁴;

- Конвенция о правах ребенка (1989), ратифицированная Российской Федерацией⁵;

- Приказ Минкомсвязи России № 161 от 16.06.2014⁶.

Однако, несмотря на наличие нормативной базы, значительная часть этих документов не содержит четко определенных механизмов привлечения к ответственности лиц, наносящих вред несовершеннолетним в интернете. Это порождает правовые лакуны и затрудняет применение законодательства на практике.

Особую тревогу вызывает активность злоумышленников в социальных сетях, которые с легкостью выходят на контакт с детьми, используя их довер-

ях и о защите информации». URL: https://www.consultant.ru/document/cons_doc_LAW_61798/ (дата обращения: 13.02.2023).

² Федеральный закон от 29.12.2010 № 436-ФЗ (ред. от 01.07.2021) «О защите детей от информации, причиняющей вред их здоровью и развитию». URL: https://www.consultant.ru/document/cons_doc_LAW_108808/ (дата обращения: 13.02.2023).

³ Федеральный закон от 24.07.1998 № 124-ФЗ «Об основных гарантиях прав ребенка в Российской Федерации» (последняя редакция). URL: https://www.consultant.ru/document/cons_doc_LAW_19558/ (дата обращения: 13.02.2023).

⁴ Концепция информационной безопасности детей (2015 г.). URL: <http://static.government.ru/media/files/mPbAMyJ29uSPhL3p20168GA6hv3CtBxD.pdf> (дата обращения: 13.02.2023).

⁵ Конвенция о правах ребёнка (одобрена Генеральной Ассамблеей ООН 20.11.1989, вступила в силу для СССР 15.09.1990). URL: https://www.consultant.ru/document/cons_doc_LAW_9959/ (дата обращения: 13.02.2023).

⁶ Приказ Минкомсвязи России от 16.06.2014 № 161 «Об утверждении требований к административным и организационным мерам, техническим и программно-аппаратным средствам защиты детей от информации, причиняющей вред их здоровью и (или) развитию». URL: <https://digital.gov.ru/documents/4446/> (дата обращения: 13.02.2023).

¹ Федеральный закон от 27.07.2006 № 149-ФЗ (ред. от 30.12.2021) «Об информации, информационных технологи-



чивость и недостаток критического мышления, получение личной информации путем обмана, вовлечение в деструктивные сообщества, а также распространение вредоносного контента [1].

Цифровая реклама представляет собой еще один значимый источник информационного давления на несовершеннолетних [2, 3, 4]. Она появляется не только в браузерах, но и во всех цифровых устройствах — смартфонах, планшетах, телевизорах с выходом в интернет. Под видом развлекательного контента рекламодатели продвигают товары и идеи, к которым дети могут оказаться не готовы ни интеллектуально, ни эмоционально (рис. 1–3).

На данный момент регулирование рекламного контента в детской цифровой среде остается фрагментарным. Отсутствуют действенные инструменты идентификации и блокировки скрытой рекламы, направленной на манипуляцию детским

поведением. В результате несовершеннолетние становятся уязвимой целевой аудиторией, подверженной потребительским и психологическим установкам, формируемым через рекламные алгоритмы.

Защита прав и интересов детей в цифровой среде входит в компетенцию сразу нескольких государственных органов, каждый из которых действует в рамках своей сферы ответственности. Среди них:

- Роскомнадзор, осуществляющий надзор за соблюдением законодательства в сфере связи, информационных технологий и защиты персональных данных.
- Рособрнадзор, контролирующий образовательные учреждения и внедрение цифровых платформ в обучении.
- Роспотребнадзор, отвечающий за защиту прав потребителей, в том числе в цифровой среде.

❓ Как вы относитесь к различным форматам рекламы?

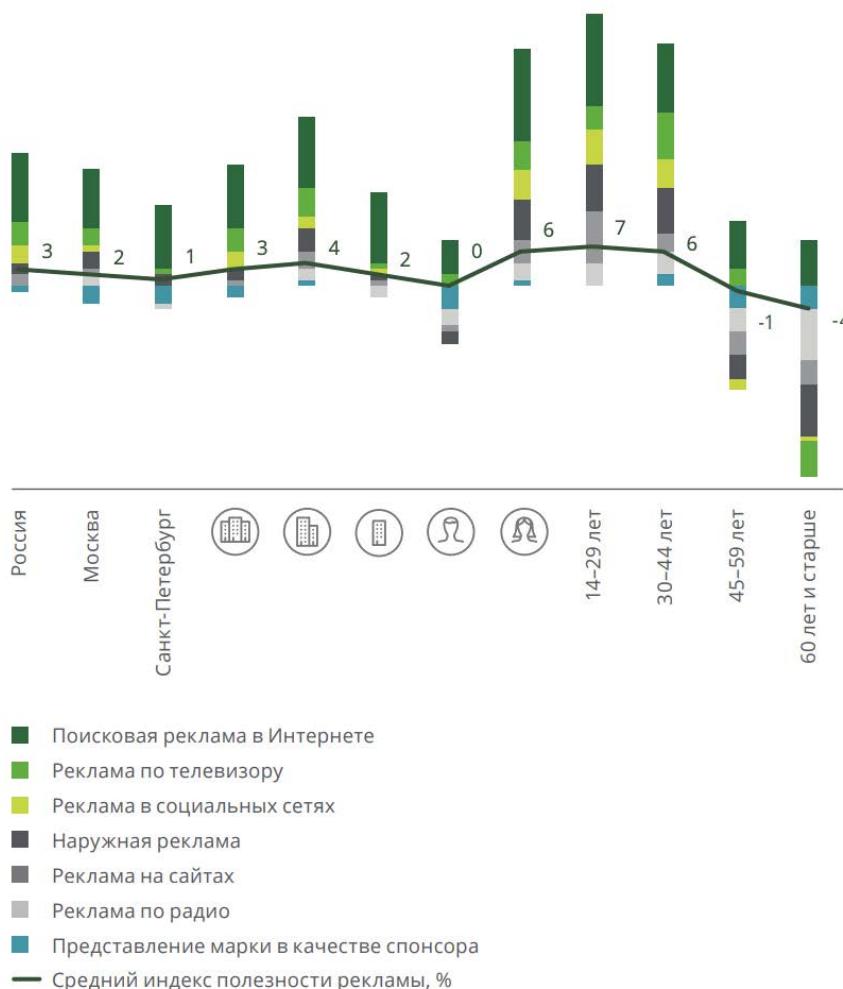


Рис. 1 / Fig. 1. Лояльность к различным форматам рекламы среди возрастных групп / Loyalty to Different Advertising Formats among Age Groups

Источник / Source: исследовательский центр компании «Делойт» в СНГ / Deloitte CIS Research Center [3].

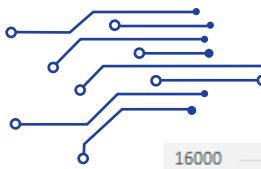


Рис. 2 / Fig. 2. Демографическое распределение населения России по возрасту (2021) /
Demographic Distribution of the Russian Population by Age (2021)

Источник / Source: Информационно-статистический портал InfoTables / InfoTables. URL: <https://infotables.ru/statistika/31-rossijskaya-federatsiya/783-raspredelenie-naseleniya-po-vozrastnym-gruppam-tablitsa>

% от группы населения, вся Россия, среднемесячный охват за февраль-ноябрь 2020

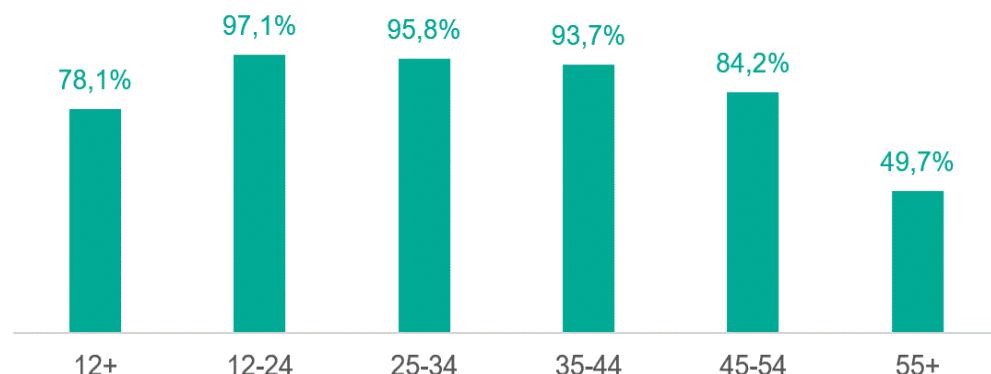


Рис. 3 / Fig. 3. Возрастная структура аудитории интернета в России / Age Structure of Internet Audience in Russia

Источник / Source: исследовательская компания Mediascope / Mediascope Research Company [4]

❓ Из каких источников Вы чаще всего узнаете новости? (%)

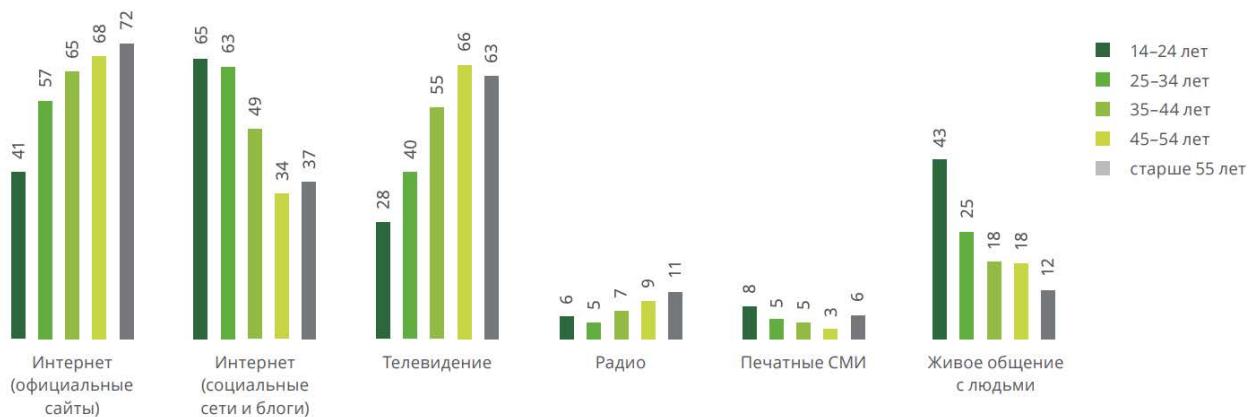


Рис. 4 / Fig. 4. Использование медиаконтента разными возрастными группами / Use of Media Content by Different Age Groups

Источник / Source: исследовательский центр компании «Делойт» в СНГ / Deloitte CIS Research Center [3].



- Министерство просвещения, разрабатывающие методические рекомендации и образовательные программы, включая темы цифровой грамотности.

Несмотря на вовлеченность различных ведомств, их усилия не объединены в единую координированную систему. Отсутствие межведомственного взаимодействия приводит к дублированию функций и снижает общую эффективность работы по обеспечению цифровой безопасности детей. Следовательно, необходим комплексный подход, основанный на координации, обмене данными и общей стратегии защиты.

МОДЕЛЬ ЗАЩИТЫ НЕСОВЕРШЕННОЛЕТНИХ В ЦИФРОВОЙ СРЕДЕ

Для преодоления разрозненности и повышения эффективности предлагается внедрение модели многоуровневой защиты несовершеннолетних в цифровой среде. Эта модель включает три ключевых уровня.

1. Формирование связи «родители — школа — ребенок». Цифровая социализация детей невозможна без активного участия взрослых. Родители и педагоги должны обладать знаниями и навыками, необходимыми для сопровождения детей в цифровом пространстве.

2. Технические алгоритмы фильтрации контента. Необходима разработка и внедрение программных решений, которые позволяют ограничивать доступ к вредоносной информации на всех устройствах, используемых несовершеннолетними (рис. 5) [5].

Это включает использование интеллектуальных фильтров, систем родительского контроля и сотрудничество с крупными ИТ-компаниями.

В рамках рассматриваемого проекта авторами были реализованы следующие инициативы, направленные на повышение цифровой безопасности несовершеннолетних:

- разработан обучающий веб-сайт, включающий видеокурсы и инструкции для родителей, касающиеся защиты детей в интернете [6];
- создан Telegram-бот, предоставляющий рекомендации и экстренные меры в случае выявления потенциальной угрозы⁷.

Эти инструменты позволяют оперативно реагировать на информационные угрозы, а также обеспечивают доступ к проверенным знаниям о безопасности в сети.

Отдельного внимания заслуживает феномен видеохостинга TikTok и других социальных плат-

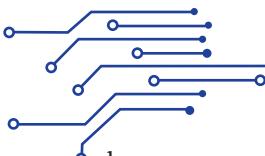
⁷ Родительский контроль ИБ21-4. URL: <https://web.telegram.org/z/#2108045873>; Telegram: @TestbotIB 214fu_bot.

РЕКОМЕНДУЕМОЕ ПОТРЕБЛЕНИЕ В ДЕНЬ



Рис. 5 / Fig. 5. Рекомендуемое потребление цифрового контента по категориям в течение дня (пирамида контента) / Recommended Consumption of Digital Content by Category throughout the Day (Content Pyramid)

Источник / Source: онлайн-журнал «Лайфхакер» / Lifehacker.ru [5].



форм, чьи алгоритмы персонализированной ленты способны формировать новые установки, вкусы и поведенческие модели. Пользователь сам не замечает, как оказывается в информационном пузыре, где его интересы подкрепляются визуальным контентом, эмоционально окрашенным и зачастую деструктивным [1].

Особенно подвержены подобному воздействию подростки, находящиеся в процессе формирования идентичности. Алгоритмы могут не только подстроиться под интересы пользователя, но и усилить его тревожность, внушить искаженные представления о себе и мире [7]. Это создает угрозу психологическому и ментальному здоровью детей, делая необходимым государственный и общественный контроль над алгоритмическими системами.

Одним из препятствий на пути к эффективной защите детей в цифровой среде является культурный разрыв между поколениями. Родители, выросшие в доцифровую эпоху, зачастую опираются на постфигуративные модели воспитания, которые не учитывают реалии сетевой жизни [8]. Между тем дети проводят в интернете значительную часть времени, формируя там не только круг общения, но и мировоззрение.

Отсутствие понимания между поколениями приводит к тому, что взрослые либо чрезмерно ограничивают доступ к сети, вызывая протест, либо, напротив, полностью игнорируют происходящее. Оба подхода неэффективны и требуют пересмотра в сторону сотрудничества и совместного освоения цифровой среды.

3. Создание специализированного координационного органа по цифровой безопасности детей (например, Федеральной службы по детскому информационному контролю — ФСДИК).

В условиях стремительного развития цифровых технологий и усложнения структуры информационного пространства становится все более очевидной необходимость формирования специализированного государственного органа, деятельность которого будет направлена исключительно на обеспечение цифровой безопасности несовершеннолетних. Предлагаемое учреждение, условно обозначаемое как Федеральная служба по детскому информационному контролю (ФСДИК), должно выполнять не карательную, а превентивную, координационную и образовательную функции. В отличие от уже существующих органов, таких как Роскомнадзор, Роспотребнадзор или Минпросвещения, новый институт должен обладать узкой, но глубокой специализацией, касающейся исключительно защиты детей в цифровой среде.

Основной задачей ФСДИК станет непрерывный мониторинг интернет-пространства с акцентом на выявление потенциально опасных информационных источников, таких как сайты с деструктивным контентом, группы в социальных сетях, распространяющие радикальные или манипулятивные идеи, а также платформы, провоцирующие девиантное поведение у подростков. Особое внимание может уделяться отслеживанию новых форм цифрового насилия, включая кибербуллинг, груминг, шантаж, цифровое преследование и вовлечение несовершеннолетних в противоправные действия.

Второе направление работы предполагает разработку методических материалов и рекомендаций для широкого круга адресатов: родителей, педагогов, администраторов образовательных учреждений, представителей IT-индустрии и контент-платформ. Эти рекомендации должны носить не только информационный, но и прикладной характер, включая чек-листы для оценки цифровой среды, инструкции по настройке фильтров и алгоритмы реагирования на критические ситуации. Такой подход обеспечит доступность и применимость знаний на практике [9].

ФСДИК также может выполнять аналитическую функцию, формируя предложения по совершенствованию действующего законодательства. Учитывая динамичность цифровой среды, необходимо регулярно адаптировать правовые нормы, выявлять пробелы в законодательстве и разрабатывать новые регулятивные механизмы. В этом контексте служба может стать связующим звеном между экспертным сообществом, законодателями и органами исполнительной власти.

Не менее важной задачей нового органа станет реализация масштабных просветительских и обучающих программ. Подобные кампании могут включать национальные информационные недели, цифровые марафоны, выпуск видеоконтента и проведение онлайн-курсов, ориентированных на родителей, школьников и учителей [10]. Это позволит не только повысить общий уровень цифровой грамотности, но и сформировать у подрастающего поколения навыки критического мышления, саморегуляции и ответственного поведения в сети.

Наконец, при разработке концепции и структуры ФСДИК важно учесть вопросы этики, соблюдения прав ребенка, неприкосновенности личной жизни и соразмерности вмешательства. Орган должен действовать в логике партнерства с гражданским обществом, ИТ-компаниями и международ-



ными организациями, обеспечивая прозрачность своих действий и открытость к диалогу. В этом случае он сможет не только оперативно реагировать на цифровые угрозы, но и стать основой устойчивой и гуманной системы защиты детей в быстро меняющемся информационном мире.

ВЫВОДЫ

Таким образом, проблема информационной безопасности несовершеннолетних в цифровом пространстве является многогранной и требует междисциплинарного подхода. Необходимо не

только совершенствовать законодательную базу и вводить технические ограничения, но и формировать культуру цифровой грамотности среди всех участников образовательного и семейного процесса.

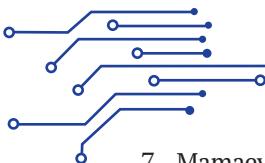
Создание комплексной системы защиты с четким распределением ответственности между государством, обществом и семьей позволит обеспечить условия для безопасного, развивающего и гуманного информационного пространства, в котором подрастающее поколение сможет реализовывать свои возможности без угрозы своему благополучию.

СПИСОК ИСТОЧНИКОВ

1. Фефелов А., Афанасьев А. Дети Интернета: что они смотрят и кто ими управляет. М.: Изд-во «Наше завтра»; 2021. 314 с. URL: <https://djvu.online/file/CJ7HiFQB4Ysxx?ysclid=mj6l7w5e2v860671556>
2. Полякова Т.А. Цифровизация и синергия правового обеспечения информационной безопасности. *Информационное право*. 2019;2(60):4–7. URL: <https://elibrary.ru/item.asp?id=39173932>
3. Табакова О., Шульга А., Родионова В. и др. Медиапотребление в России – 2021. Исследовательский центр компании «Делойт» в СНГ. URL: <https://nlr.ru/reader/dep/artupload/reader/article/RA6550/NA65935.pdf>
4. Пикулева М. Аудитория Интернета в России в 2020 году. Mediascope. URL: <https://mediascope.net/news/1250827/>
5. Евстафьева Е. Как сесть на здоровую информационную диету. Лайфхакер. 28.07.2018. URL: <https://lifehacker.ru/informacionnaya-dieta/>
6. Лазарев Д., Семухин С., Амитин М., Левченко Д. Родительский контроль. URL: <https://festive-stonebraker-ecb381.netlify.app/>
7. Мамаева А.Е. Меры предупреждения вовлечения несовершеннолетних посредством сети Интернет. Проблемы квалификации ст. 150 УК РФ. *Вопросы российского и международного права*. 2022;12(2A):236–242. DOI: 10.34670/AR.2022.12.36.027
8. Андреева Д.А. Проблема детско-родительских отношений в транзитивном обществе. *Психологическая наука и образование*. 2016;7(31):12–20. URL: <https://www.elibrary.ru/whycz>
9. Степанова Н.А. Обеспечение информационной безопасности детей в цифровом пространстве. *Гуманитарные исследования Центральной России*. 2024;1(30):60–77. DOI: 10.24412/2541-9056-2024-130-59-77
10. Боровских В.А., Петрова С.С. Формирование безопасного поведения в интернете у младших школьников. *Мир педагогики и психологии*: международный научно-практический журнал. 2023;04(81). URL: <https://scipress.ru/pedagogy/articles/formirovanie-bezopasnogo-povedeniya-v-internete-u-mladshikh-shkolnikov.html>

REFERENCES

1. Fefelov A., Afanasiev A. Children of the Internet: What They Watch and Who Controls Them. Moscow: Publishing House “Nashe vremia”; 2021. 314 p. URL: <https://djvu.online/file/CJ7HiFQB4Ysxx?ysclid=mj6l7w5e2v860671556> (In Russ.).
2. Polyakova T.A. Digitalization and Synergy of Legal Support for Information Security. *Information Law*. 2019;2(60):4–7. URL: <https://elibrary.ru/item.asp?id=39173932> (In Russ.).
3. Tabakova O., Shulga A., Rodionova V. et al. Media consumption in Russia – 2021. Research Center of Deloitte CIS. URL: <https://nlr.ru/reader/dep/artupload/reader/article/RA6550/NA65935.pdf> (In Russ.).
4. Pikuleva M. Internet Audience in Russia in 2020. Mediascope. URL: <https://mediascope.net/news/1250827/> (In Russ.).
5. Evstafieva E. How to Start a Healthy Information Diet. Livehacker. 28.07.2018. URL: <https://lifehacker.ru/informacionnaya-dieta/> (In Russ.).
6. Lazarev D., Semukhin S., Amitin M., Levchenko D. Parental control. URL: <https://festive-stonebraker-ecb381.netlify.app/> (In Russ.).



7. Mamaeva A.E. Measures to prevent the involvement of minors through the Internet. Problems of qualification Art. 150 of the Criminal Code of the Russian Federation. *Voprosy rossiiskogo i mezhdunarodnogo prava*. 2022;12(2A):236–242. (In Russ.). DOI: 10.34670/AR.2022.12.36.027
8. Andreeva D.A. The Problem of Parent-Child Relationships in a Transitive Society. *Psychological Science and Education*. 2016;7(31):12–20. URL: <https://www.elibrary.ru/whycyz> (In Russ.).
9. Stepanova N.A. Ensuring the information security of children in the digital space. *Humanities researches of the Central Russia*. 2024;1(30):60–77. (In Russ.). DOI: 10.24412/2541-9056-2024-130-59-77
10. Borovskikh V.A., Petrova S.S. Formation of safe behavior on the Internet among younger schoolchildren. *Mir pedagogiki i psichologii: International Scientific Journal*. 2023;04(81). URL: <https://scipress.ru/pedagogy/articles/formirovaniye-bezopasnogo-povedeniya-v-internete-u-mladshikh-shkolnikov.html> (In Russ.).

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Сергей Дмитриевич Семухин — студент программы магистратуры, Национальный исследовательский ядерный университет «МИФИ», Москва, Российская Федерация

Sergey D. Semukhin — Master Programme Student, National Research Nuclear University “MEPhI”, Moscow, Russian Federation

<https://orcid.org/0000-0002-2622-5879>

semukhin.serezha@mail.ru

Владимир Всеволодович Пахолюк — студент программы бакалавриата факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Vladimir V. Pakholiuk — Bachelor Programme Student, Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0009-0002-2758-1127>

237521@edu.fa.ru

Полина Дмитриевна Осина — студентка программы бакалавриата факультета информационных технологий и анализа больших данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Polina D. Osina — Bachelor Programme Student, Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0009-0000-8187-0937>

polina.osina005@gmail.com

Расул Ахматович Кочкаров — кандидат экономических наук, 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.), 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

Сергей Анатольевич Резниченко — кандидат технических наук, доцент, доцент кафедры стратегии и технологии кибербезопасности Института интеллектуальных кибернетических систем, Национальный исследовательский ядерный университет «МИФИ», Москва, Российская Федерация

Sergey A. Reznichenko — Cand. Sci. (Tech.), Assoc. Prof., Assoc. Prof. of Cybersecurity Strategy and Technologies Department of the Institute of Intelligent Cybernetic Systems, National Research Nuclear University “MEPhI”, Moscow, Russian Federation

<https://orcid.org/0000-0002-1539-0457>

rsa_5@bk.ru



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

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:

С.Д. Семухин — концепция исследования, обзор литературы, написание первоначального варианта текста (введение, часть аналитического раздела).

В.В. Пахолюк — сбор и анализ статистических данных, разработка и описание технических инструментов (веб-сайт, Telegram-бот).

П.Д. Осина — анализ нормативно-правовой базы, сравнительно-правовой анализ, работа над разделом о государственном регулировании.

Р.А. Кочкаров — научное руководство, методология исследования, критический анализ и доработка текста, формулировка выводов.

С.А. Резниченко — координация работы над статьей, консультирование по технологическим аспектам безопасности, анализ алгоритмов фильтрации контента, рецензирование.

Э.А. Окунева — финальное редактирование и оформление, подготовка аннотаций и ключевых слов, список литературы.

Authors' declared contributions:

S.D. Semukhin — research concept, literature review, drafting the initial version of the text (Introduction, part of the analytical section).

V.V. Pakholyuk — collection and analysis of statistical data, development and description of technical tools (website, Telegram bot).

P.D. Osina — analysis of the legal and regulatory framework, comparative legal analysis, work on the section concerning state regulation.

R.A. Kochkarov — scientific supervision, research methodology, critical analysis and revision of the text, formulation of conclusions.

S.A. Reznichenko — coordination of work on the article, consulting on technological aspects of security, analysis of content filtering algorithms, reviewing.

E.A. Okuneva — final editing and formatting, preparation of abstracts and keywords, reference list.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

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

Статья поступила в редакцию 13.10.2025; принята к публикации 24.11.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 13.10.2025; accepted for publication on 24.11.2025.

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



Недекларуемые возможности файловой архитектуры. Автоматизированный офис, текстовый редактор, формат DOCX

А.А. Рыженко^a, С.И. Козьминых^b

^{a,b} Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация;
^b Российский экономический университет им. Г.В. Плеханова, Москва, Российская Федерация

АННОТАЦИЯ

Вторая статья данного цикла работ предполагает приподнять завесу тайны форматов файлов автоматизированного офиса как контейнера для доработки вручную некоторых скрытых возможностей. В статье рассмотрен алгоритм реализации одной такой функции – перенаправление скрытой ссылки на активный интернет-ресурс. Как было упомянуто ранее в первой статье*, нарастающее количество недекларуемых функций в файловой архитектуре вызывает опасение у существующих спецслужб государств, что вполне обоснованно практическим отсутствием унифицированных программно-аппаратных комплексов аудита инъекций такого рода. Изучение простых программных инструментов, к сожалению, пропускаемых системами защиты на локальных ПК и в сетях, позволит построить более мощный закрытый контур на рабочих местах. Существующие системы управления информацией и событиями безопасности SIEM в унифицированном формате построения баз правил для аудита закрытого контура не содержат на данный момент готовых алгоритмов обнаружения посторонних файлов внутри файлов форматов автоматизированного офиса. Данный фактор необходимо исправлять с использованием самописных правил на рабочих местах индивидуально. В данном цикле статей не предполагаются практические инструкции, способные нанести вред цифровой среде корпоративного контура организаций. Рассмотрен сценарий простой инъекции с перенаправлением ссылки на интернет-ресурс (функция redirect), который предполагает исключительно образовательные функции и предупреждения для специалистов в сфере информационной безопасности.

Ключевые слова: инъекции; файловая система; текстовый редактор; безопасность; проникновение; глобальная сеть

Для цитирования: Рыженко А.А., Козьминых С.И. Недекларуемые возможности файловой архитектуры. Автоматизированный офис, текстовый редактор, формат DOCX. Цифровые решения и технологии искусственного интеллекта. 2025;1(4):60-68. DOI: 10.26794/3033-7097-2025-1-4-60-68

ORIGINAL PAPER

Undeclared File Architecture Features. Automated Office, Text Editor, Docx Format

А.А. Ryzhenko^a, С.И. Kozminych^b

^{a,b} Financial University under the Government of the Russian Federation, Moscow, Russian Federation;
^b Plekhanov Russian University of Economics, Moscow, Russian Federation

ABSTRACT

The second paper of this series of articles suggests lifting the veil of secrecy of automated office file formats as a container for manually refining some hidden features. The article discusses an algorithm for implementing one such function – redirecting a hidden link to an active Internet resource. As mentioned earlier in the first part of the article, the increasing number of undeclared functions in the file architecture causes concern among the existing special services of states, which is fully justified by the practical lack of unified software and hardware systems for auditing injections of this kind. Studying simple software tools, unfortunately overlooked by security systems on local PCs and networks, will allow you to build a more powerful closed circuit in the workplace. The existing SIEM in a unified format for building rule bases for closed-circuit auditing does not currently contain ready-made algorithms for detecting extraneous files inside files of automated office formats. This factor needs to be corrected using self-written workplace rules individually. This series of articles does not provide practical instructions for harming the digital environment of the corporate circuit of organizations. The considered scenario of a simple injection with redirection of a link to an Internet resource (redirect function) assumes exclusively educational functions and warnings for information security specialists.

Keywords: injections; file system; text editor; security; penetration; global network

For citation: Ryzhenko A.A., Kozminych S.I. Undeclared file architecture features. automated office, text editor, docx format. Digital Solutions and Artificial Intelligence Technologies. 2025;1(4):60-68. DOI: 10.26794/3033-7097-2025-1-4-60-68

* Рыженко А.А., Козьминых С.И. Недекларуемые возможности файловой архитектуры: графические контейнеры. Цифровые решения и технологии искусственного интеллекта. 2025;1(3):55-61.



ВВЕДЕНИЕ

Массовый переход файловой архитектуры в кросс-платформенный формат в начале 2000-х гг. привел к тому, что многие популярные форматы файлов стали открытого типа как контейнеры [1]. С одной стороны, эффект унификации позволил без дополнительных конвертаций переносить файлы в абсолютно произвольную операционную систему со своими особенностями организации файловой архитектуры, с другой — файлы-контейнеры теперь открыты и доступны для злоумышленников. Программисты часто забывают, что криптозащита файла как целостной системы позволяет не только обезопасить данные, но и предотвратить заражение в форме инъекций.

Описанный в статье метод является отправной точкой для полноценного анализа существующих методов простых инъекций. В глобальной сети множество аналогичных статей и публикаций¹. С научной точки зрения у правоохранительных органов есть множество вопросов к разработчикам, что также отражено в ряде статей [2, 3]. К сожалению, можно на данный момент уверенно констатировать тот факт, что унифицированных автоматизированных методов блокировки от данного метода инъекций (например, в базах правил SIEM) не существует [4].

В статье рассмотрен сценарий простой корректировки вложенных в контейнер файлов автоматизированного офиса (на примере формата.docx) как пример простой инъекции произвольной информации в файловую архитектуру.

АЛГОРИТМ ИНЬЕКЦИИ В ПОПУЛЯРНЫЙ ФОРМАТ ТЕКСТОВОГО РЕДАКТОРА

Цифровая среда не очень любит открывать свои тайны и секреты. И если пользователь не знает, что может скрывать вроде бы обычный файл, то, как правило, действие такого рода приводит к заражению устройства вирусами с последующей утечкой информации. В качестве примера можно рассмотреть одно из новых направлений цифровизации банковской инфраструктуры. Летом 2025 г. юридическим отделом Банка России² было предложено упростить процесс подписания договоров при оформлении кредитов дистанционно

с применением цифрового суррогата сопроводительных документов. Файлом-посредником для фиксации момента подписания выбран самый популярный формат файла автоматизированного офиса — DOCX. Данный формат содержит множество недекларированных возможностей, способствующих проникновению злоумышленника в закрытый контур банка. Далее будет рассмотрен один из известных в сети Интернет процессов перенаправления ссылки. Авторы специально не стали усложнять данный пример теми инструментами, которые позволяют еще глубже скрыть данный процесс с использование методов и алгоритмов социальной инженерии. Новое направление и возможные последствия будут рассмотрены в последующих статьях. Итак, процесс перенаправления ссылки состоит из следующих шагов.

Шаг 1. Заводим личный аккаунт в любом из IP-грабберов (рис. 1) [5]. В статье не предполагается отдельное описание функционала программных порталов такого рода, а также представление возможностей интернет-ресурсов, работающих на протоколах пятого уровня. Использование логгеров в цифровой среде нашего государства не запрещено законом, чем пользуются многие сотовые операторы для слежения за своими абонентами.

На втором шаге необходимо создать или использовать готовый файл в формате docx, на котором будем далее экспериментировать. При создании пустого нового файла не будет автоматически создана архитектура XDTO-контейнера. Страницы XML-кода добавляются в архитектуру контейнера только после открытия (или запуска) файла в активную фазу [6].

Шаг 2. Создаем документ в формате docx (рис. 2).

Далее используем ту самую недекларируемую функцию компонента ActiveX на примере «Видео из интернета». Особенностью активных элементов текстового редактора заключается в том, что они применяют встроенный макрос, который не фиксируется системами защиты на ПК как злорвяд. Именно этой особенностью часто пользуются злоумышленники при получении доступа изнутри в закрытом контуре организации. Чаще всего инструментарий ActiveX встроен в табличный процессор автоматизированного офиса. Почему до сих пор системы безопасности не научились запрещать инъекции такого рода, остается загадкой [7].

Шаг 3. Добавляем в документ компонент ActiveX на примере «Видео из интернета» (рис. 3).

Как уже было упомянуто ранее, обратимся к самому популярному примеру из интернет-среды. В 2025 г. Роскомнадзор запретил использование портала YouTube (запрещенный ресурс на терри-

¹ IP Логгер через Word, PDF или Excel файл. URL: <https://teletype.in/@rightdecision/IP-Logger-cherez-Word-PDF-ili-Excel-fajl-03-31>; IP Logger в Word. URL: <https://lolz.live/threads/2431117/>; Как нас могут логгировать общедоступными методами. URL: <https://habr.com/ru/companies/tomhunter/articles/590633/>

² Цифровизация банковской сферы в 2025 году: ключевые тренд. URL: <https://contentai.ru/blog/tpost/34rlfihu21-tsifrovizatsiya-bankovskoi-sferi-v-2025>

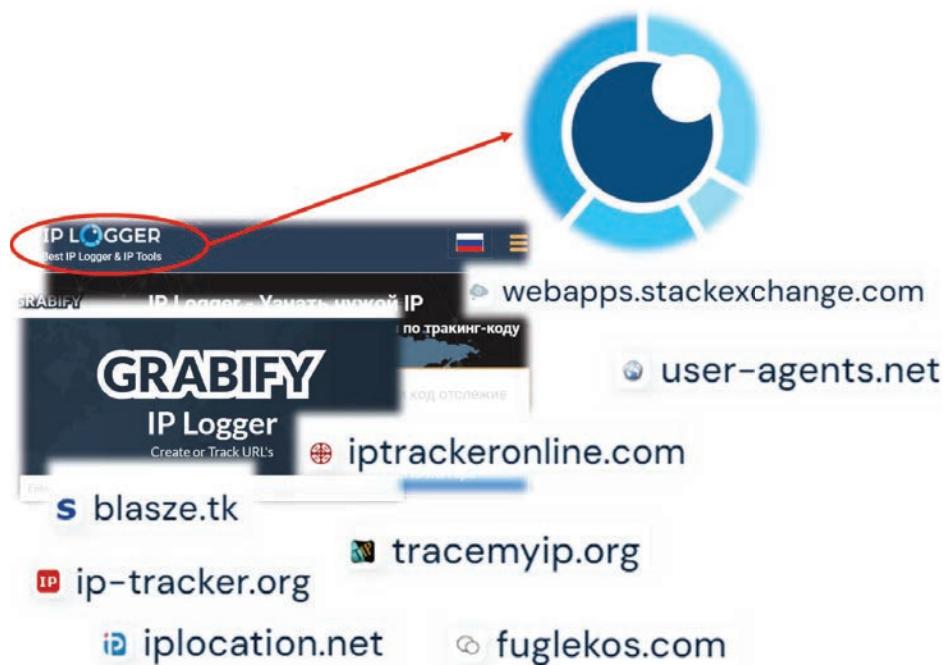


Рис. 1 / Fig. 1. Варианты IP-грабберов / IP Grabber Options

Источник / Source: открытая зона интернета / Open Internet Area.

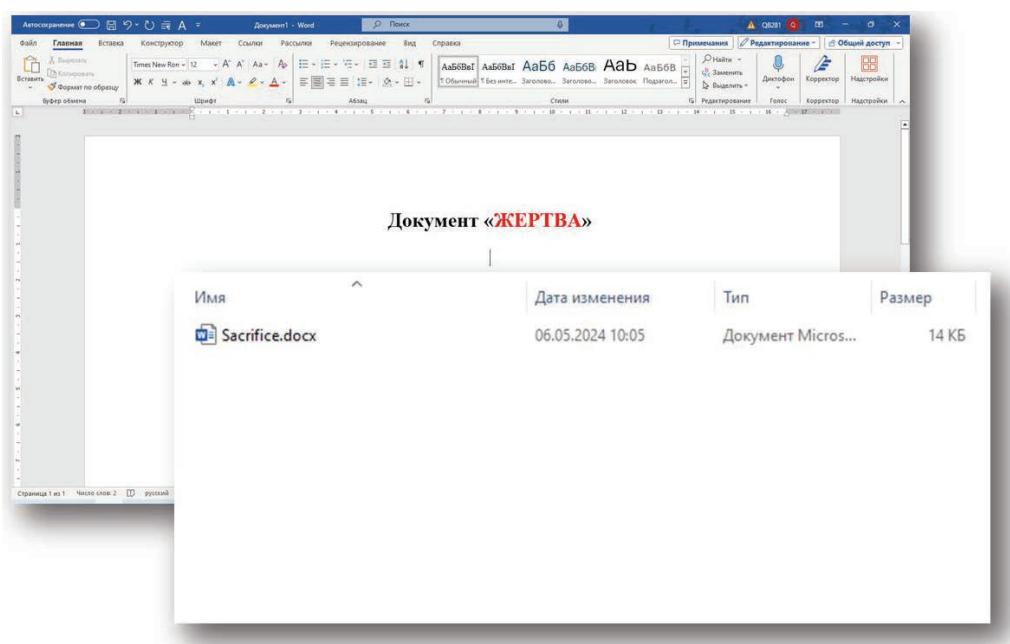


Рис. 2 / Fig. 2. Подготовка файла для инъекции / Preparing the File for Injection

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

тории РФ) в цифровой зоне домена РУ. Попытки задействовать криптозащищенные каналы VPN для получения доступа к запрещенным ресурсам отслеживается специальными службами и, в случае необходимости, пользователь может быть привлечен к статьям УК РФ [8]. Как следствие, дальнейшая инструкция приводится только с целью обучения специалистов сферы информационной безопасности недекларированным возможностям автоматизированного офиса.

Шаг 4. Просто сохраняем файл с активной вставкой (рис. 4).

Шаг 5. В папке с файлом в формате docx открываем видимость расширений файлов. Меняем расширение docx на zip (рис. 5). Именно в этом начинается проблемный момент для любой службы безопасности. Все форматы с расширением X (extended) являются контейнерами и могут быть открыты как zip-архив. Содержимое контейнера в разных версиях автоматизированного офиса

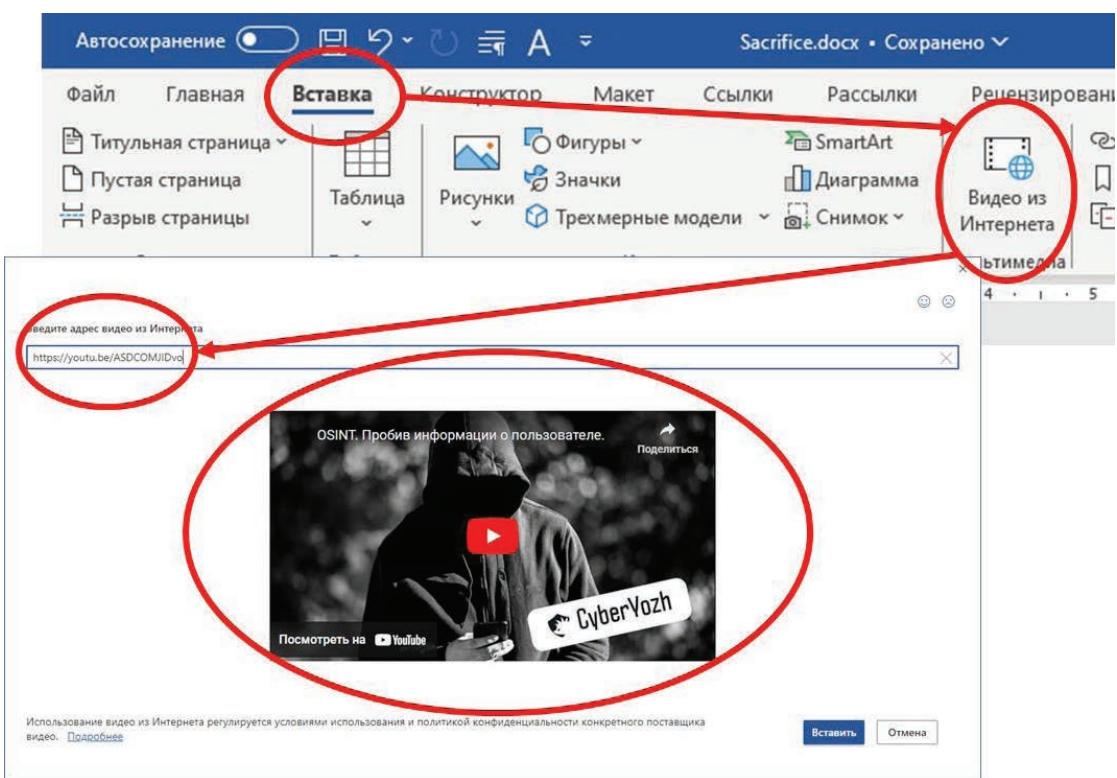
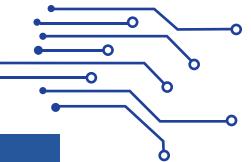


Рис. 3 / Fig. 3. Добавление активного компонента / Adding an Active Component

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

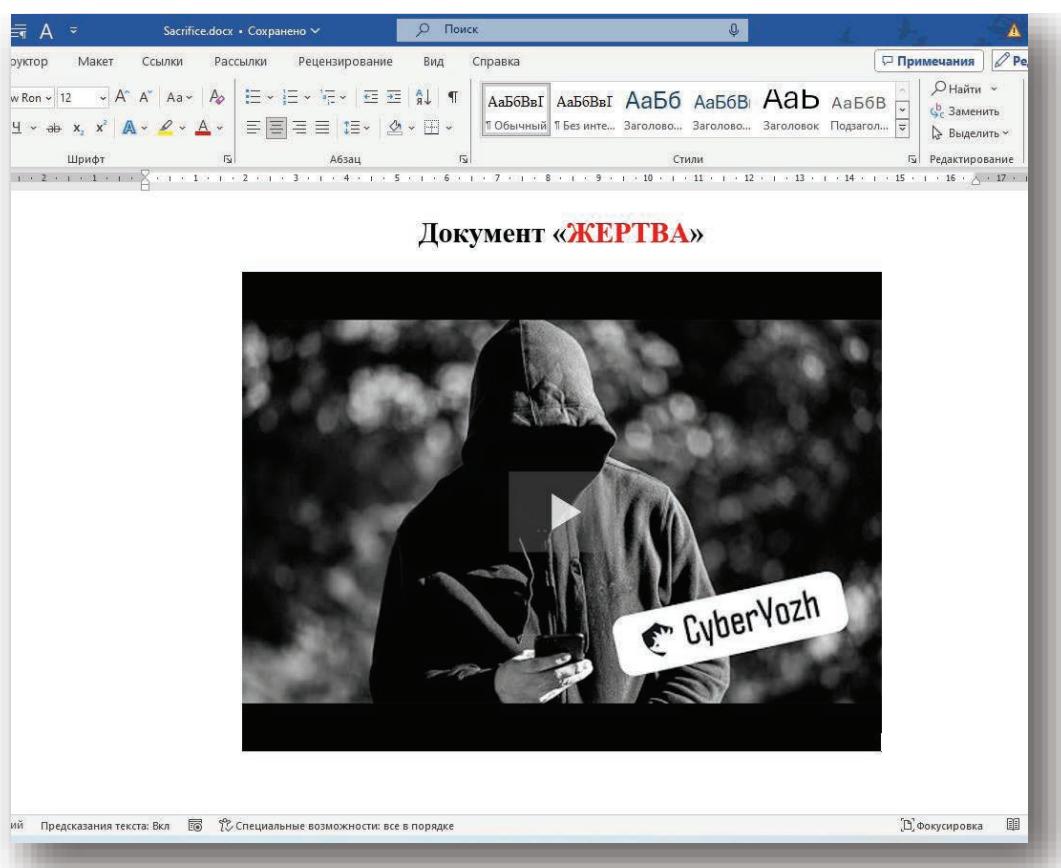


Рис. 4 / Fig. 4. Файл с ключевой командой / The File with the Key Command

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

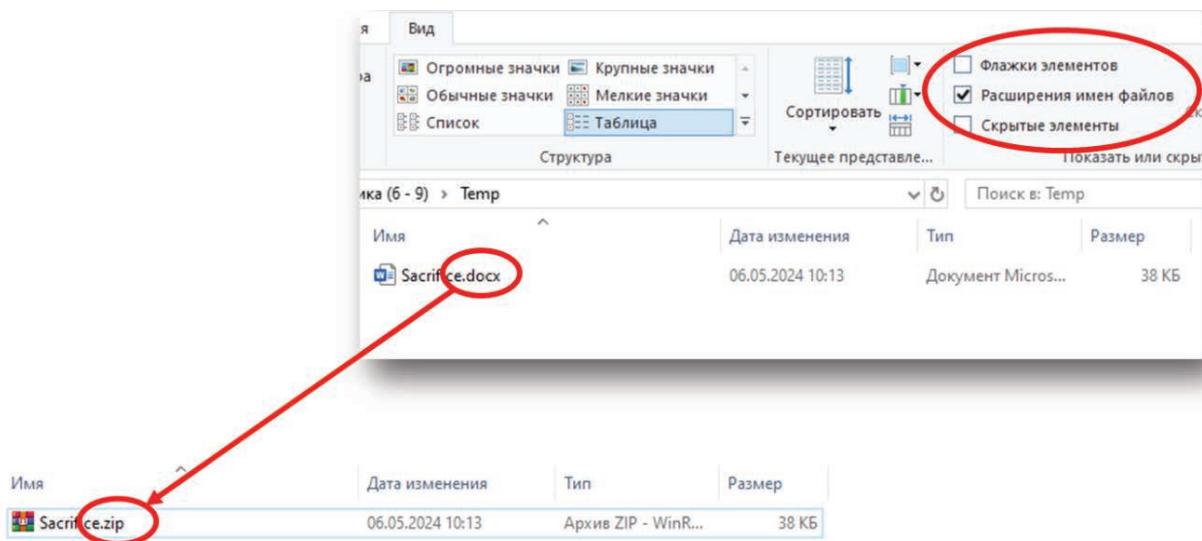
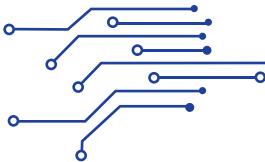


Рис. 5 / Fig. 5. Меняем расширение docx на zip / Changing the Extension docx to zip

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

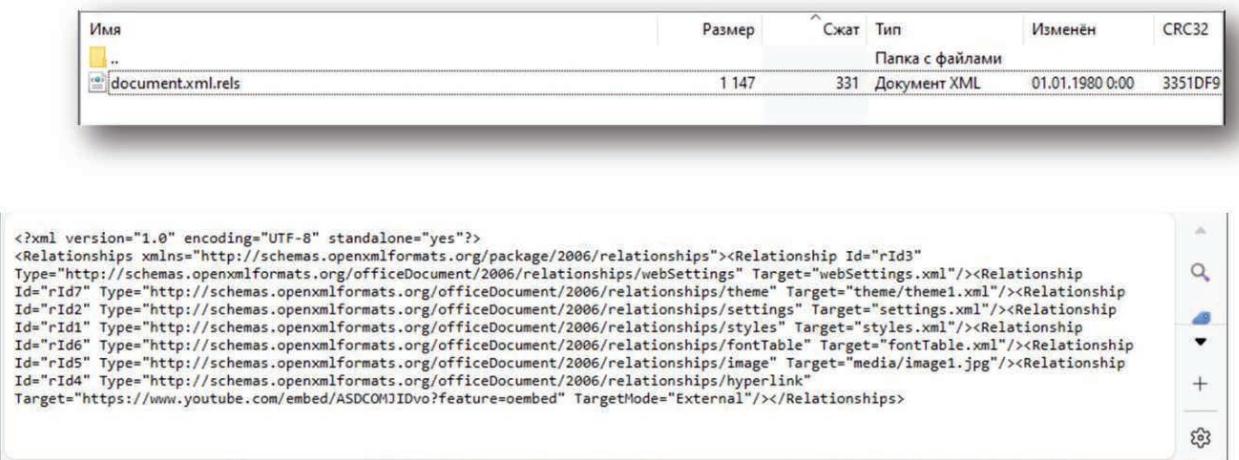


Рис. 6 / Fig. 6. Текстовый формат файла, пример / Text File Format, Example

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

может изменяться, но суть от этого не меняется. Большая часть файлов — обычные XML-форматы, свободно читаемые произвольным текстовым редактором, о чем также будет сказано ниже.

В результате переименования автоматически создается файл как zip-архив, который можно открыть без нарушения целостности [9]!

Шаг 6. Запускаем архив Sacrifice.zip. Открываем папку word, затем папку _rels. Находим файл document.xml.rels. Открываем как обычный текстовый документ, например, в приложении «Блокнот» (рис. 6).

Шаг 7. Находим в файле ссылку на Youtube-ролик и меняем на ссылку-подсказку. Например, «https://www.ЖМИ!_НЕ_СТЕСНЯЙСЯ.ru». Первый файл готов! (рис. 7).

Шаг 8. Остаемся в архиве Sacrifice.zip. Переходим в папку word. Находим файл document.xml (рис. 8).

Шаг 9. Находим в файле ссылку на Youtube-ролик и меняем на ссылку IP-логгера (рис. 9). Второй файл готов!

Шаг 10. Переименовываем файл с расширением zip обратно в формат docx. Запускаем ссылку (рис. 10). Если пользователь нажмет на кнопку воспроизведения, то видео не запустится, но сработает логгер.

Аналогично первой статье этой серии следует обратить внимание на тот факт, что все действия с целостностью файла не вызывали подозрения ни у одной установленной системы защиты информации [10].

ВЫВОДЫ

Сценарий простой инъекции с перенаправлением ссылки на интернет-ресурс (функция redirect), рассмотренный в данной статье, представлен исклю-

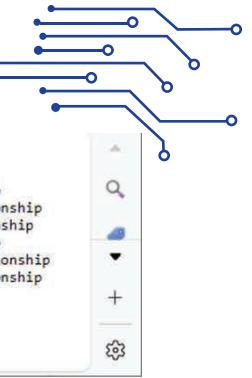


Рис. 7 / Fig. 7. Замена всплывающей подсказки на поддельную / Replacing the Popup Hint with a Fake One

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



Рис. 8 / Fig. 8. Активный файл со ссылками / Active File with Links

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

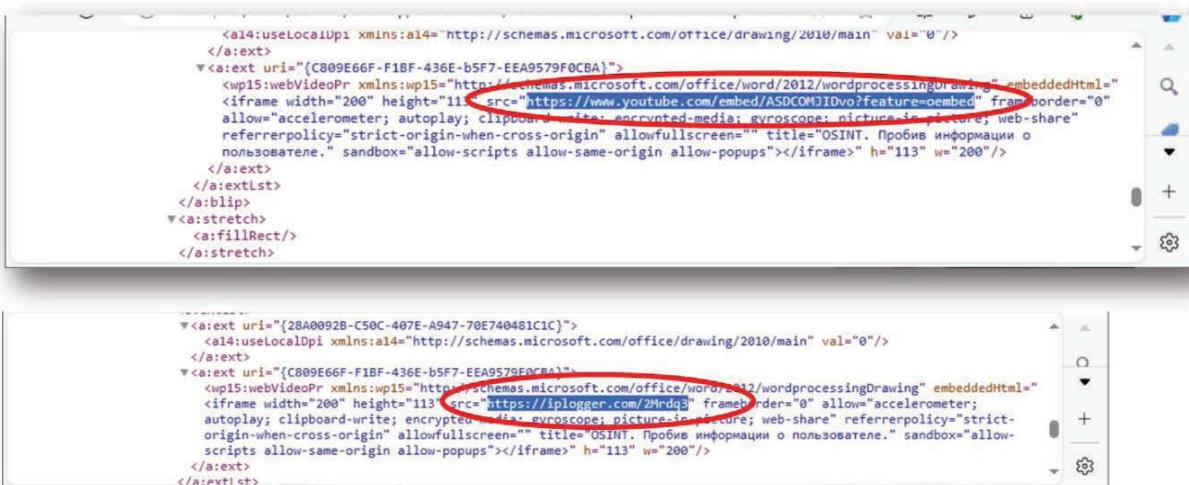


Рис. 9 / Fig. 9. Фиктивная скрытая активная ссылка / Fictitious Hidden Active Link

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

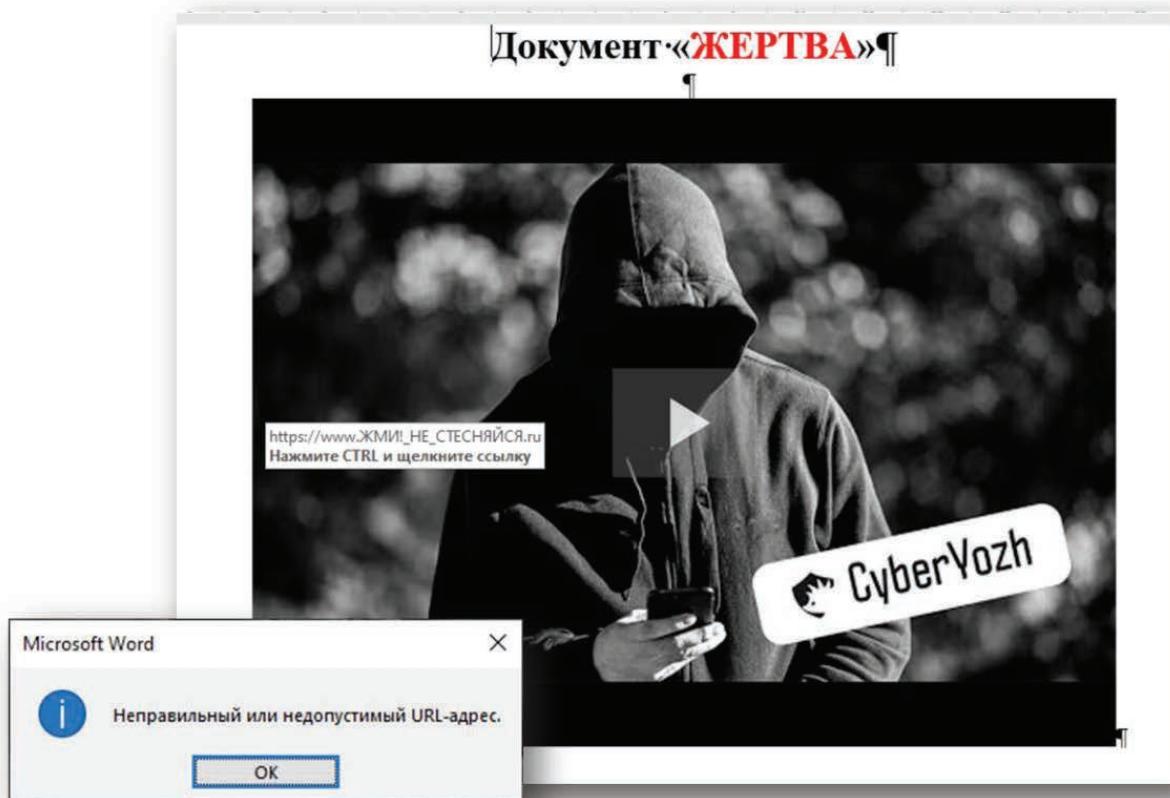
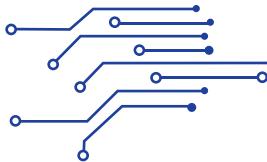


Рис. 10 / Fig. 10. Активная фиктивная ссылка в скрытом виде / An Active Dummy Link in a Hidden Form

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

чительно в образовательных и предупредительных целях для специалистов в сфере информационной безопасности.

В последующих статьях будут описаны и расшифрованы уязвимости файлов автоматизированного офиса, не представленных в сети Интернет в открытых источниках. Также будут рассматриваться

методы простых инъекций во все унифицированные форматы медиафайлов, распространенных в сети Интернет. Например, такие форматы, как: mp3, mp4, avi, mov, pdf, jpg, bmp, gif, tif и т.д. Сколько еще содержат существующие файлы контейнеры ошибок и недочетов будет также детально рассматриваться и далее.

СПИСОК ИСТОЧНИКОВ

1. Трусов А.Н., Иванченко П.Ю., Кацуро Д.А. Редактирование и внесение информации в XML-документы автоматизированных информационных систем. *Программные продукты и системы*. 2017;30(1):81–84. DOI: 10.15827/0236-235X.030.1.081-084
2. Сутыркина Е.А., Бурмистров А.Н. Исследование файлов журнала веб-сервера на предмет активности ботнетов с целью совершенствования технологии защиты веб-серверов. *Ученые записки УлГУ. Серия «Математика и информационные технологии»*. 2021;2:63–74. URL: <https://elibrary.ru/nliwpa>
3. Смольянинов В.А. Программные способы определения метаположения пользователей социальных сетей. Актуальные вопросы эксплуатации систем охраны и защищенных телекоммуникационных систем. Сборник материалов конференции, Воронеж, 09 июня 2022 г. Воронеж: Воронежский институт Министерства внутренних дел Российской Федерации; 2022;51–53. URL: <https://www.elibrary.ru/qyardw>
4. Куприяновская Ю.В., Куприяновский В.П., Климов А.А., Намиот Д.Е., Долбнев А.В. и др. Умный контейнер, умный порт, BIM, интернет вещей и блокчейн в цифровой системе мировой торговли. *International Journal of Open Information Technologies*. 2018;6(3):49–94. URL: <https://www.elibrary.ru/yrysiui>
5. Бахтеев Д.В., Шевырталов Е.П. Способы нейтрализации штатных и нештатных средств защиты автомобиля как элемент совершения угонов и хищений транспортных средств. *Вестник Уральского юридического института МВД России*. 2024;1(41):74–79. URL: <https://cyberleninka.ru/article/n/sposoby-neytralizatsii-shtatnyh-i-neshtatnyh-sredstv-zashchity-avtomobilya-kak-element-soversheniya-ugonov-i-hischeniy-transportnyh/viewer>



6. Еремченко В.И. Современные проблемы свободного оборота средств совершения и сокрытия преступлений. *Общество и право*. 2017;2(60):195–197. URL: <https://cyberleninka.ru/article/n/sovremennye-problemy-svobodnogo-oborota-sredstv-soversheniya-i-sokrytiya-prestupleniy/viewer>
7. Никифорова К.В., Окладова И.М. Обзор технологий ком. разработка сервера автоматизации. *Форум молодых ученых*. 2019;4(32):791–797. URL: <https://elibrary.ru/vuzifo>
8. Авласевич Д.В., Дмитриев Н.А., Кириллов А.А., Бачинский А.Г. Использование технологии VPN для обеспечения информационной безопасности. *Форум молодых ученых*. 2020;3(43):12–18. URL: <https://elibrary.ru/etgkxb>
9. Жуков Е.А. Разработка математической модели обнаружения программных закладных устройств. *НБИ технологии*. 2023;17(1):17–23. DOI: 10.15688/NBIT.jvolsu.2023.1.3
10. Тихомиров Н.А., Ключарёв П.Г. Проблема мониторинга информационных потоков, возникающих в ходе сборки программного обеспечения. *Вопросы кибербезопасности*. 2025;1(65):128–135. DOI: 10.21681/2311-3456-2025-1-128-135

REFERENCES

1. Trusov A.N., Ivanchenko P.Y., Katsuro D.A. Editing and entering information into XML documents of automated information systems. *Software Products and Systems*. 2017;30(1):81–84. DOI: 10.15827/0236-235X.030.1.081-084
2. Sutyrkina E.A., Burnistrov A.N. Botnet detection via server logs analysis. *Bulletin of the USU. The series "Mathematics and Information Technology"*. 2021;2:63–74. URL: <https://elibrary.ru/nliwpa>
3. Smolyaninov V.A. Software methods for determining the meta-position of users of social networks. Current issues of the operation of security systems and secure telecommunication systems: Conference proceedings, Voronezh, June 09, 2022. Voronezh: Voronezh Institute of the Ministry of Internal Affairs of the Russian Federation; 2022:51–53. URL: <https://www.elibrary.ru/qyardw>
4. Kupriyanovskaya Yu.V., Kupriyanovsky V.P., Klimov A.A., Namiot D.E., Dolbnev A.V. et al. Smart container, smart port, BIM, Internet of Things and blockchain in the digital world trade system. *International Journal of Open Information Technologies*. 2018;6(3):49–94. URL: <https://www.elibrary.ru/yrysi>
5. Bakhteev D.V., Shevyrtalov E.P. Methods of neutralizing standard and non-standard means of protecting a car as an element of committing theft and theft of vehicles. *Bulletin of the Ural Law Institute of the Ministry of Internal Affairs of Russia*. 2024;1(41):74–79. URL: <https://cyberleninka.ru/article/n/sposoby-neytralizatsii-shtatnyh-i-neshtatnyh-sredstv-zashchity-avtomobiliya-kak-element-soversheniya-ugonov-i-hischeniy-transportnyh/viewer>
6. Eremchenko V.I. Modern problems of free trafficking of the means of committing and concealing crimes. *Society and Law*. 2017;2(60):195–197. URL: <https://cyberleninka.ru/article/n/sovremennye-problemy-svobodnogo-oborota-sredstv-soversheniya-i-sokrytiya-prestupleniy/viewer>
7. Nikiforova K.V., Okladova I.M. Overview technology com. development of an automation server. *Forum of Young Scientists*, 2019;4(32):791–797. URL: <https://elibrary.ru/vuzifo>
8. Avlasevich D.V., Dmitriev N.A., Kirillov A.A., & Bachinsky A.G. Using VPN Technology to Ensure Information Security. *Forum of Young Scientists*. 2020;3(43):12–18. URL: <https://elibrary.ru/etgkxb>
9. Zhuikov E.A. Development of a mathematical model for detecting software embedded devices. *NBI Technologies*. 2023;17(1):17–23. DOI: 10.15688/NBIT.jvolsu.2023.1.3
10. Tikhomirov N.A., Klyucharev P.G. The problem of monitoring information flows that occur during software assembly. *Cybersecurity Issues*, 2025;1(65):128–135. DOI: 10.21681/2311-3456-2025-1-128-135

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

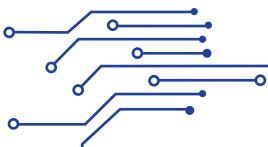
Алексей Алексеевич Рыженко — кандидат технических наук, доцент, доцент кафедры информационной безопасности, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Alexey A. Ryzhenko — Cand. Sci. (Tech.), Assoc. Prof. of the Information Safety Department, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0002-7279-9929>

Автор для корреспонденции / Corresponding author:

AARyzhenko@fa.ru



Сергей Игоревич Козьминых — доктор технических наук, доцент, профессор кафедры прикладной информатики и информационной безопасности, Российский экономический университет им. Г.В. Плеханова, Москва, Российская Федерация; профессор кафедры информационной безопасности, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Sergey I. Kozminykh — Dr. Sci. (Tech.), Assoc. Prof., Prof. of the Department of Applied Informatics and Information Security, Plekhanov Russian University of Economics, Moscow, Russian Federation; Professor of Information Security Department, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0003-3903-9562>

kozminykh.si@rea.ru;

SIKozminykh@fa.ru

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

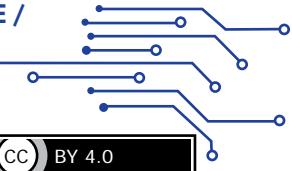
Conflicts of Interest Statement: The authors have no conflicts of interest to declare.

Статья поступила в редакцию 13.10.2025; принята к публикации 24.11.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 13.10.2025; accepted for publication on 24.11.2025.

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



ОРИГИНАЛЬНАЯ СТАТЬЯ

(CC) BY 4.0

DOI: 10.26794/3033-7097-2025-1-4-69-75
УДК 519.17(045)

Влияние искусственного интеллекта на цифровую трансформацию бизнеса в России

Р.М. Магомедов

Финансовый университет при Правительстве Российской Федерации, Москва, Российской Федерации

АННОТАЦИЯ

В данной статье приводится всесторонний анализ влияния искусственного интеллекта на процессы цифровой трансформации бизнеса в России. Рассматриваются ключевые государственные инициативы, экономические эффекты внедрения искусственного интеллекта в различные сферы экономики, отраслевые особенности, региональные диспропорции, а также вызовы и перспективы развития страны. Цель настоящей работы состоит в оценке степени влияния искусственного интеллекта на цифровую трансформацию бизнеса в России, определении возможности и перспективы внедрения искусственного интеллекта для улучшения бизнес-процессов и повышения конкурентоспособности российских компаний. Исследования проводились с помощью анализа структуры и динамики влияния искусственного интеллекта на развитие бизнеса в России. Приводятся аналитические таблицы и диаграммы, иллюстрирующие динамику и масштаб изменений. Особое внимание уделяется роли искусственного интеллекта как драйвера инноваций и повышения конкурентоспособности российских компаний в условиях глобальной цифровой экономики. Искусственный интеллект внедрен в основные процессы в 75% крупных российских компаний, а среди малого и среднего бизнеса этот показатель достиг 50%. Лидируют по внедрению искусственного интеллекта компании финансового сектора (85%), логистики и ритейла (70%) и промышленность (60%). Это свидетельствует о том, что искусственный интеллект перестает быть экспериментальной технологией и становится неотъемлемой частью бизнес-процессов.

Ключевые слова: искусственный интеллект; цифровая трансформация; бизнес; экономика; Россия; цифровые технологии; инновации; государственная политика

Для цитирования: Магомедов Р.М. Влияние искусственного интеллекта на цифровую трансформацию бизнеса в России. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(4):69-75. DOI: 10.26794/3033-7097-2025-1-4-69-75

ORIGINAL PAPER

Impact of Artificial Intelligence on the Digital Transformation of Business in Russia

R.M. Magomedov

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

ABSTRACT

This article provides a comprehensive analysis of the artificial intelligence impact on the processes of digital business transformation in Russia. Key government initiatives, the economic effects of the introduction of artificial intelligence into different economic spheres, industry specifics, regional disparities, as well as challenges and country development prospects are considered. The purpose of the present work is to assess the influence degree of artificial intelligence on the digital transformation of business in Russia, to determine the possibility and prospects for introducing artificial intelligence into business processes to improve business processes and increase the competitiveness of Russian companies. The study was carried out using an analysis of the structure and dynamics of the artificial intelligence impact on business development in Russia. Analytical tables and diagrams illustrating the dynamics and scale of changes are provided. Special attention is paid to the role of artificial intelligence as a driver of innovation and increasing the competitiveness of Russian companies in the global digital economy. Artificial intelligence has been introduced into the main processes in 75% of large Russian companies, and among small and medium-sized businesses this figure has reached 50%. The leaders in the artificial intelligence introduction are companies in the financial sector (85%), logistics and retail (70%) and industry (60%). That means that artificial intelligence is no longer an experimental technology and it is becoming an integral part of business processes. **Keywords:** artificial intelligence; digital transformation; business; economy; Russia; digital technologies; innovations; public policy

For citation: 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. DOI: 10.26794/3033-7097-2025-1-4-69-75



ВВЕДЕНИЕ

Цифровая трансформация бизнеса — это комплексное внедрение цифровых технологий, меняющее традиционные бизнес-модели, процессы и взаимодействия с клиентами. Искусственный интеллект (ИИ), как одна из наиболее перспективных и быстроразвивающихся технологий, становится ключевым фактором этой трансформации. В России, несмотря на определенные структурные и инфраструктурные ограничения, искусственный интеллект активно внедряется в различные сферы жизни и экономики, стимулируя рост эффективности и инновационности бизнеса. Развитие искусственного интеллекта в России поддерживается государственными программами, направленными на обеспечение технологического суверенитета страны и импортозамещения, что особенно актуально в условиях геополитических вызовов и экономической нестабильности. Внедрение искусственного интеллекта способствует не только автоматизации рутинных задач, но и созданию новых продуктов и услуг, улучшению качества управления и повышению удовлетворенности клиентов.

Цель исследования — оценить степень влияния искусственного интеллекта на цифровую трансформацию бизнеса в России, определить возможности и перспективы внедрения ИИ для улучшения бизнес-процессов и повышения конкурентоспособности российских компаний.

МЕТОД ИССЛЕДОВАНИЯ

В качестве метода исследования использовался анализ структуры и динамики влияния искусственного интеллекта на цифровую трансформацию бизнеса в России.

В 2025 г. Россия достигла значительных успехов в интеграции искусственного интеллекта в бизнес-процессы. Согласно данным Минцифры, доля компаний, использующих ИИ, выросла до 67% (по сравнению с 35% в 2022 г.). Это стало возможным благодаря развитию инфраструктуры, адаптации бизнеса к новым технологическим реалиям и государственной поддержке. В 2025 г. завершился федеральный проект «Искусственный интеллект», рассчитанный на 2021–2024 гг., в рамках которого было выделено 300 млрд руб. на развитие ИИ, научных исследований и образовательных программ. Фондом развития цифровой экономики запущен портал «Акселератор Искусственного Интеллекта», который помог более чем 500 стартапам выйти

на рынок. Также выделены налоговые льготы для компаний, инвестирующих в развитие искусственного интеллекта (снижение НДС на 10% для технологических проектов).

Текущее состояние ИИ в России на 2025 г. описывается объемом рынка ИИ в России, который составил 1,2 трлн руб., что на 40% больше, чем в 2023 г. Известно, что 75% крупных компаний внедрили ИИ в основные процессы, тогда как среди малого и среднего бизнеса этот показатель достиг 50%. Лидерами по внедрению искусственного интеллекта являются: финансовый сектор (85% компаний), логистика и ритейл (70% компаний) и промышленность (60% компаний).

Данные табл. 1 показывают, что финансовые организации — одни из первых и наиболее активно внедряющих искусственный интеллект. Использование машинного обучения и анализа больших данных позволяет им улучшить скоринг клиентов, выявить мошеннические операции и автоматизировать клиентский сервис. В качестве примера можно привести Сбербанк, который внедрил ИИ-платформу для обработки обращений клиентов, что позволило снизить время ответа на 40% и повысить удовлетворенность клиентов на 20%. Искусственный интеллект применяется для предиктивного обслуживания оборудования, оптимизации производственных процессов и управления цепочками поставок. К примеру, группа компаний «Северсталь» использует ИИ для мониторинга состояния оборудования, что снизило аварийность на 15%. В логистике ИИ помогает оптимизировать маршруты и контролировать условия перевозок, снижая потери и ускоряя доставку. В электронной коммерции ИИ-алгоритмы персонализируют предложения, прогнозируют поведение клиентов и оптимизируют ценообразование. Автоматизация клиентской поддержки через чат-боты повышает качество сервиса и снижает издержки. Например, компания X5 Retail Group применяет ИИ для прогнозирования спроса, что позволило снизить издержки на хранение товаров на 10% и увеличить продажи [1].

Современная деловая среда России претерпевает кардинальные изменения благодаря активной интеграции интеллектуальных технологий. Рассмотрим ключевые аспекты этого процесса. В сфере торговли наблюдается революционный прорыв. Крупнейшие торговые площадки страны успешно внедрили системы анализа покупательских предпочтений. Согласно последним исследованиям, такой подход увеличивает средний размер покупки на 15–20% по сравнению с традиционными схемами продаж. Сервисные службы кардинально измени-

* Научная электронная библиотека eLibrary.ru. URL: <https://www.elibrary.ru>

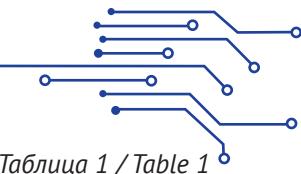


Таблица 1 / Table 1

Внедрение ИИ в российских компаниях (2025 г.) / AI Introduction in Russian Companies in 2025

Сектор / Sector	Доля компаний, использующих ИИ, % / Share of companies using AI, %	Основные применения / Main applications
Финансы и банкинг	85	Кредитный scoring, чат-боты, AML-анализ
Логистика	70	Оптимизация маршрутов, прогнозирование спроса
Производство	60	Предиктивное обслуживание, контроль качества
Медицина	55	Диагностика, анализ медицинских данных

Источник / Source: составлено авторами / Complied by the author.

ли принципы работы. Современные электронные помощники самостоятельно обрабатывают до 80% стандартных обращений, сокращая время ожидания ответа с 10 минут до 30 секунд. Особенно заметны эти изменения в банковской сфере, где подобные решения значительно оптимизировали работу клиентских служб [2].

Следует отметить, что сфера государственных услуг стала значительно доступнее благодаря внедрению умных систем обработки запросов. Автоматизированные сервисы в многофункциональных центрах (МФЦ) сократили время оказания услуг с 2 часов до 15 минут. Судебная система также применяет аналитические алгоритмы для работы с правовой информацией, что ускоряет рассмотрение дел на 40%. Системы видеоконтроля с функцией

распознавания образов стали важным инструментом обеспечения порядка. В мегаполисах такие технологии помогают предотвращать правонарушения и оперативно реагировать на чрезвычайные ситуации. По данным МВД, в районах с развитой системой видеонаблюдения отмечается снижение уличной преступности на 25%.

Безусловно, развитие технологий потребовало создания новой законодательной базы. Принятый в 2025 г. нормативный акт установил четкие правила использования интеллектуальных систем. Особое внимание уделяется вопросам прозрачности алгоритмов и защиты персональных данных.

К сожалению, сохраняются проблемы, связанные с качеством исходных данных для обучения систем. Около 45% организаций отмечают недостаток релевантной информации, особенно в регионах. Также требуют решения вопросы информационной безопасности и защиты авторских прав.

По оценкам международной консалтинговой компании McKinsey, рынок ИИ в России будет расти на 40% ежегодно, а вклад ИИ в ВВП к 2030 г. может достигнуть 5 трлн руб. (см. рисунок). Это составляет около 20–33% общего прироста ВВП, что свидетельствует о стратегической важности технологий ИИ для экономики¹ [3].

К 2030 г. российский рынок технологий искусственного интеллекта достигнет отметки в 3 трлн руб., что в 2,5 раза превысит показатели 2025 г. Такой стремительный рост обусловлен сразу несколькими факторами:

- массовая цифровизация традиционных отраслей промышленности;

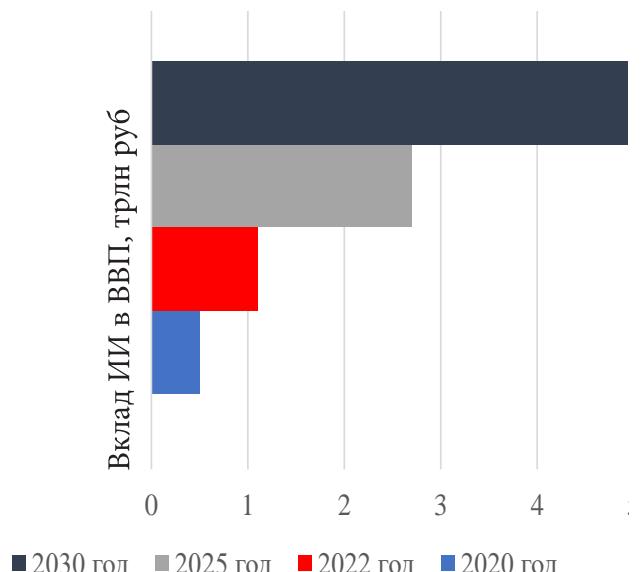


Рис./Fig. Прогноз вклада ИИ в ВВП России (2020–2030 гг.) / Forecast of AI Contribution to Russia's GDP (2020–2030)

Источник / Source: составлено авторами / Complied by the author.

¹ Делаем науку в России: ускорение цифровой трансформации. Институт статистических исследований и экономики знаний НИУ ВШЭ. URL: <https://issek.hse.ru/news/1033038241.html>



- увеличение государственных инвестиций в ИИ-разработки;
- расширение сфер применения интеллектуальных систем.

Особенно значительный прогресс ожидается в медицинской диагностике (точность прогнозов возрастет до 95%), финансовом секторе (полная автоматизация 70% банковских операций), а также в сельском хозяйстве — внедрение предиктивных систем управления урожаем.

Согласно исследованиям Высшей школы экономики, к 2030 г. около половины всех рабочих мест в России будут так или иначе связаны с технологиями искусственного интеллекта. Это проявится в появлении новых профессий, изменении существующих специальностей, исчезновении некоторых традиционных профессий.

Внедрение ИИ способствует снижению операционных затрат (до 15% в промышленности и логистике), увеличению выручки за счет новых продуктов и персонализации, повышению производительности труда и сокращению времени на рутинные операции [4–6].

Уже известно, что искусственный интеллект активно внедряется в ключевые отрасли — финансы, промышленность, ритейл, здравоохранение, транспорт. В регионах, таких как Московская и Сахалинская области, реализуются уникальные проекты. Московская область запустила сервис «ВсеСети» — цифровую платформу для упрощения согласований инфраструктурных проектов, сокращающую сроки с 12 месяцев до 14 дней. На Сахалине беспилотники с ИИ-ассистентами выявляют и помогают ликвидировать несанкционированные свалки, что улучшает экологическую ситуацию в регионе.

Однако цифровое неравенство между регионами остается вызовом — около двух третей станций связи в ряде субъектов не поддерживают современные стандарты 4G/LTE, что ограничивает доступ к цифровым сервисам и тормозит развитие ИИ [7, 8].

В мае 2025 г. Правительство России официально запустило Центр развития искусственного интеллекта (далее — Центр), который станет проектным офисом для координации и систематизации внедрения ИИ в стране. Основные задачи Центра:

- масштабирование лучших практик ИИ в различных отраслях;
- экспертно-аналитическое сопровождение приоритетных проектов;
- разработка нормативных документов и методик;
- поддержка разработчиков и развитие вычислительных мощностей.

Центр внедряет проектный подход с цифровым мониторингом и контролем исполнения, что

должно повысить эффективность реализации национальных инициатив.

Эксперты отмечают, что Россия имеет потенциал стать одним из лидеров в области ИИ за счет концентрации усилий на развитии «сильного» ИИ — технологий, способных к самостоятельному обучению и принятию решений [9–10].

Это обусловлено как растущим спросом на ИИ-решения в корпоративном секторе, так и государственной поддержкой высокотехнологичных отраслей. Инвестиции в цифровую инфраструктуру и программное обеспечение в течение последних четырех лет выросли более чем на 80%, превысив 4 трлн руб. При этом расходы на внедрение программных продуктов увеличились в 2,5 раза, что свидетельствует о масштабной цифровой трансформации бизнеса.

Цифровая зрелость промышленных компаний в России уже превышает 45%, а более 70% предприятий продолжают инвестировать в развитие цифровых технологий, из них треть наращивает темпы вложений [11]. Это означает, что ИИ перестает быть экспериментальной технологией и становится неотъемлемой частью бизнес-процессов.

Эксперты выделяют сразу три ключевых направления, в которых ИИ оказывает наиболее значимое влияние на бизнес.

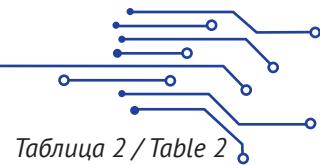
1. Развитие ИТ-инфраструктуры. Создание эффективных каналов взаимодействия с пользователями, сбор и анализ данных, цифровое проектирование и моделирование (включая VR и AR) становятся основой для инноваций в различных отраслях. Особенно активно эти технологии внедряются в топливно-энергетическом комплексе, здравоохранении и финансовом секторе.

2. Автоматизация и оптимизация бизнес-процессов.

3. Создание новых продуктов и услуг.

Многие компании уже сегодня используют нейросети для автоматизации без значительных затрат на ИТ-инфраструктуру. Это позволяет предпринимателям сосредоточиться на развитии бизнеса и создании ценности, а не на рутинных задачах. Особенно это касается малого и среднего бизнеса, который не всегда располагает ресурсами для цифровой трансформации. Спрос на специалистов по машинному обучению и ИИ в России стремительно растет — по данным hh.ru, за 2023 г. он увеличился на 67%. Недостаток квалифицированных кадров ограничивает возможности компаний по внедрению и развитию ИИ [12].

Как уже упоминалось, государственная поддержка и инвестиции помогают развитию ИИ в России (табл. 2). Инвестиции в стартапы спо-



Прогноз развития рынка ИИ и цифровых технологий / Forecast for the Development of the AI and Digital Technology Market

Год / Year	Объем рынка ИИ и цифровых решений, млрд руб. / Volume of the AI and digital solutions market, billion rubles	Годовой рост, % / Annual growth, %
2020	200	-
2022	392	40
2025	1100	40
2028	1800	24 (кибербезопасность)

Источник / Source: составлено авторами / Complied by the author.

собствуют расширению экосистемы ИИ-решений. Создание региональных центров компетенций и хабов, аналогичных Сколково, позволит равномерно развивать цифровую экономику по всей стране. Интеграция данных между государственными и коммерческими структурами — важный шаг к повышению эффективности управления и снижению издержек. Внедрение «Цифрового паспорта системы» позволит создать прозрачную и удобную платформу для взаимодействия всех участников рынка. Запуск программ обучения и акселерации для ИТ-специалистов в сотрудничестве с бизнесом поможет сократить кадровый дефицит и повысить уровень цифровой грамотности предпринимателей.

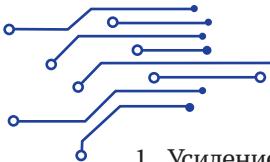
По оценкам экспертов, компании, внедряющие ИИ, получают до 30% экономии ресурсов за счет точного прогнозирования спроса и оптимизации процессов. В госсекторе цифровизация позволяет сократить бюрократическую нагрузку на 40%, что ускоряет принятие решений и повышает качество услуг.

В последние годы Россия значительно нарастила финансирование проектов, связанных с искусственным интеллектом, что отражает стратегическую важность ИИ для национальной безопасности и экономического развития. В 2025 г. на реализацию федерального проекта «Искусственный интеллект» выделено около 7,7 млрд руб., что является частью более широкой программы цифровой трансформации и развития экономики данных. В рамках дорожной карты развития ИИ до 2030 г. общий объем инвестиций в технологии ИИ составит порядка 145,85 млрд руб., из которых 33,3 млрд руб. — средства федерального бюджета, а 112,6 млрд руб. — внебюджетные инвестиции, включая крупные вложения таких институтов, как Сбербанк (около 99,7 млрд руб.) и Российский фонд прямых инвестиций (РФПИ) — 5,6 млрд руб. До-

полнительно выделяются средства на исследование и разработку методологий оценки безопасности ИИ-систем, что особенно важно для оборонного и других критически важных секторов экономики — в 2024–2025 гг. на эти цели планируется выделить более 8 млрд руб. Российский венчурный рынок в сфере ИИ демонстрирует устойчивый рост. Частные инвесторы и венчурные фонды активно финансируют стартапы, работающие в области машинного обучения, компьютерного зрения, обработки естественного языка и робототехники. Помимо крупных игроков, таких как Сбербанк и РФПИ, растет число специализированных акселераторов и инкубаторов, поддерживающих инновационные проекты. Согласно экспертным оценкам, ежегодный объем частных инвестиций в ИИ-стартапы в России превышает 20 млрд руб., при этом наблюдается тенденция к увеличению доли сделок на стадии раннего финансирования, что свидетельствует о формировании устойчивой экосистемы инноваций [13].

Одним из ключевых шагов по систематизации и масштабированию внедрения ИИ в бизнес и государственное управление стало создание платформы типовых ИИ-решений. Эта инициатива направлена на тиражирование лучших региональных практик и упрощение доступа к готовым решениям для различных отраслей и процессов. Платформа позволяет компаниям и органам власти быстро интегрировать ИИ-инструменты в существующие процессы без необходимости создавать собственные разработки с нуля. В числе первых кейсов — проекты в здравоохранении, коммунальном хозяйстве, цифровизации госуслуг, где ИИ берет на себя рутинные задачи, повышая эффективность и снижая нагрузку на персонал.

Для дальнейшего развития рынка ИИ в России необходимо выполнение ряда условий.



1. Усиление поддержки стартапов на ранних стадиях через гранты и льготное финансирование.
 2. Развитие инфраструктуры для тестирования и внедрения ИИ-решений.
 3. Содействие интеграции российских ИИ-компаний в международные цепочки создания стоимости.
 4. Повышение качества и доступности образовательных программ для подготовки квалифицированных кадров.

Выводы

В заключение хотелось бы отметить, что искусственный интеллект становится фундаментальным

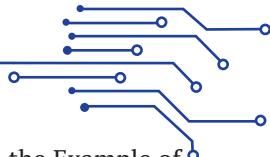
элементом цифровой трансформации бизнеса в России. Он способствует радикальному изменению бизнес-процессов, повышению эффективности и конкурентоспособности компаний. Государственная поддержка, развитие инфраструктуры и образовательных программ создают условия для масштабного внедрения ИИ в различные отрасли. Однако для достижения полного потенциала необходимо преодолеть технологические и кадровые барьеры, а также усовершенствовать нормативно-правовую базу. В ближайшие годы именно интеграция ИИ и предпринимательского мышления определит успех российских компаний на глобальном рынке.

СПИСОК ИСТОЧНИКОВ

1. Албогачиева Л.А., Бийсултанова М.А. Искусственный интеллект и его влияние на бизнес-процессы. *Экономика: вчера, сегодня, завтра*. 2024;14(7-1):812–816. URL: <http://www.publishing-vak.ru/file/archive-economy-2024-7/d37-albogachieva-biisultanova.pdf>
 2. Альцман А.В., Липис Е.А. Влияние искусственного интеллекта на международный бизнес (на примере AMAZON и UBER). Счисляевские чтения: актуальные проблемы экономики и управления. 2024;12:32–39. DOI: 10.52899/978-5-88303-686-5_32
 3. Карлов И.А. Искусственный интеллект и цифровая трансформация в образовании. Высшая школа экономики. Учебные курсы. 2023/2024. URL: <https://www.hse.ru/edu/courses/835236757>
 4. Магомедов Р.М. Трансформация бизнеса в условиях использования искусственного интеллекта. *Самоуправление*. 2023;5(136):475–478. URL: https://samupr.mosveo.ru/wp-content/uploads/2023/07/samupr%E2%84%963_1362023WW1.pdf
 5. Никонов П.М. Влияние искусственного интеллекта на цифровую трансформацию малого бизнеса. *Экономика и бизнес: теория и практика*. 2025;3(121):225–229. DOI: 10.24412/2411-0450-2025-3-225-229
 6. Лукинов В.А., Соколов Д.А. Роль искусственного интеллекта в цифровой трансформации современной России. *Научное обозрение. Технические науки*. 2023;2:38–43. DOI: 10.17513/srts.1432
 7. Савина С.В. Анализ влияния санкций на развитие ИТ-сектора в России: проблемы и перспективы. *РИСК: Ресурсы, Информация, Снабжение, Конкуренция*. 2024;1:188–193. DOI: 10.56584/1560-8816-2024-1-188-193
 8. Тухугов Я.Ш., Баташев Р.В. Влияние искусственного интеллекта на трансформацию современных экономических моделей. *Экономика и бизнес: теория и практика*. 2024;118(12-3):110–113. DOI: 10.24412/2411-0450-2024-12-3-110-113
 9. Барашкова А.Л., Воробьев И.В. Цифровая трансформация в науке: что ждут от технологий ИИ российские ученые? *Науковедческие исследования*. 2024;1:33–45. DOI: 10.31249/scis/2024.01.02
 10. Фомичева Т.Л. Параллельный импорт: российская специфика. *Инновации и инвестиции*. 2024;4:361–363. URL: <https://www.elabrary.ru/ckhcrp>
 11. Хромова И.Н., Святкина К.Н., Ховята Е.А. Применение искусственного интеллекта в условиях цифровой трансформации бизнеса. *Вестник Академии знаний*. 2024;1:342–345. URL: <https://www.elabrary.ru/gikrpa>
 12. Чебуханова Л.В. Искусственный интеллект и его влияние на трансформацию финансовых инструментов. *Вестник Академии знаний*. 2024;5:486–491. URL: <https://www.elabrary.ru/gqhftm>
 13. Шипулов Е.О. Влияние искусственного интеллекта на социальные коммуникации: трансформация взаимодействия в цифровую эпоху. *Гуманитарный научный журнал*. 2025;1-1:61–64. URL: <https://www.elabrary.ru/edhuta>

REFERENCES

1. Albogachieva L.A., Biysultanova M.A. Artificial Intelligence and Its Impact on Business-Processes. *Economy: Yesterday, Today, Tomorrow*. 2024;14(7-1):812-816. URL: <http://www.publishing-vak.ru/file/archive-economy-2024-7/d37-albogachieva-biysultanova.pdf> (In Russ.).



2. Altsman A.V., Lipis E.A. The Impact of Artificial Intelligence on International Business (on the Example of AMAZON and UBER). *Schislyaev Readings: Current Problems of Economics and Management*. 2024;12:32-39. (In Russ.). DOI: 10.52899/978-5-88303-686-5_32
3. Karlov I.A. Artificial Intelligence and Digital Transformation in Education. *Higher School of Economics. Curiculum*. 2023/2024. URL: <https://www.hse.ru/edu/courses/835236757>. (In Russ.).
4. Magomedov R.M. Business Transformation in the Context of Using Artificial Intelligence. *Self-Government*. 2023;3(136):475-478. URL: https://samupr.mosveo.ru/wp-content/uploads/2023/07/samup%E2%84%963_1362023WWW1.pdf (In Russ.).
5. Nikonorov P.M. The Impact of Artificial Intelligence on the Digital Transformation of Small Business. *Economics and Business: Theory and Practice*. 2025;3(121):225-229. (In Russ.). DOI: 10.24412/2411-0450-2025-3-225-229
6. Lukinov V.A., Sokolov D.A. The Role of Artificial Intelligence in the Digital Transformation of Modern Russia. *Scientific Review. Technical Sciences*. 2023;2:38-43. (In Russ.). DOI: 10.17513/srts.1432
7. Savina S.V. Analysis of the Impact of Sanctions on the Development of the IT Sector in Russia: Problems and Prospects. *RISK: Resources, Information, Supply, Competition*. 2024;1:188-193. (In Russ.). DOI: 10.56584/1560-8816-2024-1-188-193
8. Tukhugov Ya.Sh., Batashev R.V. The Impact of Artificial Intelligence on the Transformation of Modern Economic Models. *Economics and Business: Theory and Practice*. 2024;118(12-3):110-113. (In Russ.). DOI: 10.24412/2411-0450-2024-12-3-110-113
9. Barashkova A.L., Vorobiev I.V. Digital transformation creation in science: what do Russian scientists expect from technology? *Science Studies*. 2024;1:33-45. (In Russ.). DOI: 10.31249/scis/2024.01.02
10. Fomicheva T.L. Parallel import: Russian specifics. *Innovation and Investment*. 2024;4:361-363. URL: <https://www.elabrary.ru/ckhcpo> (In Russ.).
11. Khromova I.N., Svyatkina K.N., Khovyatskaya E.A. Application of artificial intelligence in the context of digital business transformation. *Bulletin of the Academy of Knowledge*. 2024;1:342-345. URL: <https://www.elabrary.ru/gikrpa>
12. Chebukhanova L.V. Artificial Intelligence and its Impact on the Financial Instruments Transformation. *Bulletin of the Academy of Knowledge*. 2024;5:486-491. URL: <https://www.elabrary.ru/gqhftm>
13. Shipulev E.O. The impact of artificial intelligence on social communication: the transformation of interaction in the digital age. *Humanitarian Scientific Journal*. 2025;1-1:61-64. URL: <https://www.elabrary.ru/edhuta>

ИНФОРМАЦИЯ ОБ АВТОРЕ / ABOUT THE AUTHOR

Рамазан Магомедович Магомедов — кандидат педагогических наук, доцент, доцент кафедры математики и анализа данных, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Ramazan M. Magomedov — Cand. Sci. (Ped.), Associate Professor, Associate Professor of the Department of Mathematics and Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0003-1290-3816>

Rmagomedov@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 в редакцию 13.10.2025; принята к публикации 24.11.2025.

Автор прочитал и одобрил окончательный вариант рукописи.

The article was submitted on 13.10.2025; accepted for publication on 24.11.2025.

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



Прогнозирование урожайности в регионах юга России с использованием инструментов искусственного интеллекта

С.В. Шайтура^a, Н.П. Семичевская^b, Н.С. Шайтура^c

^a Технологический университет им. дважды Героя Советского Союза, летчика-космонавта А.А. Леонова, Московская область, г. Королев, Российская Федерация;

^b Московский государственный университет технологий и управления им. К.Г. Разумовского (ПКУ), Москва, Российская Федерация;

^c Российский государственный аграрный университет – МСХА им. К.А. Тимирязева, Москва, Российская Федерация

АННОТАЦИЯ

В статье рассматриваются современные подходы к прогнозированию урожайности сельскохозяйственных культур в аграрных регионах юга России с использованием технологий искусственного интеллекта (нейронных сетей). Актуальность темы обусловлена высокой значимостью южных регионов (Краснодарский и Ставропольский край, Ростовская область и др.) в продовольственной безопасности России и необходимостью оперативного и точного прогнозирования урожая. Цель данной работы – разработать, применить и сделать оценку моделей прогнозирования урожайности сельскохозяйственных культур на юге России с использованием методов искусственного интеллекта, основанных на нейронных сетях различного типа. Рассмотрены методология и инструментарий применения нейросетевых алгоритмов (LSTM, CNN, MLP) для прогнозирования урожайности на основе данных 2020–2025 гг., включая статистические показатели урожайности, метеорологические данные и индексы растительности (NDVI). Представлены результаты моделирования, демонстрирующие преимущество LSTM-модели по точности прогноза по сравнению с другими моделями. Приведены графики и таблицы, иллюстрирующие фактическую и прогнозируемую урожайность, а также сравнительный анализ ошибок моделей. Проведена оценка результатов – сравнительная точность и ошибки прогнозов различных моделей. Рассмотрены ограничения проведенного исследования, к которым относятся непредставительность контрольных выборок, а также несовершенство системы сбора статистической информации. В связи с этим предложены направления дальнейших исследований, таких как расширение объема данных, обработка и подготовка данных к анализу, использование гибридных моделей, улучшение интерпретируемости моделей. Ключевые слова: урожайность сельскохозяйственных культур; прогнозирование урожайности; нелинейная регрессионная модель; полиномиальная регрессионная модель; нейронная сеть; многослойный перцептрон; сверточная нейронная сеть; карта нормализованного вегетационного индекса; рекуррентная нейронная сеть

Для цитирования: Шайтура С.В., Семичевская Н.П., Шайтура Н.С. Прогнозирование урожайности в регионах юга России с использованием инструментов искусственного интеллекта. Цифровые решения и технологии искусственного интеллекта. 2025;1(4):76-85. DOI: 10.26794/3033-7097-2025-1-4-76-85

ORIGINAL PAPER

Predicting Crop Yields in the Southern Regions of Russia with Artificial Intelligence Tools

S.V. Shaitura^a, N.P. Semichevskaya^b, N.S. Shaitura^c

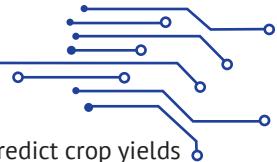
^a Leonov University of Technology, Korolev, Moscow Region, Russian Federation;

^b K.G. Razumovsky Moscow State University of Technologies and Management, Moscow, Russian Federation;

^c Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, Moscow, Russian Federation

ABSTRACT

The article discusses modern approaches to predicting crop yields in the agricultural regions of southern Russia using artificial intelligence technologies (neural networks). The relevance of this topic is due to the high importance of the southern regions (Krasnodar Territory, Stavropol Territory, Rostov Region, etc.) in Russia's food security, and the need for prompt and accurate crop forecasting. The purpose of this work is to develop, apply and evaluate models for predicting crop yields in southern Russia using artificial intelligence methods based on various types of neural networks.



Methodology and tools of neural network algorithms application (LSTM, CNN, MLP) are considered to predict crop yields based on data from 2020 to 2025, including statistical indicators of crop yields, meteorological data, and vegetation indices (NDVI). **The article presents the results** of modeling, which demonstrate the advantage of the LSTM model in terms of prediction accuracy compared to other models. The results section includes graphs and tables that illustrate the actual and predicted crop yields, as well as a comparative analysis of the model errors.

Keywords: crop yield; yield prediction; nonlinear regression model: polynomial regression model; neural network; multilayer perceptron; convolutional neural network; normalized vegetation index map; recurrent neural network

For citation: Shaitura S.V., Semichevskaya N.P., Shaitura N.S. Predicting crop yields in the southern regions of Russia with artificial intelligence tools. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(4):76-85. DOI: 10.26794/3033-7097-2025-1-4-76-85

ВВЕДЕНИЕ

Прогнозирование урожайности сельскохозяйственных культур является одной из ключевых задач аграрного сектора, особенно для регионов с интенсивным земледелием, таких как юг России.

Ростовская область, Краснодарский и Ставропольский края традиционно занимают лидирующие позиции по производству зерновых культур (пшеница, рожь, ячмень, овес) и являются важнейшей компонентой продовольственной безопасности страны. От точности прогнозов урожая в этих регионах зависит планирование продовольственных ресурсов, экспортного потенциала и ценовой стабильности.

Решение задачи прогнозирования урожайности культур может потенциально повысить саму урожайность за счет выполнения следующих мероприятий в сельскохозяйственных регионах:

- определение состояния растений, которое визуально незаметно, применяя аппаратные методы визуализации;
- выделение проблемных участков уже на ранних этапах вегетации путем применения методов компьютерного зрения и аэрофотосъемки;
- планирование методов обработки посевов (пересева, дополнительной подпитки);
- контроль появления сорных растений сразу после проведения посева, так как сорняки активнее набирают массу и хорошо отображаются в спектре;
- установление растений, которые возделывались в данном месте в предыдущие периоды и какие растут сейчас;
- точечное применение фосфорных, калийных и азотных удобрений на основе определения проблемных зон посредством индексов вегетации и последующего забора почвы на анализ;
- своевременная идентификация болезней и вредителей в период, когда повреждения еще не заметны визуально, путем применения методов распознавания и компьютерной идентификации.

Актуальность применения искусственного интеллекта и нейросетевых технологий для решения задачи прогнозирования урожайности обусловлена несколькими факторами. Во-первых, традиционные

методы прогнозирования (агрометеорологические и статистические модели) не всегда обеспечивают требуемую точность и оперативность. Математические модели, построенные на нейросетевых алгоритмах, способны выявлять скрытые нелинейные зависимости между урожайностью и множеством влияющих факторов (погодные условия, агротехнологии, состояние посевов и др.), что повышает точность прогнозов [1–3]. Во-вторых, последние годы характеризуются бурным развитием цифровых технологий в сельском хозяйстве — от спутникового мониторинга полей до систем точного земледелия, что обеспечивает приток высокочастотных и детализированных пространственных данных [4–6].

Цель данной работы заключается в разработке модели прогнозирования урожайности сельскохозяйственных культур на юге России с использованием методов искусственного интеллекта, основанных на нейронных сетях различного типа. Для достижения цели решены задачи: сбор и подготовка данных по урожайности в регионах юга России за 2020–2025 гг.; разработка моделей (MLP, CNN, LSTM); обучение и тестирование на актуальных, фактических данных; сравнение точности и ошибок; анализ преимуществ и ограничений подходов; формулировка рекомендаций.

МЕТОДЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ИССЛЕДОВАНИИ ПРОГНОЗИРОВАНИЯ УРОЖАЙНОСТИ

В данном исследовании применялся комплекс методов искусственного интеллекта, главным образом различные архитектуры искусственных нейронных сетей.

1. Многослойный перцептрон (MLP) — это класс искусственных нейронных сетей прямого распространения. В исследовании на нейронной сети построена модель, имитирующая зависимость урожайности от набора признаков. MLP как минимум состоит из трех слоев. Конфигурация сети MLP: два скрытых слоя по 32 нейрона, ReLU, выход с линейной активацией; оптимизация — Adam; функция потерь — MSE. Модель обучалась на исторических данных 2020–2024 гг. и служила базовым нейросе-



тевым бенчмарком. Многослойный перцептрон является популярным инструментом анализа данных и входит в платформы для бизнес-аналитики [13].

2. Сверточная нейронная сеть (CNN) — специализированный тип глубоких нейронных сетей, предназначенных для эффективного распознавания образов, данная сеть входит в технологию глубокого обучения. Сеть CNN в исследовании применена для анализа пространственных данных, а именно данных на картах нормализованного вегетационного индекса (NDVI). Архитектура сети CNN: несколько сверточных слоев (ядро 3×3) с пулингом, затем полносвязный блок для регрессии урожайности. CNN обучалась на парах «спутниковое изображение участка — фактическая урожайность» [3–7].

3. Рекуррентная сеть LSTM — специализированный тип рекуррентной нейронной сети RNN, используемой для запоминания и обработки долгосрочных зависимостей в последовательностях данных временной динамики. В исследовании рекуррентная сеть LSTM использовалась для анализа временной динамики по последовательности NDVI и собранных данных по метеопоказателям в течение сезона [5]. Архитектура сети LSTM: два LSTM-слоя (50 и 20 ячеек) и выходной плотный слой; оптимизатор — Adam; функция потерь — MSE. LSTM использует механизмы памяти для выделения существенных межфазовых закономерностей роста сельскохозяйственной культуры [7–10].

В качестве дополнительных сравнительных методов для анализа прогнозных значений использовалась полиномиальная регрессионная модель, для построения которой были собраны статистические данные из официальных статистических источников.

Для предотвращения переобучения применялись кросс-валидация по годам, регуляризация (dropout 0,2; L2), ранняя остановка. Качество оценивали по RMSE, MAPE и R^2 . Предварительная нормализация и отбор признаков выполнены на основе анализа корреляций и важности (в том числе SHAP для MLP).

ОБЛАСТЬ ИССЛЕДОВАНИЯ

Областью исследования являются аграрные регионы юга Российской Федерации: Республики Адыгея, Калмыкия, Крым, Краснодарский край, Астраханская, Волгоградская и Ростовская области и город Севастополь. Для проведения анализа урожайности были выбраны южные регионы (Краснодарский и Ставропольский края, Ростовская область). Для этих регионов характерен умеренно континентальный климат с мягкой зимой и теплым продолжительным летом; при годовых осадках 400–700 мм доминируют весенне-летние.

Почвенно-ландшафтный фонд представлен высокоплодородными черноземами, что определяет высокий потенциальный уровень урожайности. Структура посевов включала озимую пшеницу (как индикаторную культуру), ячмень, кукурузу, подсолнечник, сахарную свеклу. Период анализа 2020–2025 гг. охватывает годы с различными погодными режимами, что важно для устойчивого обучения моделей и получения прогнозных значений на 2025 г. [3–6].

СБОР ДАННЫХ ОБ УРОЖАЙНОСТИ КУЛЬТУР

Опишем систему сбора и обработки данных об урожайности культур, так как от нее зависит качество всей системы прогнозирования урожайности в южных регионах Российской Федерации. Структура Южного федерального округа представлена тремя республиками, тремя областями, одним краем и одним городом федерального значения. Для исследования урожайности сельскохозяйственных культур выбирались данные по трем объектам: Краснодарский край, Ставропольский край, Ростовская область.

Инструментальными средствами сбора статистических данных послужили статистические данные по урожайности сельскохозяйственных культур в сельскохозяйственных организациях Южного федерального округа по указанным объектам.

По данным сформированы следующие группы данных (выборки).

- Статистические показатели урожайности культур по регионам за 2020–2024 гг. (ц/га), предварительные данные за 2025 г. прогнозировались методом полиномиальной регрессии (рис. 1); валовые сборы использовались для контроля. Эти данные выступали целевыми переменными.

- Метеорологические данные: месячные и сезонные суммы осадков, средние температуры, сумма активных температур ($>+10^{\circ}\text{C}$), индикаторы экстремальных явлений. Агрегация по региону.

- Дистанционное зондирование: индексы NDVI (и доп. EVI/VHI) по данным Sentinel-2/MODIS; рассчитаны среднемесячные ряды и интегральные показатели (максимум NDVI за сезон, площадь под кривой NDVI). Использовались готовые продукты и расчеты в специализированных сервисах спутникового мониторинга («ВЕГА» и др.) [1, 4, 5, 10–12].

- Агротехнические факторы: индикаторы орошения, приблизительные оценки применения удобрений, доли элитных семян, предшественники (на региональном уровне — укрупненно) [13–15].

Для расширения выборки применено синтетическое моделирование сценариев погодных комбина-



ций с эмпирическим откликом урожайности; затем дообучение на фактических данных 2020–2024 гг. Все количественные признаки нормированы; категориальные (регионы) закодированы.

Результаты прогноза урожайности культур на 2025 г. по регрессионной модели представлены на рис. 1.

ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ И ИНСТРУМЕНТЫ

Для реализации исследования использовалось специальное программное обеспечение и комплекс технических средств.

Индекс NDVI (Normalized Difference Vegetation Index) — нормализованный относительный индекс растительности, он определяется как количественный показатель фотосинтетически активной биомассы на участке поверхности Земли. Индекс рассчитывается на основе данных спутниковых фотоснимков или аэрофотоснимков, полученных с беспилотных аппаратов [1, 2, 4, 5].

Карта NDVI может быть получена с помощью следующих видео- и фотооборудования: фотоаппарат, БВС «Альбатрос М», геодезическое GNSS оборудование, мультиспектральная камера для получения нормализованного вегетационного индекса NDVI. В результате имеем визуальную карту местности, карту с индексом NDVI и детальный

ортфотоплан полей, что позволяет дать качественный прогноз с диапазоном отклонений от фактических данных от 4 до 20%. Показатели представляются с географической точечной привязкой, выполненной в формате KMZ, geoTIF или в других форматах SHP, JPG. Методика расчетов индекса NDVI позволяет определить состояние посевов на местности со сложным рельефом и присутствием объектов природного и неприродного происхождения, причем четко определяются искусственные материалы (асфальт, бетон), а также естественные водные источники, участки со снежным покровом, разряженных растений и незасеянные почвенные участки. Используются программы по распознаванию объектов на фотоснимках. Пример полученных и обработанных изображений с визуализацией засеянных полей представлен на рис. 2.

Используются библиотеки на языке программирования Python: NumPy — библиотека для работы с массивами большой размерности, с помощью этой библиотеки обрабатываются статистические данные по урожайности культур; Pandas — программная библиотека для обработки и анализа структурированных наборов данных (панельных данных), сформированных как многомерные массивы; Matplotlib — библиотека для работы с графикой, подключение которой позволяет визуализировать анализ данных; geodata-стек для обработки гео-

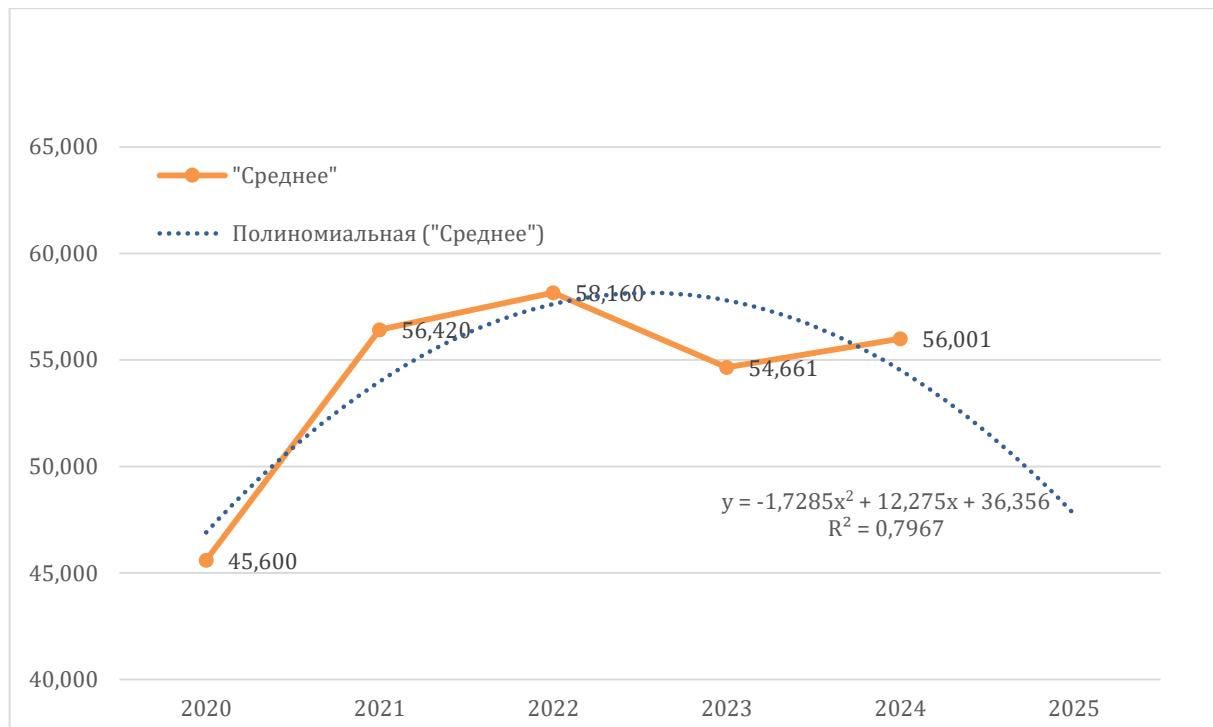


Рис. 1 / Fig. 1. Фактическая и прогнозируемая урожайность культур (2020–2024 гг.), ц/га / Actual and Predicted Crop Yields of Agricultural Culture (2020–2024 гг.)

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



данных (rasterio/GDAL — инструмент для создания нейросетей, для геопространственной обработки данных, GeoPandas — библиотека для работы с пространственными данными); фреймворки глубинного обучения TensorFlow/Keras предоставляет мощные инструменты для создания и обучения нейронных сетей, выполнения различных задач машинного обучения и PyTorch — фреймворк для глубинного обучения, при котором используются многослойные обучаемые модели и нейронные сети. При проведении эксперимента использованы random_state — генератор случайных чисел в алгоритмах машинного обучения и MLflow — платформа для управления жизненным циклом машинного обучения, которая регистрирует параметры, метрики и артефакты проводимого эксперимента, включая random_state.

Программная реализация нейронных сетей выполнена на языке Python с использованием следующих библиотек и инструментов NumPy, Pandas, Matplotlib, geodata-стек (rasterio/GDAL, GeoPandas),

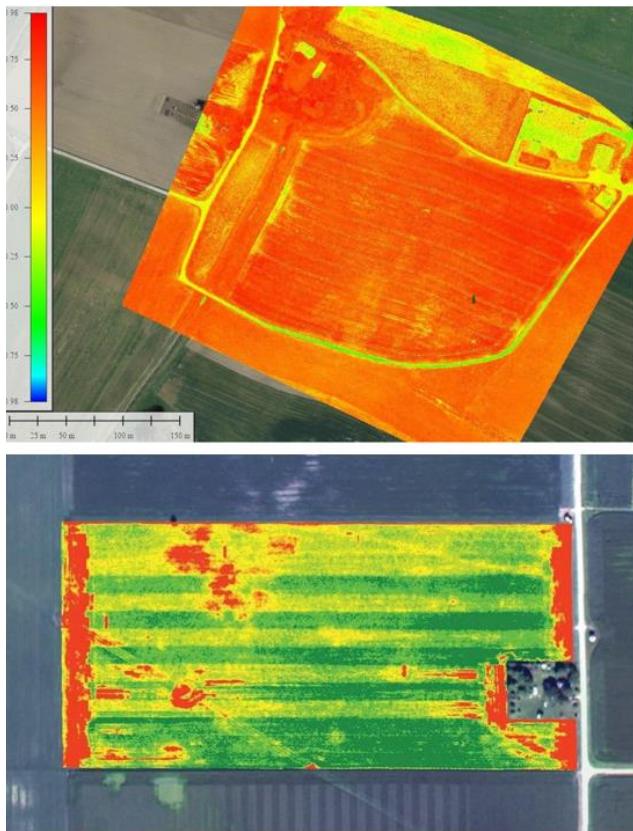


Рис. 2 / Fig. 2. Графическая интерпретация данных об урожайности культур на картах NDVI / Graphical Interpretation of Agricultural Culture Crop Yields Data on NDVI Maps

Источник / Source: карты NDVI. ООО «Альбатрос». / NDVI Maps. Albatros. URL: <https://www.alb.aero/services/karta-ndvi/>

фреймворки глубинного обучения TensorFlow/Keras и PyTorch. Для репликации экспериментов использованы фиксированные random_state и MLflow для логирования метрик и артефактов. Спутниковые данные агрегировались через Earth Engine и профильные отечественные сервисы («ВЕГА»). Дополнительно для сравнительного анализа классических моделей временных рядов использовался пакет R (пакет forecast).

УЧЕТ ФАКТОРОВ, ВЛИЯЮЩИХ НА РЕЗУЛЬТАТЫ

В модель включены агрометеорологические показатели (осадки и температура по месяцам/сезонно), дистанционные индексы (максимальный NDVI, интегральный NDVI, фенологические характеристики), региональные эффекты (категориальный признак), ориентиры агротехники (уровень внесения удобрений, орошение). Анализ точности алгоритмов проводился алгоритмом машинного обучения Random Forest и SHAP для MLP, что показало доминирование NDVI (пик и интеграл), суммы осадков июня–июля, средней температуры июня и индикатора сдвига фенологий (ранняя/поздняя весна). Для частичной интерпретируемости модели LSTM визуализирован вклад временных шагов: максимальная чувствительность к NDVI мая–июня и к осадкам в июне. Признаки масштабированы, высоко коррелирующие агрегированы. Учтены риски аномалий (град, вспышки болезней) — частично отражаются в динамике NDVI, но требуют дальнейшей интеграции фитосанитарных данных [7–12].

РЕЗУЛЬТАТЫ ПРОГНОЗИРОВАНИЯ

Сравнение фактической и прогнозной урожайности культур по регионам показало, что все нейросетевые модели улавливают межгодовую динамику, но с варьируемой точностью. Наиболее точные оценки продемонстрировала модель LSTM, особенно при раннем прогнозировании (за 1,5–2 месяца до уборки ошибка возрастила лишь умеренно). Графическое сопоставление (рис. 3) иллюстрирует, что модель LSTM лучше воспроизводит экстремумы (низкая урожайность 2020 г., высокий уровень 2021 г.), тогда как перцептрон MLP склонен к сглаживанию.

Для оценки точности прогноза использовались такие показатели, как: RMSE — среднеквадратическая ошибка, MAPE — средняя абсолютная процентная ошибка между предсказанными и фактическими значениями и коэффициент детерминации R^2 — статистическая мера соответствия регрессионной модели фактическим данным. Анализ позволяет

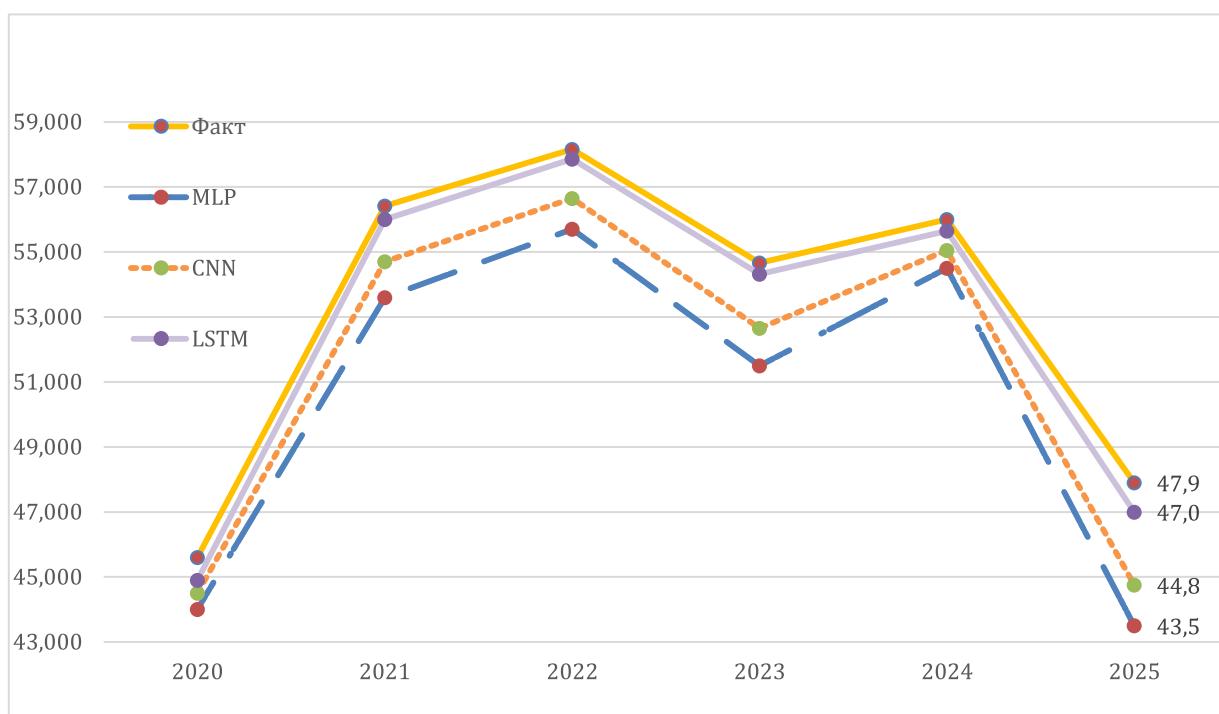


Рис. 3 / Fig. 3. Фактическая и прогнозируемая урожайность культур (2020–2024 гг.) на моделях нейросетей MLP, CNN, LSTM, ц/га / Actual and Predicted Agricultural Culture (2020–2024) Based on Neural Network Models MLP, CNN, LSTM, c/ha

Источник / Source: составлено авторами / Complied by authors.

установить статистическую значимость математических моделей искусственного интеллекта.

Количественные метрики приведены в таблице:

- модель LSTM показала $RMSE \approx 2,5$ ц/га, $MAPE \approx 5,5\%$, $R^2 \approx 0,92$;
- модель CNN — $RMSE \approx 3,0$ ц/га, $MAPE \approx 6\%$, $R^2 \approx 0,89$;
- модель MLP — $RMSE \approx 3,5$ ц/га, $MAPE \approx 7,5\%$, $R^2 \approx 0,85$;
- для линейной регрессии $RMSE \approx 5$ ц/га, $MAPE \approx 10,5\%$, $R^2 \approx 0,75$;
- для полиномиальной регрессионной модели $RMSE \approx 4,5$ ц/га, $MAPE \approx 10,0\%$, $R^2 \approx 0,79$.

Это соответствует представлениям о превосходстве рекуррентных архитектур в задачах временных рядов, т.е. рекуррентная сеть LSTM, используемая как модель для запоминания и обработки долгосрочных зависимостей в последовательностях данных временной динамики по последовательности NDVI и собранных данных по метеорологическим показателям в течение сезона, показала наиболее точный прогноз урожайности культур [7–9].

Ключевые аналитические выводы:

1) индекс NDVI в период выхода в трубку — колошение зерна является сильнейшим индикатором будущей урожайности культур;

2) сумма осадков в июне–июле критически влияет на налив зерна;

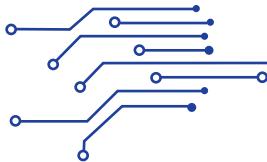
3) существуют значимые региональные эффекты (при прочих равных по Краснодарскому краю прогнозы выше, чем в Ростовской области, что отражает различия в почвенно-агротехнической базе);

4) по индексу NDVI выделяются проблемные участки уже на ранних этапах вегетации в южных регионах;

5) прогнозирование неурожайных ситуаций возможно уже по состоянию на конец мая при резком отставании NDVI от многолетней нормы.

Сравнительные метрики моделей полиномиальной регрессии и нейросетей MLP, CNN, LSTM показаны в таблице.

Полученные количественные метрики отражают в большей степени точность прогнозирования урожайности культур и никак не показывают ключевые особенности каждой построенной модели нейронных сетей, не дают точную оценку по архитектуре нейронной сети. Полиномиальная регрессионная модель была построена на основе статистических данных об урожайности за период 2020–2024 гг. в трех южных регионах России (Краснодарский край, Ставропольский край, Ростовская область). При построении моделей нейронных сетей использовался многофакторный анализ данных по следующим показателям: урожайность в регионах, метеорологические показатели, полученные индексы NDVI путем дистанционного зондирования



Сравнение качества прогноза по моделям (точность на тестовой выборке) / Comparison of Model Prediction Quality (Accuracy on the Test Set)

Модель / Model	RMSE, ц/га	MAPE, %	R 2
Полиномиальная регрессия	4,50	10,00	0,79
MLP (Перцептрон)	3,50	7,50	0,85
CNN (Сверточная сеть)	3,00	6,00	0,89
LSTM (Рекуррентная сеть)	2,5	5,50	0,92

Источник / Source: составлено авторами / Complied by authors.

ния и индикаторы по агротехническим факторам, влияющим на урожайность (индикаторы орошения, оценки применения удобрений, доли элитных семян, предшественники). Применение аппарата нейронных сетей позволило увеличить точность прогнозных моделей и выделить лучшую из трех моделей нейронных сетей.

ОБСУЖДЕНИЕ ПОЛУЧЕННЫХ РЕЗУЛЬТАТОВ

При получении результатов были учтены основные ограничения: 1) умеренный объем данных по урожайности сельскохозяйственных культур (2020–2025 гг., три региона) и частичная неоднородность источников; 2) неполный учет биотических факторов (болезни, вредители); 3) локальность моделей (адаптация под юг России); 4) ограниченная интерпретируемость. Можно выделить следующие направления развития: расширение временных рядов, т.е. увеличение временных диапазонов исследования урожайности культур; увеличение зон исследования и пространственно-го охвата; применение в дальнейшем гибридных нейросетевых архитектур (Conv LSTM, трансформеры), ансамблирование нейросетевых моделей CNN (перцептрон) и LSTM (сверточная сеть); интеграция в модели данных фитосанитарного мониторинга; внедрение оценок неопределенности

за счет построения статистических моделей (байесовские сети); использование пилотных облачных сервисов для хозяйств с регулярным обновлением прогноза.

Экономический эффект от внедрения автоматизированных систем прогнозирования на базе ИИ проявляется через оптимизацию процессов планирования, снижение рисков и повышение эффективности использования ресурсов в сельскохозяйственной деятельности [3–6, 13–15].

ВЫВОДЫ

Сравнительный анализ показателей оценочных метрик качества прогнозных моделей выявил статистически значимое преимущество модели LSTM над MLP (по критерию Вилкоксона сдвиг показателей одной модели более интенсивный, чем в другой модели, по парным ошибкам $p < 0,05$) и умеренное преимущество CNN над MLP. Интерпретируемость нейросетей обеспечивается частично (SHAP, анализ временных вкладов), однако для производственного внедрения предпочтительна интеграция модулей XAI. Стабильность результатов подтверждена тестами на независимых годах (2024 г.). Практическая значимость ошибки порядка 5–6% оценивается как достаточная для управленческих решений по логистике и страхованию урожая, превосходящая точность классических подходов [1–3, 7–13].

СПИСОК ИСТОЧНИКОВ

1. Лупян Е.А., Савин И.Ю., Барталев С.А., Толпин В.А., Балашов И.В. и др. Спутниковый сервис мониторинга состояния растительности («ВЕГА»). *Современные проблемы дистанционного зондирования Земли из космоса*. 2011;8(1):190–198. URL: <https://elibrary.ru/nvvwbl>
2. Савин И.Ю., Барталев С.А., Лупян Е.А., Толпин В.А. Прогнозирование урожайности сельскохозяйственных культур на основе спутниковых данных: возможности и перспективы. *Современные проблемы дистанционного зондирования Земли из космоса*. 2010;7(3):275–285. URL: <https://elibrary.ru/nctyazf>
3. Тарасов А.Н., Исаева О.В., Холодова М.А. Аграрный сектор юга России: современные тенденции и перспективы развития. Ростов-на-Дону: Азов-Принт; 2020. 112 с. DOI: 10.34924/FRARC.2020.45.18.001



4. Барталев С.А., Лупян Е.А., Савин И.Ю. Дистанционная оценка параметров сельскохозяйственных земель по данным MODIS. *Современные проблемы дистанционного зондирования Земли из космоса*. 2004;1(1):113–123. URL: <https://elibrary.ru/ndpnt1>
5. Ерошенко Ф.В., Барталев С.А., Сторчак И.Г., Плотников Д.Е. Возможности дистанционной оценки урожайности озимой пшеницы на основе вегетационного индекса фотосинтетического потенциала. *Современные проблемы дистанционного зондирования Земли из космоса*. 2016;13(4):99–112. DOI: 10.21046/2070-7401-2016-13-23-99-112
6. Сторчак И.Г., Ерошенко Ф.В. Использование NDVI для оценки продуктивности озимой пшеницы в Ставропольском крае. *Земледелие*. 2014;7:12–15. URL: <http://jurzemledelie.ru/arkhiv-nomerov/7-2014/662-ispolzovanie-ndvi-dlya-otsenki-produktivnosti-ozimoj-pshenitsy-v-stavropolskom-krae>
7. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997;9(8):1735–1780. DOI: 10.1162/neco.1997.9.8.1735
8. Gers F., Schmidhuber J., Cummins F. Learning to Forget: Continual Prediction with LSTM. *Neural Computation*. 2000;12(10):2451–2471. DOI: 10.1162/089976600300015015
9. Karim F., Majumdar S., Darabi H., Chen S. LSTM Fully Convolutional Networks for Time Series Classification. *IEEE Access*. 2018;6:1662–1669. DOI: 10.1109/ACCESS.2017.2779939
10. Денисов П.В., Иванов А.Б., Мишурев Н.П., Петухов Д.А., Подъяблонский П.А. и др. Прогнозирование урожайности озимой пшеницы с использованием технологий дистанционного зондирования Земли. *Управление рисками в АПК*. 2021;39:37–45. DOI: 10.53988/24136573-2021-01-03
11. Бондур В.Г., Гороховский К.Ю., Игнатьев В.Ю., Мурынин А.Б., Гапонова Е.В. Метод прогнозирования урожайности по космическим наблюдениям за динамикой развития вегетации. *Известия высших учебных заведений. Геодезия и аэрофотосъемка*. 2013;6:61–68. URL: <https://elibrary.ru/uicycwn>
12. Лупян Е.А., Барталев С.А., Крашенинникова Ю.С., Плотников Д.Е., Толпин В.А. и др. Спутниковый сервис «ВЕГА»: методы и примеры использования в АПК. *Современные проблемы дистанционного зондирования Земли из космоса*. 2015;12(5):231–247. URL: <https://elibrary.ru/thxydn>
13. Шайтура С.В., Герасимов В.А. Методы проведения интеллектуального анализа данных. *Славянский форум*. 2022;4(38):421–429. URL: <https://elibrary.ru/xwuxw>
14. Шайтура С.В., Семичевская Н.П., Белю Л.П. Анализ процессов цифровизации социально-экономических систем. *Вопросы региональной экономики*. 2024;4(61):197–212. URL: <https://elibrary.ru/jaeyhr>
15. Николаева С.Г., Семичевская Н.П., Кошкина Л.Ю. Анализ больших данных в экономике: применение и перспективы. *Экономика и управление: проблемы, решения*. 2025;11(3)(156):188–192. DOI: 10.36871/ek.up.p.r.2025.03.11.018

REFERENCES

1. Lupyan E.A., Savin I. Yu., Bartalev S.A., Tolpin V.A., Balashov I.V., Plotnikov D.E. Satellite service for vegetation monitoring VEGA. *Sovremennye Problemy Distantionnogo Zondirovaniya Zemli iz Kosmosa* [Modern Problems of Earth Remote Sensing from Space]. 2011;8(1):190–198. URL: <https://elibrary.ru/nvvwbl> (In Russ.).
2. Savin I. Yu., Bartalev S.A., Lupyan E.A., Tolpin V.A. Crop yields forecasting based on satellite data: opportunities and prospects. *Sovremennye Problemy Distantionnogo Zondirovaniya Zemli iz Kosmosa* [Modern Problems of Earth Remote Sensing from Space]. 2010;7(3):275–285. URL: <https://elibrary.ru/ncyazf> (In Russ.).
3. Tarasov A.N., Isaeva O.V., Kholodova M.A. The agrarian sector of the south of Russia: current trends and development prospects. Rostov-on-Don: Azov-Print; 2020. 112 p. (In Russ.). DOI: 10.34924/FRARC.2020.45.18.001
4. Bartalev S.A., Lupyan E.A., Savin I. Yu. Remote Assessment of Agricultural Land Parameters Using MODIS Data. *Sovremennye Problemy Distantionnogo Zondirovaniya Zemli iz Kosmosa* [Modern Problems of Earth Remote Sensing from Space]. 2004;1(1):113–123. URL: <https://elibrary.ru/ndpnt1> (In Russ.).
5. Eroshenko F.V., Bartalev S.A., Storchak I.G., Plotnikov D.E. The possibility of winter wheat yield estimation based on vegetation index of photosynthetic potential derived from remote sensing data. *Sovremennye Problemy Distantionnogo Zondirovaniya Zemli iz Kosmosa* [Modern Problems of Earth Remote Sensing from Space]. 2016;13(4):99–112. (In Russ.). DOI: 10.21046/2070-7401-2016-13-23-99-112
6. Storchak I.G., Eroshenko F.V. Using of NDVI for assessing productivity of winter wheat in Stavropol region. *Agriculture*. 2014;7:12–15. URL: <http://jurzemledelie.ru/arkhiv-nomerov/7-2014/662-ispolzovanie-ndvi-dlya-otsenki-produktivnosti-ozimoj-pshenitsy-v-stavropolskom-krae> (In Russ.).
7. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997;9(8):1735–1780. DOI: 10.1162/neco.1997.9.8.1735



8. Gers F., Schmidhuber J., Cummins F. Learning to Forget: Continual Prediction with LSTM. *Neural Computation*. 2000;12(10):2451-2471. DOI: 10.1162/089976600300015015
9. Karim F., Majumdar S., Darabi H., Chen S. LSTM Fully Convolutional Networks for Time Series Classification. *IEEE Access*. 2018;6:1662–1669. DOI: 10.1109/ACCESS.2017.2779939
10. Denisov P.V., Ivanov A.B., Mishurov N.P., Petukhov D.A., Podyablonskiy P.A. et al. Forecasting the yield of winter wheat using remote sensing technologies. *Agricultural Risk Management*. 2021;39:37–45. (In Russ.). DOI: 10.53988/24136573-2021-01-03
11. Bondur V.G., Gorokhovsky K. Yu., Ignatiev V. Yu., Murynin A.B., Gaponova E.V. Method of Yield Forecasting Based on Space Observations of Vegetation Dynamics. *Izvestia Vuzov. Geodesy and Aerophotogrammetry*. 2013;6:61–68. URL: <https://elibrary.ru/uiycwn> (In Russ.).
12. Lupyany E.A., Bartalev S.A., Krasheninnikova Yu.S., Plotnikov D.E., Tolpin V.A. et al. VEGA satellite service applications in regional remote monitoring systems. *Sovremennye Problemy Distantionnogo Zondirovaniya Zemli iz Kosmosa* [Modern Problems of Earth Remote Sensing from Space]. 2015;12(5):231–247. URL: <https://elibrary.ru/thxydn> (In Russ.).
13. Shaitura S.V., Gerasimov V.A. Data Mining Methods. *Slavic Forum*. 2022;4(38):421-429. URL: <https://elibrary.ru/xwuxwa> (In Russ.).
14. Shaitura S.V., Semichevskaya N.P., Belyu L.P. Analysis of the Processes of Digitalization of Socio-Economic Systems. *Problems of Regional Economy*. 2024;4(61):197–212. URL: <https://elibrary.ru/jaeyhr> (In Russ.).
15. Nikolaeva S.G., Semichevskaya N.P., Koshkina L. Yu. Big data analysis in economy: application and prospects. *Economics and Management: Problems, Solutions*. 2025;11(3)(156):188–192. (In Russ.). DOI: 10.36871/ek.up.p.r.2025.03.11.018

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Сергей Владимирович Шайтура — кандидат технических наук, доцент кафедры информационных технологий и управляемых систем, Технологический университет имени дважды Героя Советского Союза, летчика-космонавта А.А. Леонова, г. Королев, Московская область, Российская Федерация

Sergey V. Shaitura — Cand. Sci. (Tech.), Assoc. Prof. of the Department of Information Technologies and Control System, Leonov University of Technology, Korolev, Moscow Region, Russian Federation, Korolev, Moscow Region, Russian Federation

<https://orcid.org/0000-0002-5621-5460>

Автор для корреспонденции / Corresponding author:

swshaytura@gmail.com

Наталья Петровна Семичевская — кандидат технических наук, доцент, доцент кафедры информационных систем и цифровых технологий, Московский государственный университет технологий и управления имени К.Г. Разумовского (ПКУ), Москва, Российская Федерация

Nataliya P. Semichevskaya — Cand. Sci. (Tech.), Assoc. Prof., Assoc. Prof. of the Department of Information Systems and Digital Technologies, K.G. Razumovsky Moscow State University of Technologies and Management, Moscow, Russian Federation

<https://orcid.org/0009-0001-2577-3363>

npsem@mail.ru

Наталья Сергеевна Шайтура — кандидат физико-математических наук, старший преподаватель кафедры высшей математики, Российский государственный аграрный университет — МСХА имени К.А. Тимирязева, Москва, Российская Федерация

Nataliya S. Shaitura — Cand. Sci. (Phys.-Math.), Senior Lecturer of the Higher Mathematics Department, Russian State Agrarian University — Moscow Timiryazev Agricultural Academy, Moscow, Russian Federation

<https://orcid.org/0000-0002-9422-910X>

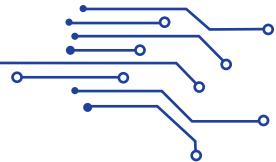
tesh-s@yandex.ru

Заявленный вклад авторов:

С.В. Шайтура — разработка общей концепции статьи и технической части.

Н.П. Семичевская — описание общей теоретической части, проверка и описание математических моделей, выкладок и аналитической части.

Н.С. Шайтура — разработка алгоритмов, сбор и обработка данных, предоставление результатов и участие в обсуждениях и выводах.



Authors declared contributions:

S.V. Shaitura — development of the general concept of the article and the technical part.

N.P. Semichevskaya — description of the general theoretical part, verification of mathematical models, calculations, and the analytical part.

N.S. Shaitura — data collection and processing, reporting results, and participation in discussions and conclusions.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

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

Статья поступила в редакцию 13.10.2025; принятa к публикации 24.11.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 13.10.2025; accepted for publication on 24.11.2025.

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



Теоретическое решение модели неопределенности опережающих данных

И.Ю. Варяш^a, Д.В. Климонов^b

^a Научно-исследовательский финансовый институт Министерства финансов Российской Федерации,
Москва, Российской Федерации;

^b Московский университет «Синергия», Москва, Российской Федерации

АННОТАЦИЯ

В статье предлагается теоретическое решение переменной неопределенности в расчетах опережающих индикаторов на примере экономических данных, ожидаемых деловыми сообществами. Предлагаемый авторами подход позволяет решить проблему, имеющуюся в технологии обработки первичных данных мнений деловых сообществ, что является актуальным для максимального привлечения значимой информации в принятии решений. **Цель статьи** – продемонстрировать результаты решения модели инкапсуляции и декапсуляции информации с неопределенными исходами. В качестве метода исследования применялось построение нелинейных парных уравнений регрессии временных последовательностей экономико-статистической и социологической информации. Рассматриваются условия модели с временными последовательностями независимой неопределенной переменной, обсуждается верификация и оценка качества модели. Исследование проводилось в 1993–2025 гг. на базах Банка России и Научно-исследовательского финансового института Министерства финансов РФ (НИФИ). Источниками информации являются Московская межбанковская валютная биржа, платформа Investing.com, аналитические подразделения коммерческих банков и брокерских организаций. Модель строилась на сплошной выборке данных прогнозов и мнений участников срочных рынков. **Основные результаты**, полученные при решении модели, свидетельствуют о существенном повышении (на 40%) тестирования точности классификации для машинного обучения нейросети поиска и предобработки данных биржевой торговли. Показано преимущество решения множественной модели парных уравнений регрессии с использованием временной последовательности ожидаемых деловыми сообществами значений экономического показателя, включая деинкапсулированную неопределенную переменную по отношению к стандартным решениям парных уравнений регрессии.

Ключевые слова: информатика; экономика; опережающие индикаторы; стратегическое планирование; биржевой анализ

Для цитирования: Варяш И.Ю., Климонов Д.В. Теоретическое решение модели неопределенности опережающих данных. Цифровые решения и технологии искусственного интеллекта. 2025;1(4):86-92. DOI: 10.26794/3033-7097-2025-1-4-86-92

ORIGINAL PAPER

Solving an Uncertainty Model Using Leading Data Synthesis

И.Ю. Varjas^a, Д.В. Климонов^b

^{a,b} Research Financial Institute of the Ministry of Finance of the Russian Federation, Moscow, Russian Federation;

^b Moscow University “Synergy”, Moscow, Russian Federation

ABSTRACT

This article proposes a theoretical solution to the problem of overcoming variable uncertainty in leading indicator calculations using economic data expected by business communities as an example. The novelty of the proposed approach lies in its ability to fill a gap in the technology for processing primary data on business community opinions, which is essential for maximizing the utilization of information relevant for decision making. **The objective of this article** is to present the results of solving a model for encapsulating and decapsulating information with uncertain outcomes. The research method was to construct nonlinear paired regression equations for time series of economic, statistical, and sociological information. The conditions of the model with time series of an independent uncertain variable are examined, and verification and quality assessment of the model are discussed. The study was conducted from 1993 to 2025 using the Bank of Russia and the National Research Financial Institute (NIFI) databases. The data sources included the Moscow Interbank Currency Exchange, Investing, and the analytical departments of commercial banks and brokerage firms. The model was built on a continuous sample of forecast data and opinions from participants in the derivatives markets. **The conclusion presents** the key results of the model solution, which include a significant increase (by 40%) in the classification accuracy testing for machine learning of the neural network for searching and preprocessing exchange trading data. The advantages of solving a multiple paired regression equation model using a time series of economic indicator values expected by business communities, including a de-encapsulated uncertain variable, are discussed relative to standard solutions of paired regression equations.

Keywords: computer science; economics; leading indicators; strategic planning; exchange analysis

For citation: Varjas I.Yu., Klimonov D.V. Solving an uncertainty model using leading data synthesis. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(4):86-92. DOI: 10.26794/3033-7097-2025-1-4-86-92



ВВЕДЕНИЕ

В расчетах опережающих экономических и финансовых индикаторов преобладают балансовый и диффузный методы. Им присущ весьма существенный недостаток, а именно игнорирование доли ответов участников опросов об ожидаемой деловой активности. В итоге при обработке результатов не учитывается часть информации, что некорректно с методологической точки зрения. Как показывают тестирование и компьютерные эксперименты, подобные методы искажают результат, требуя избыточного резервирования под риски. Кроме этого, на протяжении 30 лет наблюдается сохранение преобладающего значения зоны неопределенности в распределении первичных данных по альтернативам предполагающихся векторов изменений. Этот факт послужил основой для теоретического исследования модели расчета опережающих индикаторов с учетом зоны неопределенности.

Цель настоящей работы заключается в теоретическом решении проблемы преодоления неопределенности переменной в расчетах опережающих индикаторов экономических данных. Исходные уравнения расчетов опережающих индикаторов от балансового и диффузного к диффузному рассматриваются с точки зрения перспектив изменений с использованием *V*-распределения доли неопределенных ответов. Составляются нелинейные парные уравнения регрессии временных последовательностей экономико-статистической и социологической информации. Условия модели исследуются с временными последовательностями независимой неопределенной переменной. Представлена верификация и оценка качества модели.

Основные результаты решения модели показывают существенное повышение (на 40%) тестирования точности классификации для машинного обучения нейросети поиска и предобработки данных биржевой торговли. Также продемонстрированы преимущества решения множественной модели парных уравнений регрессии с использованием временной последовательности ожидаемых деловыми сообществами значений экономического показателя, включая деинкапсулированную неопределенную переменную по отношению к стандартным решениям парных уравнений регрессии.

ОБЗОР РЕШЕНИЙ МОДЕЛИ РАСЧЕТА ОПЕРЕЖАЮЩИХ ИНДИКАТОРОВ

В данном исследовании используется термин «преактивность» в отношении экономических показателей, чтобы отличать опережающие индикаторы¹ от так на-

зываемых опережающих показателей [1, 2] текущих ожиданий в деловых сообществах, объединяемых совместными производственно-кооперационными и финансово-хозяйственными циклами. Особенностью преактивных моделей является использование социологического метода агрегирования мнений руководителей предприятий о будущих изменениях ключевых параметров финансового-хозяйственной деятельности, обращаемых в формат численных значений соответствующих будущих статистический показателей.

Исключение² переменной неопределенности из расчета опережающих индикаторов балансовым методом оказалось существенной методологической проблемой [3]. Применение диффузного метода ухудшило сходимость опережающих индикаторов со статистикой, еще больше искажив конечный результат [3].

В определенном смысле макропрогнозные эконометрические модели являются частным случаем преактивных моделей, в скрытом виде они в той или иной степени используют экспертные оценки для параметризации и верификации моделей³ [4–6]. Обратимся к общим и частным различиям макропрогнозных и преактивных моделей.

Для общего случая преактивных моделей важно учитывать асимметрию рынка. Тогда по методологии теоретические рекомендации и диапазоны задаются коэффициентами, для учета различий которых применяются экспертные суждения и байесовская оценка. Коэффициенты эластичности в случаях нелинейных моделей корректируются с помощью дополнительных исследований или экспертных суждений. Диагностика калибровки модели с измененными коэффициентами может проводиться с помощью анализа функций импульсных откликов, прогнозов внутри выборки и анализа декомпозиций переменных, используя фильтр Калмана [7].

При другом подходе используются классические уравнения с включением неопределенной переменной в прогнозное уравнение регрессии. Предлагается трактовать качественные переменные в противоположность значащим переменным, отражающим количественную сторону показателя, как индикаторы уровня задачи. Экономический смысл введения в модель фиктивных переменных заключается в учете факторов, способных повлиять на структуру связей

² В статье опираемся на информационную теорию инкапсуляции/деинкапсуляции данных. Инкапсуляция (программирование). Знание. Вики. URL: <https://znanierussia.ru/articles>

³ Business Tendency and Consumer Opinion Surveys (MEI): Business tendency surveys. OESD. URL: <https://stats.oecd.org/Index.aspx?QueryId=4783>

¹ Агрегированные мнения топ-менеджмента предприятий о предполагаемых условиях финансово-хозяйственной деятельности [1].



между значащими переменными. При их изменении будут наблюдаться скачкообразные изменения параметров регрессионной (по информационной терминологии) модели.

РЕШЕНИЕ МОДЕЛИ ПАРНЫХ НЕЛИНЕЙНЫХ УРАВНЕНИЙ МНОЖЕСТВЕННОЙ РЕГРЕССИИ

В качестве неопределенных переменных предлагаются использовать дихотомические переменные. Коэффициент регрессии при неопределенной переменной интерпретируется как среднее изменение зависимой переменной при переходе от одного уровня к другому при неизменных значениях других факторов [8]. На основе t -критерия Стьюдента можно сделать вывод о значимости влияния неопределенной переменной на зависимую переменную или существенном их расхождении на разных уровнях обобщения примеров решения модели.

Предлагаемый нестандартный подход решения преактивной модели основан на парных нелинейных уравнениях регрессии, содержащих временные последовательности регрессии, включая неопределенные переменные. В результате решения получают интервальные величины. Необходимо отметить, что благодаря диффузной модели ожиданий с распределенной неопределенной переменной модель носит вероятностный характер [7]. Таким образом парные нелинейные уравнения относятся к множественной регрессии. Эту схему модели обозначим, как *преактивную модель филиситации*⁴.

Необходимо обратить внимание, что для получения ожидаемых численных значений существуют определенные проблемы парных нелинейных уравнений множественной регрессии. Так, предполагается, что использование кривой регрессии вне пределов наблюдаемого диапазона значений объясняющей переменной может привести к значительным погрешностям временных последовательностей зависимой переменной. Однако опыт показывает, что приближение теоретической временной последовательности к ожидаемой деловыми сообществами увеличивает сходимость со статистическим рядом.

Некорректно заключение о том, что точечный прогноз не реален. Использование доверительного интервала возможно и имеет экономический смысл лишь относительно точечного значения для каждого временного периода, входящего в найденную их выборку. Но верно и то, что для расчета фактически двух доверительных интервалов по отношению к точечно-му прогнозу необходимы дополнительные расчеты.

Требуют экономической интерпретации те случаи, когда на долю факторных признаков приходится меньшая их часть по сравнению с остальными неучтеными в модели факторами, влияющими на изменение результирующего показателя. Построенные при таких условиях множественные регрессионные уравнения модели не могут не иметь практического смысла, так как свидетельствуют о релевантности ожиданий деловых сообществ относительно сложившихся экономических процессов. И, как правило, ожидания делового сообщества оказываются более реальными, чем экстраполяция инерционных следов прошлых экономических событий, какими бы сильными они не представлялись в настоящем. В случаях, когда при значениях показателей тесноты связи меньше 0,7 индекс детерминации нелинейной модели ниже 50%, это требует дополнительного экономического анализа.

УСЛОВИЯ МОДЕЛИ МНОЖЕСТВЕННОЙ ПАРНОЙ РЕГРЕССИИ. ЗАМЕНА ПЕРЕМЕННЫХ

Для оценки параметров регрессии, нелинейной относительно включенной в уравнение объясняющей переменной, но линейной по оцениваемым параметрам, используется подход, называемый «замена переменных». В этом случае нелинейные объясняющие переменные заменяются линейными переменными, соответствующими предположениям Гаусса–Маркова. В случае исследования интервальной регрессии, если исследуемая переменная не участвовала в заменах переменных, то полученный прогнозный интервал является конечным результатом прогнозирования. При замене исследуемой переменной с помощью обратной замены необходимо вычислить прогнозный интервал для исходной исследуемой переменной.

Исследуемая нелинейная множественная парная регрессия охватывает два качественно разных параметра – статистический динамический (временной) ряд, приведенный к приростной форме (в %) уравнений второго порядка и ряд ожидаемого показателя (в %), рассчитанного с использованием приростного опережающего индикатора (в %) в уравнениях первого порядка. В соответствии с предварительно проведенным тестированием доказана правомочность использования косвенной регрессии [9].

При исследовании парных уравнений регрессии стараются избегать непосредственного использования нелинейных уравнений. Действительно, громоздкие математические решения в этом случае обременяют модель избыточной сложностью, практически малосущественной для слишком большого в экономике интервала неопределенности, обусловливаемого весьма широким кругом разной степени косвенности

⁴ The International Association of Facilitators, IAF. URL: <https://www.iaf-world.org>



факторов, реально мало и редко учитывающихся при принятии решений. Однако с одним исключением, а именно — для совместно вырабатываемых решений требуются агрегаты (фисилитация) мнений субъектов хозяйствования (EMI⁵), которые в высшей степени заинтересованы в учете своего мотивированного суждения. Ради них стоит усложнить модель, тем более что новый компонент соответствует логике предположений Гаусса–Маркова⁶.

ВЕРИФИКАЦИЯ КАЧЕСТВА МОДЕЛИ

Исследование модели с включением опережающего индикатора ожиданий опирается на эконометрическую схему множественных нелинейных парных уравнений регрессии [9]. В литературе она приводится в конечном счете к точечной парной регрессии, представляющей среднее значений зависимой переменной y , рассматриваемой как функции одной независимой переменной (регрессора) x и случайной величины ε :

$$y = \pi f(x) + \varepsilon, \quad (1)$$

где величина ε назначается случайной и предиктирует случайность y . Разбиение y на объяснимую $f(x)$ и ε неучтенных уравнением парной регрессии ($\tilde{y} = f(x)$) факторов сопровождается элиминированием неопределенности y . Для ε вводятся предположения Гаусса–Маркова, а также полагается нормальный закон распределения вероятностей с нулевым математическим ожиданием и постоянной дисперсией, что, однако, не соответствует исследуемой неопределенной переменной ожиданий.

Для верификации модели с неопределенной переменной ожиданий может быть использовано оценивание степени подгонки теоретических значений $\tilde{y}_i = f(x_i)$ к ожидаемым данным y_i , или коэффициент рассеивания точки корреляционного поля относительно линии регрессии. Для анализа общего качества уравнения нелинейной регрессии используется индекс детерминации [10], который придает размерность влиянию фактора на результат, фиксируя одновременно и роль ошибок. Величина $R^2 = r_{xy}^2$ характеризует долю дисперсии переменной y , вызванную влиянием прочих неучтенных в модели факторов.

Считается, что в большинстве экономических задач регрессор не может принять нулевое или даже близкое к 0 значение. Свободный член линейной регрессии относят к неинтерпретируемым параметрам из-за

⁵ MEI — Market Estimates Indicators (индикатор ожиданий рынка), — агрегированная величина оценки руководителями производства будущих результатов финансово-хозяйственной деятельности.

⁶ The International Association of Facilitators, IAF. URL: <https://www.iaf-world.org>

того, что его не удается проверить экспериментально. Однако экономический смысл интерпретации коэффициента регрессии b как эластичности по ожиданиям дает возможность оценить его экспериментально.

Методом оценки адекватности модели экспериментальным наблюдениям ожиданий и статистики может служить коэффициент (индекс) детерминации, как доля дисперсии, объясняемая регрессией, в общей дисперсии результативного признака y . Индекс детерминации равен квадрату коэффициента линейной парной корреляции:

$$R^2 := \frac{Var(\tilde{y})}{Var(y)}. \quad (2)$$

При использовании оценки адекватности модели в расчете средней ошибки аппроксимации необходимо учитывать, что условие предела значений среднего отклонения расчетных значений от фактических не более 8–10% представляется избыточно жестким. При повышательном изменении параметров показателя ожидания несколько преувеличиваются за счет преуменьшения понижательных ожиданий, и, наоборот, при понижательном тренде ожидания несколько преувеличивают возможное снижение показателя, хотя и в меньшей степени, чем преувеличиваются повышательные ожидания. Кроме того, при снижении положительных ожиданий может складываться иное соотношение понижательной и повышательной волатильности показателя, и наоборот. Поэтому в обоих случаях необходимо вводить поправочные коэффициенты на основании исследования моделей архивных данных в найденной выборочной совокупности временных последовательностей в каждом конкретном примере решения уравнения:

$$\bar{A} := \frac{1}{n} \beta \sum \left| \frac{y_x - \tilde{y}_x}{y_x} \right|. \quad (3)$$

В случае с временными последовательностями ожиданий проблема мультиколлинеарности не возникает, так как отдельные факторы связаны между собой стохастически, а не линейно, что подтверждается корреляционным анализом, в результате которого исключительные случаи линейной зависимости ($K = 1$) отвергаются.

Для оценки адекватности уравнения регрессии также используется показатель средней ошибки аппроксимации. Ошибка аппроксимации не более 12% свидетельствует о подобии прогноза с ожиданиями, а выход за указанные пределы — о рисках при реализации прогноза, что требует ревизии условий модели.

Считается, что интервальный прогноз реалистичен в пределах диапазона исходных данных, а экстраполяция кривой регрессии не оправдывает себя в случаях ее использования вне пределов наблюдаемого диапа-



зона 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 данном 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 длинным 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 накладывает отпечаток значительное количество участников наблюдения и мультиплекция отмечаемых ими событий, учтенных в исходных данных и агрегируемых в преактивных параметрах [11–13], а также суммирование временных периодов в микроциклах, что отвечает условию увеличения числа наблюдений при усложнении вида функции.

В ежемесячном преактивном агрегате представлены 4–5 микроциклов. Согласно социологической теории в выборке необходимо иметь не менее 54 респондентов, а число наблюдений в каждый момент переменной x составляет 250–300 событий, что достаточно для признания статистической значимости модели, в том числе с точки зрения ее репрезентативности и скедастичности.

Перенос измеренной в варьирующей совокупности в статистике 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 экспертиных оценок, использующихся для подтверждения возможности их отнесения к будущему.

ВЫВОДЫ

Исследование модели с неопределенной временной последовательностью ожидаемого параметра показывает, что использование таких последовательностей упрощает ее, а не усложняет, позволяя

отказываться от избыточного применения формальных методов оценки корректности расчетов параметров будущего в социальных системах.

Рассматриваемая схема модели избавляет от необходимости избыточной ее верификации и обеспечивает более лаконичное решение проблемы оценки статистической значимости. В ряде временной последовательности неопределенных ожиданий имплицитно учтены экономические смыслы и их взаимосвязанности.

Кроме того, благодаря самообучению модели с помощью автоматизированной системы поиска и обработки первичных данных, в том числе анализа больших данных, в режиме реального времени формируются оценки, изменяющиеся при добавлении в исходную выборку новых данных для расчета силы (весов) факторов. Содержательное решение проблемы оценки статистической значимости, разумеется, не исключает дополнительной верификации модели обычными методами, в том числе, например применением F -критерия Фишера. Но также требует интерпретации экономического смысла получаемых численных значений.

Основной вывод из сравнения рассмотренных вариантов методологии моделирования финансово-экономических процессов состоит в том, что любое включение мнений деловых сообществ в прогнозные модели улучшает ее качество. Степень улучшения тем больше, чем большее значение им придается с помощью эконометрических преобразований социально-экономического смысла.

Этот результат достигается путем использования временных последовательностей показателей, приведения их к единой размерности, перенесением верификации модели и оценки качества модели ожидаемых параметров экономики и финансов на прогнозную модель. Для биржевой торговли особенно важно то, что в модели парных уравнений регрессии используется интерактивный вариант представления результатов.

Качество модели, выполненной методом парных уравнений регрессии с инверсионным вектором ожидаемых параметров, оценивается экономическими смыслами не в меньшей мере, чем формально-логическими критериями. Указанные преимущества существенно увеличивают глубину предположений без потери подобия с соответствующей догоняющей статистикой.

Использование парных уравнений регрессии дает возможность оценить наиболее вероятный тренд развития событий в результате осуществления монетарной политики с максимальным уменьшением избыточных трансакционных издержек, и в первую очередь резервирования средств



под риски, которые имеют относительно малую вероятность.

Модель нуждается в обучении фактически в режиме реального времени, поскольку множественность независимых переменных изменяется неравномерно и сопряжена с трудностями автоматизации обучения из-за шоков численных значений данных и их выборок, которые в данном примере нельзя трактовать как случайные ошибки.

Весьма существенно, что интервальное соотношение в парах уравнений регрессии, делящих-

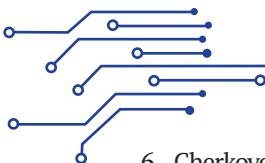
ся на прогнозную (классическую) и фактическую (ожиданий), показывает критически важные границы численных значений, в которых решение о коррекции экономической политики будет более всего вероятным в изменяющихся условиях. Разработка преактивных микроэкономических моделей расширяет возможности макропрогнозирования и придает им дополнительный экономический смысл развития стратегического планирования, коррекции дорожных карт и научно обоснованного принятия текущих решений.

СПИСОК ИСТОЧНИКОВ

1. Варьаш И.Ю. Контроллинг экономических ожиданий. М.: Финуниверситет; 2012. 176 с. URL: <https://elibrary.ru/qvimen>
2. Varyash I. Yu. The Planning System: Market and Centralization. *Review of Business and Economics Studies*. 2022;10(3):18–25. DOI: 10.26794/2587-5671-2022-10-3-18-25
3. Варьаш И.Ю., Зубец А.Н. Оценка опережающих индикаторов экономической деятельности в Российской Федерации по методологии ОЭСР. *Вопросы статистики*. 2016;11:31–36. URL: <https://elibrary.ru/nliwpa>
4. Варьаш И.Ю., Логвинов С.А., Ильинский А.И., Донцова О.И. Макропланирование экономического развития. Динамическая модель опережающих индикаторов. Монография. Николаев: Изд-во Ирины Гудим; 2014. 157 с. URL: <https://elibrary.ru/nliwpa>
5. Платов В.Я., Платова О.В., Золотарева С.Е. Технология стратегического планирования и управления. М.: Изд-во «Дело»; 2013. 372 с. URL: <https://elibrary.ru/qvcyal>
6. Черковец В.Н. К ренессансу планомерного функционирования и развития экономики России. *Вестн. Моск. Ун-та. Серия 6: Экономика*. 2015;2:56–65. URL: <https://elibrary.ru/tthiin>
7. Kalman R.E. A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*. 1960;82(1):35–45. DOI: 10.1115/1.3662552
8. Котенко А.П., Кузнецова О.А. Эконометрика. Парная регрессия. Методические указания к лабораторным работам. Самара: Изд-во Самарского университета; 2016. 49 с. URL: <https://repo.ssau.ru/bitstream/Metodicheskie-materialy/Ekonometrika-Parnaya-regressiya-Elektronnyi-resurs-metod-ukazaniya-k-lab-rabotam-68633/1> Котенко А.П. Эконометрика. Парная регрессия.pdf
9. Варьаш И.Ю., Бурова Т.Ф., Панасенко К.К. Исследование моделей опережающих индикаторов условий финансирования. *Chronos. Экономические науки*. 2019;1(15):100–114. URL: <https://elibrary.ru/njzzlv>
10. Чесноков С.В. Детерминационный анализ социально-экономических данных. М.: URSS; 2009. 168 с. URL: <https://elibrary.ru/qteedx>
11. Демидова О.А., Карнаухова Е.Е., Коршунов Д.А., Мясников А.А., Серегина С.Ф. Асимметричные эффекты денежно-кредитной политики в регионах России. *Вопросы экономики*. 2021;6:77–102. DOI: 10.32609/0042-8736-2021-6-77-102
12. Анохин П.К. Системный анализ интегративной деятельности нейрона. *Успехи физиологических наук*. 1974;5(5):5–92.
13. Анохин П.К. Избранные труды. Системные механизмы высшей нервной деятельности. М.: Наука; 1979. 453 с. URL: <https://djvu.online/file/IVz0OfxMDP16r>

REFERENCES

1. Varyash I. Yu. Controlling economic expectations. Moscow: Finuniversitet; 2012. 176 p. URL: <https://elibrary.ru/qvimen> (In Russ.).
2. Varyash I. Yu. The Planning System: Market and Centralization. *Review of Business and Economics Studies*. 2022;10(3):18–25. DOI: 10.26794/2587-5671-2022-10-3-18-25
3. Varjas I. Yu., Zubec A.N. Evaluation of leading indicators of economic activity in the Russian Federation using OECD methodology. *Voprosy Statistiki*. 2016;11:31–36. URL: <https://elibrary.ru/nliwpa> (In Russ.).
4. Varyash I. Yu., Logvinov S.A., Ilyinsky A.I., Dontsova O.I. Macroeconomic planning: a dynamic model of leading indicators. Nikolaev: Publishing Hous of Irina Gudim; 2014. 157 p. URL: <https://elibrary.ru/nliwpa> (In Russ.).
5. Platov V. Ya., Platova O.V., Zolotareva S.E. Technology of strategic planning and management. Moscow: Publishing House “Delo”; 2013. 372 p. URL: <https://elibrary.ru/qvcyal> (In Russ.).



6. Cherkovets V.N. To the renaissance of orderly functioning and development of the Russian economy. *Moscow University Economics Bulletin*. 2015;2:56–65. URL: <https://elibrary.ru/tthiin> (In Russ.).
7. Kalman R.E. A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*. 1960;82(1):35–45. DOI: 10.1115/1.3662552
8. Kotenko A.P., Kuznetsova O.A. Econometrics. Paired Regression: Lab Guidelines. Samara: Samara University Publishing House; 2016. 2016. 49 p. URL: <https://repo.ssau.ru/bitstream/Metodicheskie-materialy/Ekonometrika-Parnaya-regressiya-Elektronnyi-resurs-metod-ukazaniya-k-lab-rabotam-68633/1>/Котенко А.П. Эконометрика. Парная регрессия.pdf (In Russ.).
9. Varyash I. Yu., Burova T.F., Panasenko K.K. A study of leading indicator models of financing conditions. *Chronos. Economics*. 2019;1(15):100–114. URL: <https://elibrary.ru/njzzlv> (In Russ.).
10. Chesnokov S.V. Determinative analysis of socio-economic data. Moscow: URSS; 2009. 168 p. URL: <https://elibrary.ru/qteedx> (In Russ.).
11. Demidova O.A., Karnaughova E.E., Korshunov D.A., Myasnikov A.A., Seregina S.F. Asymmetric effects of monetary policy in Russia. *Voprosy Ekonomiki*. 2021;6:77–102. (In Russ.). DOI: 10.32609/0042-8736-2021-6-77-102
12. Anokhin P.K., Corson S.A. & Corson E.O. Systems analysis of the integrative activity of the neuron. *The Pavlovian Journal of Biological Science: official journal of the Pavlovian*. 1984;19:43–101. (In Eng.). DOI: 10.1007/BF03003132
13. Anokhin P.K. Selected works. Systemic mechanisms of higher nervous activity. Moscow: Nauka; 1979. 453 p. URL: <https://djvu.online/file/iVz0OfxMDP16r> (In Russ.).

СВЕДЕНИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

Игорь Юрьевич Варяш — 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

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

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

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

Статья поступила в редакцию 13.10.2025; принята к публикации 24.11.2025.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 13.10.2025; accepted for publication on 24.11.2025.

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