

ISSN 2518-1092

НАУЧНЫЙ РЕЗУЛЬТАТ

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

RESEARCH RESULT. INFORMATION TECHNOLOGY

11(3) 2026

16+

Сайт журнала:
rinformation.ru
сетевой научный рецензируемый журнал
online scholarly peer-reviewed journal



Журнал зарегистрирован в Федеральной службе по надзору в сфере связи, информационных технологий и массовых коммуникаций (Роскомнадзор)
Свидетельство о регистрации средства массовой информации Эл. № ФС77-69101 от 14 марта 2017 г.
Журнал включен в Перечень ВАК рецензируемых научных изданий, в которых должны быть опубликованы основные научные результаты диссертаций на соискание ученых степеней кандидата и доктора наук (1.2.1. Искусственный интеллект и машинное обучение, 2.3.1. Системный анализ, управление и обработка информации, статистика).
Журнал зарегистрирован в Российском индексе научного цитирования (РИНЦ).
The journal has been registered at the Federal service for supervision of communications information technology and mass media (Roskomnadzor)
Mass media registration certificate El. № FS 77-69101 of March 14, 2017
The journal is included into the List of Higher Attestation Commission of peer-reviewed scientific publications where the main scientific results of dissertations for obtaining scientific degrees of a candidate and doctor of science should be
(1.2.1. Artificial Intelligence and machine learning, 2.3.1. The system analysis, management and information processing, statistics).
The journal is introduced in Russian Science Citation Index (RSCI).



Том 11, № 3. 2026



Volume 11, № 3. 2026

СЕТЕВОЙ НАУЧНО-ПРАКТИЧЕСКИЙ ЖУРНАЛ

Издается с 2016 г.

ISSN 2518-1092

ONLINE SCHOLARLY PEER-REVIEWED JOURNAL

First published online: 2016

ISSN 2518-1092

РЕДАКЦИОННАЯ КОЛЛЕГИЯ:

ГЛАВНЫЙ РЕДАКТОР: **Жихарев А.Г.**, доктор технических наук, доцент, профессор кафедры информационно-телекоммуникационных систем и технологий Белгородского государственного национального исследовательского университета (г. Белгород, Россия).

ЗАМЕСТИТЕЛЬ ГЛАВНОГО РЕДАКТОРА: **Черноморец А.А.**, доктор технических наук, доцент, профессор кафедры прикладной информатики и информационных технологий Белгородского государственного национального исследовательского университета (г. Белгород, Россия).

ОТВЕТСТВЕННЫЙ СЕКРЕТАРЬ: **Болгова Е.В.**, кандидат технических наук, доцент, доцент кафедры прикладной информатики и информационных технологий Белгородского государственного национального исследовательского университета (г. Белгород, Россия).

РЕДАКТОР АНГЛИЙСКИХ ТЕКСТОВ: **Ляшенко И.В.**, кандидат филологических наук, доцент, доцент кафедры английской филологии и межкультурной коммуникации Белгородского государственного национального исследовательского университета (г. Белгород, Россия).

ЧЛЕНЫ РЕДАКЦИОННОЙ КОЛЛЕГИИ:

Басов О.О., доктор технических наук, доцент, исполнительный директор (Общество с ограниченной ответственностью «СПИЧАП», г. Санкт-Петербург, Россия).

Белов С.П., доктор технических наук, профессор (Белгородский государственный национальный исследовательский университет, г. Белгород, Россия).

Волчков В.П., доктор технических наук, профессор (Московский технический университет связи и информатики, г. Москва, Россия).

Иващук О.А., доктор технических наук, профессор (Белгородский государственный национальный исследовательский университет, г. Белгород, Россия).

Калмыков И.А., доктор технических наук, профессор (Северо-Кавказский федеральный университет, г. Ставрополь, Россия).

Корсунов Н.И., заслуженный деятель науки РФ, доктор технических наук, профессор (Белгородский государственный национальный исследовательский университет, г. Белгород, Россия).

Коськин А.В., доктор технических наук, профессор (Орловский государственный университет им. И.С. Тургенева, г. Орел, Россия).

Ломазов В.А., доктор физико-математических наук, профессор (Белгородский государственный аграрный университет им. В.Я. Горина, г. Белгород, Россия).

Маторин С.И., доктор технических наук, профессор (Белгородский государственный национальный исследовательский университет, г. Белгород, Россия).

Наджаджра М.Х., кандидат технических наук, профессор кафедры информационных систем управления (Университет Аль-Истикляль, г. Иерихон, Палестина).

Орлова Ю.А., доктор технических наук, доцент (Волгоградский государственный технический университет, г. Волгоград, Россия).

Таранчук В.Б., доктор физико-математических наук, профессор, (Белорусский государственный университет, г. Минск, Республика Беларусь).

EDITORIAL TEAM:

EDITOR-IN-CHIEF: **Alexander G. Zhikharev**, Doctor of Technical Sciences, Associate Professor, Professor of the Department of Information and Telecommunication Systems and Technologies, Belgorod State National Research University (Belgorod, Russia).

DEPUTY EDITOR-IN-CHIEF: **Andrey A. Chernomorets**, Doctor of Technical Sciences, Associate Professor, Professor of the Department of Applied Informatics and Information Technology, Belgorod State National Research University (Belgorod, Russia).

EXECUTIVE SECRETARY: **Evgeniya V. Bolgova**, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Applied Informatics and Information Technology, Belgorod State National Research University (Belgorod, Russia).

ENGLISH TEXT EDITOR: **Igor V. Lyashenko**, Candidate of Philological Sciences, Associate Professor, Associate Professor of the Department of English Philology and Intercultural Communication, Belgorod State National Research University (Belgorod, Russia).

EDITORIAL BOARD:

Oleg O. Basov, Doctor of Technical Sciences, Associate Professor (Limited Liability Company «SPEECHUP», Saint Petersburg, Russia).

Sergey P. Belov, Doctor of Technical Sciences, Professor (Belgorod State National Research University, Belgorod, Russia).

Valery P. Volchikov, Doctor of Technical Sciences, Professor (Moscow Technical University of Communications and Informatics, Moscow, Russia).

Olga A. Ivaschuk, Doctor of Technical Sciences, Professor (Belgorod State National Research University, Belgorod, Russia).

Igor A. Kalmykov, Doctor of Technical Sciences, Professor (North Caucasus Federal University, Stavropol, Russia).

Nikolay I. Korsunov, Honoured Science Worker of Russian Federation, Doctor of Technical Sciences, Professor (Belgorod State National Research University, Belgorod, Russia).

Alexander V. Koskin, Doctor of Technical Sciences, Professor (Orel State University named after I.S. Turgenev, Orel, Russia).

Vadim A. Lomazov, Doctor of Physical and Mathematical Sciences, Professor (Gorin Belgorod State Agrarian University, Belgorod, Russia).

Sergey I. Matorin, Doctor of Technical Sciences, Professor (Belgorod State National Research University, Belgorod, Russia).

Mohammed H. Najajra, Candidate of Technical Sciences (Al Istiqlal University, Jericho, Palestine).

Yulia A. Orlova, Doctor of Technical Science, Associate Professor (Volgograd State Technical University, Volgograd, Russia).

Valery B. Taranchuk, Doctor of Physical and Mathematical Sciences, Professor (Belarusian State University, Minsk, Belarus).

Учредитель: Федеральное государственное автономное образовательное учреждение высшего образования
«Белгородский государственный национальный исследовательский университет»
Издатель: НИУ «БелГУ». Адрес издателя: 308015 г. Белгород, ул. Победы, 85.
Журнал выходит 4 раза в год

Founder: Federal state autonomous educational establishment of higher education
«Belgorod State National Research University»
Publisher: Belgorod State National Research University
Address of publisher: 85 Pobeda St., Belgorod, 308015, Russia
Publication frequency: 4/year

СОДЕРЖАНИЕ

CONTENTS

ИНФОРМАЦИОННЫЕ СИСТЕМЫ
И ТЕХНОЛОГИИINFORMATION SYSTEM
AND TECHNOLOGIES

Сысоев Р.В., Антамошкин О.А. Применение интегральной аппроксимации к мультимодальным функциям	3	Sysoev R.V., Antamoshkin O.A. Application of Integral Approximation to Multimodal Functions	3
---	----------	---	----------

АВТОМАТИЗАЦИЯ И УПРАВЛЕНИЕ

AUTOMATION AND CONTROL

Рыбанов А.А., Кузминский М.С. Разработка веб-интерфейса административного управления распределенной сетью устройств сбора батареек и аккумуляторов на основе RESTful API	11	Rybanov A.A., Kuzminsky M.S. Development of a web interface for administrative management of a distributed network of battery and accumulator collection devices based on the RESTful API	11
--	-----------	---	-----------

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ
И ПРИНЯТИЕ РЕШЕНИЙARTIFICIAL INTELLIGENCE
AND DECISION MAKING

Великая Я.Г., Медведев А.Э., Васильев П.В., Михелев В.М. Применение методов машинного обучения при создании ассистивной интеллектуальной системы для людей с нарушениями слуха	28	Velikaya Ya.G., Medvedev A.E., Vassiliev P.V., Mikhelev V.M. Applying Machine Learning Techniques to the Development of Assistive Intelligent System for the Hearing Impaired	28
Левина Т.М., Беляков Я.В. Оптимизация гибридного алгоритма поиска в текстовых корпусах на основе многоуровневых метрик релевантности	41	Levina T.M., Belyakov Ya.V. Optimization of a Hybrid Search Algorithm in Text Corpora Based on Multi-Level Relevance Metrics	41
Чашин Ю.Г., Ширяев А.А. Исследование метода прогнозирования цены акции на основе евклидова расстояния	49	Chashin Y.G., Ширяев А.А. Investigation of a Stock Price Forecasting Method Based on Euclidean Distance	49
Низамли Я., Филатов А.Ю., Фадел В., Шичкина Ю.А. Оценка валидности общедоступных наборов данных МРТ для нейроонкологического обнаружения аномалий: выявление критических проблем качества данных	59	Nizamli Ya., Filatov A.Yu., Fadel W., Shichkina Yu.A. Validity Assessment of Public MRI Datasets for Neuro-Oncological Abnormality Detection: Uncovering Critical Data Quality Issues	59
Монгуш М.А. Параллелизация вычислений в жидких нейронных сетях с сохранением гарантий устойчивости	75	Mongush M.A. Parallelization of Computations in Liquid Neural Networks with Preservation of Stability Guarantees	75
Ивашко К.С., Изосимова С.А., Пигуз В.Н., Ковалева К.В., Киосева Е.В. Инновационные методы и лингвистические подходы ИИ для преодоления психологических травм	86	Ivashko K.S., Izosimova S.A., Piguz V.N., Kovaleva K.V., Kioseva E.V. Innovative Methods and Linguistic Approaches of AI for Overcoming Psychological Trauma	86

КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ

COMPUTER SIMULATION

Румбешт В.В., Бурданова Е.В. Описание комбинаторного алгоритма перечисления упорядоченных мультипликативных разложений	100	Rumbesht V.V., Burdanova E.V. Description of a Combinatorial Algorithm for Enumerating Ordered Multiplicative Factorizations	100
--	------------	--	------------

ИНФОРМАЦИОННЫЕ СИСТЕМЫ И ТЕХНОЛОГИИ INFORMATION SYSTEM AND TECHNOLOGIES

УДК 519.651

DOI: 10.18413/2518-1092-2026-11-3-0-1

**Сысоев Р.В.
Антамошкин О.А.**

**ПРИМЕНЕНИЕ ИНТЕГРАЛЬНОЙ АППРОКСИМАЦИИ
К МУЛЬТИМОДАЛЬНЫМ ФУНКЦИЯМ**

Сибирский Федеральный Университет,
пр. Свободный, 79, г. Красноярск, 660041, Россия

e-mail: romansw00@inbox.ru

Аннотация

В статье предлагается метод интегральной аппроксимации как эффективный инструмент для упрощения рельефа сложных функций, возникающих в задачах численной оптимизации. Традиционные методы оптимизации часто сталкиваются с трудностями при работе с функциями, обладающими большим количеством локальных экстремумов. Интегральная аппроксимация предлагает решение, заменяя исходную функцию более гладкой версией. В статье представлены результаты численных экспериментов, подтверждающих эффективность предложенного метода на наборе тестовых мультимодальных функций. В заключении авторы обсуждают перспективы дальнейшего развития метода и его потенциальное применение в различных областях, требующих эффективной оптимизации сложных функций.

Ключевые слова: интегральная аппроксимация; сглаживание функций; оптимизация; высокая размерность; гладкие аппроксимации

Для цитирования: Сысоев Р.В., Антамошкин О.А. Применение интегральной аппроксимации к мультимодальным функциям // Научный результат. Информационные технологии. – Т.11, №3, 2026. – С. 3-10. DOI: 10.18413/2518-1092-2026-11-3-0-1

**Sysoev R.V.
Antamoshkin O.A.**

**APPLICATION OF INTEGRAL APPROXIMATION
TO MULTIMODAL FUNCTIONS**

Siberian Federal University
79 Svobodnyj ave., Krasnoyarsk, 660041, Russia

e-mail: romansw00@inbox.ru

Abstract

The article proposes the method of integral approximation as an effective tool for simplifying the relief of complex functions arising in numerical optimization problems. Traditional optimization methods often face difficulties when working with functions that have a high degree of non-smoothness or a large number of local extremes. Integral approximation offers a solution by replacing the original function with a smoother integral version of it. The article presents the results of numerical experiments confirming the effectiveness of the proposed method on a set of test multimodal functions. In conclusion, the authors discuss the prospects for further development of the method and its potential application in various areas that require effective optimization of complex functions.

Keywords: integral approximation; smoothing of functions; optimization; high dimensionality; smooth approximations

For citation: Sysoev R.V., Antamoshkin O.A. Application of Integral Approximation to Multimodal Functions // Research result. Information technologies. – Т.11, №3, 2026. – P. 3-10. DOI: 10.18413/2518-1092-2026-11-3-0-1

ВВЕДЕНИЕ

В эпоху стремительного развития вычислительных технологий, оптимизация сложных функций является ключевой задачей во множестве областей, от машинного обучения и финансового моделирования до проектирования инженерных сооружений и поиска оптимальных параметров в физических симуляциях. Однако, многие реальные функции, с которыми приходится сталкиваться, обладают высокой сложностью, а также могут быть вычислительно затратными для прямого анализа и оптимизации [1-3]. В связи с этим, методы аппроксимации функций играют важную роль, позволяя заменять оригинальную сложную функцию более простой и управляемой моделью, сохраняя при этом достаточную точность для успешного применения алгоритмов оптимизации.

Большинство известных методов сглаживания [4-5], таких как гауссовы фильтры или регуляризованные аппроксимации, не учитывают специфическую геометрию целевой функции. В таких случаях, как методы наименьших квадратов, полиномиальные и кусочно-полиномиальные методики сглаживают только заданный диапазон координат. Мы предлагаем метод интегральной аппроксимации, который действителен на всей протяженности целевой функции, а также учитывает специфику каждой целевой функции тем, что значение аппроксимированной функции в каждой точке является средним значением исходной функции в соответствующей точке на заданном диапазоне.

В данной статье предложен новый метод интегральной аппроксимации, отличающийся от существующих, а также исследуется применимость метода интегральной аппроксимации функций, разработанного для повышения эффективности методов оптимизации в условиях высокой размерности и сложности целевых функций.

Целью данной работы является предоставить исследователям и практикам инструмент, способствующий более эффективному решению задач оптимизации, связанных с аппроксимацией сложных функций.

ОСНОВНАЯ ЧАСТЬ

Интегральная аппроксимация

Пусть $f: \mathbb{R}^N \rightarrow \mathbb{R}$ – измеримая и локально-интегрируемая функция, $S > 0$ – параметр, $X = (x_1, \dots, x_N) \in \mathbb{R}^N$. Определим функцию:

$$\bar{f}(X) = \int_{(x_1-S)}^{(x_1+S)} \dots \int_{(x_N-S)}^{(x_N+S)} f(X) dx_1 \dots dx_N$$

Тогда:

1. функция $\bar{f}(X, S)$ является средней интегральной аппроксимацией функции $f(X)$ в точке X , т.е. принимает значение среднего значения $f(X)$ на гиперкубе с центром в X и длиной ребра $2 * S$;
2. Если $f(X)$ непрерывна в точке X , то: $\lim_{S \rightarrow 0} \bar{f}(X, S) = f(X)$.

Структура работы

Данный метод подходит для сглаживания мультимодальных функций, некоторые из них будут рассмотрены далее. В последующий примерах будет приведено сравнение применения адаптивного метода оптимизации *Adam* (*Adaptive Moment Estimation*) для поиска минимума исходной и аппроксимированной функции при равных параметрах и исходной точки. Также, в конце каждого подраздела будет приведена визуализация путей поиска минимума функции, где черной линией будет представлен путь поиска по исходной функции $f(X)$, а красной поиск по сглаженной $\bar{f}(X)$.

Функция Растригина

Функция Растригина – это невыпуклая функция, которая часто используется в качестве тестовой функции для алгоритмов оптимизации, особенно эволюционных алгоритмов и методов глобальной оптимизации. Она была предложена Леонардом Растригиным в 1974 году [6].

Исходный вид функции:

$$f_1(x_1, x_2) = 20 * ((x_1^2 - 10 * \cos(2 * \pi * x_1)) + (x_2^2 - 10 * \cos(2 * \pi * x_2))) \quad (1.1)$$

Аппроксимированный вид, при значении $S = 3$:

$$\tilde{f}_1(x_1, x_2) = \int_{(x_1-S)}^{(x_1+S)} \int_{(x_2-S)}^{(x_2+S)} f_1(x_1, x_2) dx_1 dx_2 = 36 * x_1^2 + 36 * x_2^2 + 936 \quad (1.2)$$

Следует отметить – обновленная функция (уравнение 1.2) полностью избавлена от тригонометрической составляющей и представляет собой полусферу.

Функция имеет глобальный минимум в точке $X_{min} = (0, \dots, 0)$, где $f_1(X_{min}) = 0$. При исходных параметрах поиска:

- $X_0 = (-4, 4)$;
- $lr = 0.2$;
- $tolerance = 10^{-13}$;
- ограничении числа итераций в 1000.




Рис. 1. Пути поиска минимума функции Растригина с использованием исходной и аппроксимированной функции

Fig. 1. Paths to the minimum of the Rastrigin function using the original and approximated functions

Функция Экли

Функция Экли – это невыпуклая функция, широко используемая в качестве тестовой функции для алгоритмов оптимизации. Она была предложена Дэвидом Экли в его диссертации на соискание докторской степени в 1987 году [7].

Исходный вид функции:

$$f_2(x_1, x_2) = -20 * \exp\left(-0.2 * \sqrt{\frac{1}{2} * (x_1^2 + x_2^2)}\right) - \exp\left(\frac{1}{2} * (\cos(2 * \pi * x_1) + \cos(2 * \pi * x_2))\right) + 20 + e^1 \quad (2.1)$$

Аппроксимированный вид, при значении $S = 1$:

$$\tilde{f}_2(x_1, x_2) = \int_{(x_1-1)}^{(x_1+1)} \int_{(x_2-1)}^{(x_2+1)} f_2(x_1, x_2) dx_1 dx_2 \quad (2.2)$$

Функция имеет глобальный минимум в точке $X_{min} = (0, \dots, 0)$, где $f_1(X_{min}) = 0$. При исходных параметрах поиска:

- $X_0 = (-10, 10)$;
- $lr = 0.2$;
- $tolerance = 10^{-13}$;
- ограничении числа итераций в 1000.




Рис. 2. Пути поиска минимума функции Экли с использованием исходной и аппроксимированной функции

Fig. 2. Paths to the minimum of the Ackley function using the original and approximated functions

Функция «Cross-in-Tray»

Функция «Cross-in-Tray» – это двумерная тестовая функция, используемая для оценки алгоритмов глобальной оптимизации [8]. Она отличается своей сложностью и наличием нескольких глобальных минимумов.

Исходный вид функции:

$$f_3(x_1, x_2) = -0.0001 * \left(\left| \sin(x_1) * \sin(x_2) * \exp \left(\left| 100 - \frac{\sqrt{x_1^2 + x_2^2}}{\pi} \right| \right) \right| + 1 \right)^{0.1} \quad (3.1)$$

Аппроксимированный вид, при значении $S = \pi$:

$$\tilde{f}_3(x_1, x_2) = \int_{(x_1-\pi)}^{(x_1+\pi)} \int_{(x_2-\pi)}^{(x_2+\pi)} f_3(x_1, x_2) dx_1 dx_2 \quad (3.2)$$

Функция имеет глобальный минимум в точке $X_{min} = (0, \dots, 0)$, где $f_1(X_{min}) = 0$. При исходных параметрах поиска:

- $X_0 = (10, -10)$;
- $lr = 0.2$;
- $tolerance = 10^{-13}$;
- ограничении числа итераций в 1000.




Рис. 3. Пути поиска минимума функции «Cross-in-Tray» с использованием исходной и аппроксимированной функции

Fig. 3. Paths to the minimum of the "Cross-in-Tray" function using the original and approximated functions

Функция Гриуэнка

Функция Гриуэнка – многомерная тестовая функция, часто используемая для оценки производительности алгоритмов глобальной оптимизации[9]. Она известна своим умеренно сложным рельефом, включающим множество локальных минимумов, окружающих глобальный минимум.

Исходный вид функции:

$$f_4(x_1, x_2) = 1 + \frac{1}{4000} * (x_1^2 + x_2^2) - \left(\cos\left(\frac{x_1}{\sqrt{1}}\right) * \cos\left(\frac{x_2}{\sqrt{2}}\right) \right) \quad (4.1)$$

Аппроксимированный вид, при значении $S = \pi$:

$$\tilde{f}_4(x_1, x_2) = g_1(x_1, x_2) = \int_{(x_1-S)}^{(x_1+S)} \int_{(x_2-S)}^{(x_2+S)} f_4(x_1, x_2) dx_1 dx_2 = \frac{\pi^2 * (3 * x_1^2 + 3 * x_2^2 + 2 * \pi^2 + 12000)}{3000} \quad (4.2)$$

Отметим, что обновленная функция (уравнение 4.2) полностью избавлена от тригонометрической составляющей.

Функция имеет глобальный минимум в точке $X_{min} = (0, \dots, 0)$, где $f_1(X_{min}) = 0$. При исходных параметрах поиска:

- $X_0 = (-15, 20)$;
- $lr = 0.2$;
- $tolerance = 10^{-13}$;
- ограничении числа итераций в 1000.




Рис. 4. Пути поиска минимума функции Гриуэнка с использованием исходной и аппроксимированной функции

Fig. 4. Paths to the minimum of the Griewank function using the original and approximated functions

Функция Швевеля

Исходный вид функции Швевеля [10]:

$$f_5(x_1, x_2) = 418.9829 * 2 - \left((x_1 * \sin(\sqrt{|x_1|})) + (x_2 * \sin(\sqrt{|x_2|})) \right) \quad (4.3)$$

Аппроксимированная форма уравнения 4.1 представляет собой тот же график в двух вариациях:

1. Сжатый по аппликате, при значениях $S \leq 1$;
2. Увеличенный по аппликате, при значениях $S > 1$.

В данных условиях, применение интегральной аппроксимации не дает должного эффекта сглаживания, и того же поведения алгоритма оптимизации можно было бы добиться корректировками параметров поиска.

ОБСУЖДЕНИЕ

Базовый подход интегральной аппроксимации функций отлично себя показывает в случаях статичного расстояния между ближайшими локальными экстремумами, как в случае функций Растригина, Экли и Гриуэнка (Таблица).

Однако, поведение алгоритма аппроксимации в функции Швевеля связывается с тем, что в данном примере частота появления экстремумов реализует иную зависимость, а именно $f_{dynamic}(x) = \sin(\sqrt{|x|})$.

В случае функции «Cross-in-Tray» метод удалился от точки минимума в силу того, что точки глобального минимума функции расположены вблизи точек глобального максимума, где, в данной функции – точек минимума намного меньше, чем точек максимума. В данном случае алгоритм направился в сторону удаления от глобальных максимумов.

Таблица

Результаты поиска минимума функций

Table

Results of function minimization

Функция	Итерации	Найденная точка	Значение	Тип экстремума
$f_1(x_1, x_2)$	284	$(-3.98, 3.98)$	31.838	Локальный
$\tilde{f}_1(x_1, x_2)$	344	$(-6.5 * 10^{-8}, 6.5 * 10^{-8})$	$1.67 * 10^{-12}$	Около глобального
$f_2(x_1, x_2)$	279	$(-9.99, 9.99)$	17.29	Локальный
$\tilde{f}_2(x_1, x_2)$	1000	$(0.015, -0.015)$	0.072	Около глобального
$f_3(x_1, x_2)$	226	$(10.77, -10.77)$	-1.4913	Локальный
$\tilde{f}_3(x_1, x_2)$	300	$(29.22, 19.48)$	-0.73	Локальный
$f_4(x_1, x_2)$	233	$(-15.7, 22.19)$	0.18	Локальный
$\tilde{f}_4(x_1, x_2)$	437	$(-2.465 * 10^{-8}, -1.17 * 10^{-6})$	$3.499 * 10^{-13}$	Около глобального

В связи с этим, авторами предлагается внести корректировку в метод аппроксимации и реализовать параметр S как функцию $S(x)$ для случаев динамической частоты исходных функций.

В таком случае определение $\tilde{f}(X, S)$ принимает следующий вид:

$$\tilde{f}(X, S) = \int_{(x_1-S(x))}^{(x_1+S(x))} \dots \int_{(x_N-S(x))}^{(x_N+S(x))} f(x_1, \dots, x_N) dx_1 \dots dx_N$$

ВЫВОДЫ

Проведённое исследование подтвердило высокую эффективность метода интегральной аппроксимации для сглаживания и приближения сложных функций, характерных для задач оптимизации в условиях высокой размерности. Представленный подход позволяет получать гладкие аппроксимации исходных функций, что существенно облегчает применение численных методов оптимизации и повышает их сходимость и устойчивость. Практическая реализуемость метода и его гибкость делают его перспективным инструментом для широкого круга задач в области оптимизации и численного анализа. Дальнейшие исследования могут быть направлены на адаптацию метода к специфическим классам функций и расширение его применения в различных прикладных областях.

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Список литературы

1. Sun R.Y. Optimization for deep learning: An overview // Journal of the Operations Research Society of China. – 2020. – Т. 8. – №. 2. – P. 249-294.
2. Gunantara N. A review of multi-objective optimization: Methods and its applications // Cogent Engineering. – 2018. – Т. 5. – №. 1. – P. 1502242.
3. Sun S. et al. A survey of optimization methods from a machine learning perspective // IEEE transactions on cybernetics. – 2019. – Т. 50. – №. 8. – P. 3668-3681.
4. Vazirani V.V. Approximation algorithms. – Berlin: springer, 2001. – Т. 1. – 378 pp.
5. Leordeanu M., Hebert M. Smoothing-based optimization // 2008 IEEE Conference on Computer Vision and Pattern Recognition. – IEEE, 2008. – P. 1-8.
6. Растрингин Л. А. Системы экстремального управления. – Наука. Гл. ред. физ.-мат. Лит., 1974. – 630 с.
7. Ackley D. A connectionist machine for genetic hillclimbing. – Springer science & business media, 2012. – Т. 28. – 260 p.

8. Marinho P.R.D. et al. Adequacy Model: An R package for probability distributions and general purpose optimization // PloS one. – 2019. – Т. 14. – №. 8. – P. e0221487.
9. Griewank A.O. Generalized descent for global optimization // Journal of optimization theory and applications. – 1981. – Т. 34. – №. 1. – P. 11-39.
10. Schwefel H.P.P. Evolution and optimum seeking: the sixth generation. – John Wiley & Sons, Inc., 1993. – 445 p.

References

1. Sun R.Y. Optimization for deep learning: An overview // Journal of the Operations Research Society of China. – 2020. – Т. 8. – №. 2. – P. 249-294.
2. Gunantara N. A review of multi-objective optimization: Methods and its applications // Cogent Engineering. – 2018. – Т. 5. – №. 1. – P. 1502242.
3. Sun S. et al. A survey of optimization methods from a machine learning perspective // IEEE transactions on cybernetics. – 2019. – Т. 50. – №. 8. – P. 3668-3681.
4. Vazirani V.V. Approximation algorithms. – Berlin: springer, 2001. – Т. 1. – 378 pp.
5. Leordeanu M., Hebert M. Smoothing-based optimization // 2008 IEEE Conference on Computer Vision and Pattern Recognition. – IEEE, 2008. – P. 1-8.
6. Rastrigin L.A. Systems of extremal control // Nauka. – 1974. – 630 p.
7. Ackley D. A connectionist machine for genetic hillclimbing. – Springer science & business media, 2012. – Т. 28. – 260 p.
8. Marinho P.R.D. et al. Adequacy Model: An R package for probability distributions and general purpose optimization // PloS one. – 2019. – Т. 14. – №. 8. – P. e0221487.
9. Griewank A.O. Generalized descent for global optimization // Journal of optimization theory and applications. – 1981. – Т. 34. – №. 1. – P. 11-39.
10. Schwefel H.P.P. Evolution and optimum seeking: the sixth generation. – John Wiley & Sons, Inc., 1993. – 445 p.

Сысоев Роман Васильевич, аспирант кафедры программной инженерии, Сибирский Федеральный Университет, г. Красноярск, Россия

Антамошкин Олеслав Александрович, доктор технических наук, доцент, профессор кафедры программной инженерии, Сибирский Федеральный Университет, г. Красноярск, Россия

Sysoev Roman Vasilievich, Postgraduate student of the Department of Software Engineering, Siberian Federal University, Krasnoyarsk, Russia

Antamoshkin Oleslav Alexandrovich, Doctor of Technical Sciences, Associate Professor, Professor of the Department of Software Engineering, Siberian Federal University, Krasnoyarsk, Russia

АВТОМАТИЗАЦИЯ И УПРАВЛЕНИЕ AUTOMATION AND CONTROL

УДК 004.4'242

DOI: 10.18413/2518-1092-2026-11-3-0-2

Рыбанов А.А.
Кузминский М.С.

РАЗРАБОТКА ВЕБ-ИНТЕРФЕЙСА АДМИНИСТРАТИВНОГО УПРАВЛЕНИЯ РАСПРЕДЕЛЕННОЙ СЕТЬЮ УСТРОЙСТВ СБОРА БАТАРЕЕК И АККУМУЛЯТОРОВ НА ОСНОВЕ RESTFUL API

Волжский политехнический институт (филиал)
ФГБОУ ВО «Волгоградский государственный технический университет»,
ул. Энгельса, 42а, г. Волжский, Волгоградская область, 404121, Россия

e-mail: rybanoff@yandex.ru, kuzminskiy25@mail.ru

Аннотация

Актуальность исследования связана с ростом экологической нагрузки от отработанных батареек и аккумуляторов, содержащих токсичные металлы. Степень вовлечения населения в отдельный сбор остаётся низкой из-за слабого развития инфраструктуры приёма и отсутствия удобных средств контроля. Проблема заключается в том, что существующие IoT-платформы не имеют специализированного функционала для администрирования автоматизированных пунктов приёма батареек (фандоматов): облачные сервисы ориентированы на универсальный мониторинг и не учитывают обработку данных о сдаче опасных отходов, начисление баллов и централизованный контроль состояния устройств. Методы включают сравнительный анализ пяти IoT-платформ по пяти критериям, их ранжирование методом анализа иерархий Саати с агрегацией экспертных матриц через геометрическое среднее, а также проверку согласованности суждений. Веб-интерфейс реализован как одностороннее приложение на React, серверная часть – как RESTful API с PostgreSQL и TimescaleDB. Безопасность обеспечена JWT, OAuth и защитой от CSRF, XSS, SQL-инъекций. Результаты – функционирующая административная панель с модулями управления пользователями (ролевое разграничение), контроля устройств (текущая вместимость, время последнего сигнала), гибридного дашборда со спидометром и графиком наполненности за неделю, а также страницы статистики. Интегральная оценка качества разработанной системы сопоставима с ведущими зарубежными платформами, а по приоритетным критериям (управление пользователями и устройствами) достигнуты максимальные показатели. Апробация подтвердила высокую скорость освоения интерфейса и удобство работы. Выводы – предложенная архитектура позволяет создать масштабируемую, безопасную систему централизованного администрирования сети фандоматов. Разработанный веб-интерфейс создаёт основу для внедрения математических моделей оптимизации размещения устройств, прогнозирования их наполненности и геймификации для повышения мотивации населения к отдельному сбору опасных отходов.

Ключевые слова: веб-интерфейс; административное управление; сбор батареек и аккумуляторов; RESTful API; метод анализа иерархий; математическое моделирование

Для цитирования: Рыбанов А.А., Кузминский М.С. Разработка веб-интерфейса административного управления распределенной сетью устройств сбора батареек и аккумуляторов на основе RESTful API // Научный результат. Информационные технологии. – Т.11, №3, 2026. – С. 11-27. DOI: 10.18413/2518-1092-2026-11-3-0-2

Rybanov A.A.
Kuzminsky M.S.

DEVELOPMENT OF A WEB INTERFACE FOR ADMINISTRATIVE MANAGEMENT OF A DISTRIBUTED NETWORK OF BATTERY AND ACCUMULATOR COLLECTION DEVICES BASED ON THE RESTFUL API

Volzhsky Polytechnic Institute (branch) Volgograd State Technical University,
42a Engels str., Volzhsky, Volgograd region, 404121, Russia

e-mail: rybanoff@yandex.ru, kuzminskiy25@mail.ru

Abstract

The relevance of the study is associated with the increasing environmental burden from spent batteries and accumulators containing toxic metals. The level of public involvement in separate collection remains low due to poor development of collection infrastructure and the lack of convenient monitoring tools. The problem is that existing IoT platforms lack specialized functionality for administering automated battery collection points (reverse vending machines): cloud services are focused on universal monitoring and do not account for the processing of hazardous waste deposit data, point accrual, or centralized device status control. The methods include a comparative analysis of five IoT platforms according to five criteria, their ranking using the Saaty analytic hierarchy process with aggregation of expert matrices via the geometric mean, as well as consistency verification of judgments. The web interface is implemented as a single-page application in React, the server side as a RESTful API with PostgreSQL and TimescaleDB. Security is ensured by JWT, OAuth, and protection against CSRF, XSS, and SQL injection attacks. The results are a functioning administrative panel featuring user management modules (role-based access control), device status monitoring (current fill level, last signal time), a hybrid dashboard with a speedometer and a weekly fill dynamics graph, as well as a statistics page. The integral quality assessment of the developed system is comparable to leading foreign platforms, while maximum indicators have been achieved for the highest-priority criteria (user and device management). Testing confirmed the high speed of interface mastery and ease of use. The conclusions are that the proposed architecture enables the creation of a scalable, secure system for centralized administration of a network of reverse vending machines. The developed web interface provides a foundation for implementing mathematical models for device placement optimization, fill level forecasting, and gamification to increase public motivation for separate collection of hazardous waste.

Keywords: web interface; administration; battery and accumulator collection; RESTful API; analytic hierarchy process; mathematical modeling

Forcitation: Rybanov A.A., Kuzminsky M.S. Development of a web interface for administrative management of a distributed network of battery and accumulator collection devices based on the RESTful API // Research result. Information technologies. – T.11, №3, 2026. – P. 11-27. DOI: 10.18413/2518-1092-2026-11-3-0-2

ВВЕДЕНИЕ

Одной из актуальных экологических проблем современности является загрязнение окружающей среды токсичными компонентами отработанных батареек и аккумуляторов, поступающими в почву и водные объекты [7]. Данная категория отходов содержит тяжелые металлы и иные опасные вещества, оказывающие долговременное негативное воздействие на экосистемы и здоровье человека.

Ключевыми препятствиями для эффективной утилизации батареек и аккумуляторов выступают низкий уровень вовлеченности населения в отдельный сбор, а также недостаточное развитие специализированной инфраструктуры, в частности ограниченное количество пунктов приема [10]. Указанные факторы обуславливают необходимость поиска новых организационных и технологических решений.

Актуальность исследования определяется устойчивым ростом потребления портативных источников питания, что ведет к увеличению объемов образования опасных отходов. Отсутствие системного подхода к их сбору и утилизации усиливает антропогенную нагрузку на окружающую

среду [8]. Несмотря на наличие технологий переработки, проблема сбора отработанных батареек остается нерешенной [5], что связано как с недостаточной экологической грамотностью и низкой мотивацией населения, так и с ограниченной доступностью и удобством существующей инфраструктуры приема.

В указанных условиях возрастает значимость разработки цифровых инструментов, направленных на повышение эффективности взаимодействия пользователей с инфраструктурой сбора отходов. Создание веб-интерфейса для управления фандоматами (автоматизированными пунктами приема) позволяет повысить удобство их использования, упростить контроль функционирования и, как следствие, увеличить объемы принимаемых на переработку батареек.

Таким образом, анализ проблематики утилизации батареек свидетельствует о необходимости не только развития материальной инфраструктуры, но и внедрения механизмов, стимулирующих вовлеченность граждан в раздельный сбор. Перспективным направлением в решении данной задачи является применение элементов геймификации – внедрение игровых механик (начисление баллов, достижения, рейтинги) в неигровой контекст с целью повышения мотивации пользователей. Согласно результатам исследований, геймификация способствует росту пользовательской активности [13], а также отмечается ее эффективность в формировании экологически ответственного поведения [15].

Реализация подобных подходов требует наличия надежной системы управления, обеспечивающей обработку пользовательских данных, контроль работы устройств сбора и администрирование инфраструктуры в целом. В данном контексте ключевая роль отводится веб-интерфейсу, выполняющему функции административной панели.

Целью исследования является повышение эффективности управления системой сбора и утилизации батареек за счет автоматизации процессов мониторинга, обработки и администрирования данных о пользователях и фандоматах на основе специализированного веб-интерфейса.

ОСНОВНАЯ ЧАСТЬ

Для достижения поставленной цели в работе был применён многоуровневый методологический подход, включающий анализ предметной области, формирование критериев оценки и их последующее ранжирование.

На первом этапе был проведён анализ предметной области, включающий сравнительное исследование существующих веб-интерфейсов для управления IoT-устройствами. В качестве объектов анализа были выбраны распространённые и активно используемые решения: Ubidots [14], Blynk IoT [16, 20], AWS IoT Core [6], Kaa IoT Platform [12], ThingsBoard [18]. Выбор данных платформ обусловлен их популярностью на рынке, широким функционалом и применимостью для задач удалённого мониторинга и управления устройствами. Проведённый анализ позволил выявить ключевые подходы к организации пользовательских интерфейсов, управлению устройствами и обработке данных.

На втором этапе были сформированы пять ключевых критериев оценки, отражающих требования к разрабатываемой системе администрирования и обеспечивающих непротиворечивость и полноту анализа:

1. *Управление учётными записями пользователей* – включает возможность регистрации, хранения профилей, аутентификации, назначения ролей (администратор, оператор), а также выполнения операций блокировки, удаления и просмотра истории действий пользователей.

2. *Управление устройствами (фандоматами)* – обеспечивает добавление, редактирование, удаление фандоматов, мониторинг их состояния (статус, текущая вместимость, время последнего сигнала), просмотр истории операций сдачи на каждом устройстве и возможность удалённой настройки пороговых значений.

3. *Автономность и устойчивость работы* – способность системы функционировать без постоянного подключения к сторонним облачным сервисам, наличие собственного сервера

аутентификации, базы данных и API, устойчивость к сбоям и автоматическое восстановление после перезагрузки.

4. *Визуализация и аналитика данных* – построение графиков наполненности устройств и активности пользователей, формирование отчётов (в том числе экспорт в CSV/Excel), наличие дашборда с ключевыми показателями эффективности.

5. *Безопасность и защита данных* – реализация HTTPS, JWT-аутентификации, защиты от CSRF/XSS/SQL-инъекций, разграничение прав доступа (ролевая модель), возможность аудита действий администраторов.

Выделенные критерии легли в основу дальнейшего исследования, направленного на определение их относительной значимости.

На третьем этапе было выполнено ранжирование критериев с использованием метода анализа иерархий Саати (АНП) [11].

В исследовании приняли участие 12 экспертов, обладающих практическим опытом в области разработки программного обеспечения не менее 3 лет, включая опыт администрирования информационных систем. Отбор экспертов проводился по критериям наличия высшего технического образования, участия в разработке не менее двух коммерческих проектов в области веб-технологий или IoT, а также наличия опыта работы с системами удалённого управления устройствами.

Для агрегации индивидуальных матриц парных сравнений, построенных каждым экспертом, использовался метод геометрического среднего. На основе полученной обобщённой матрицы были вычислены максимальное собственное число λ_{max} и индекс согласованности CI :

$$CI = \frac{\lambda_{max} - n}{n - 1},$$

где n – размерность матрицы. Отношение согласованности CR определялось как

$$CR = \frac{CI}{RI},$$

где RI – случайный индекс (для $n=5$, $RI=1,12$). Для агрегированной матрицы значение CR составило 0,078, что не превышает 0,1, следовательно, согласованность групповых экспертных суждений является приемлемой.

На основе попарных сравнений были рассчитаны весовые коэффициенты критериев a_i . Результаты ранжирования представлены в таблице 1.

Таблица 1

Весовые коэффициенты критериев качества
(после агрегирования методом геометрического среднего)

Table 1

Weighting factors of quality criteria (after geometric mean aggregation)

Критерий	Обозначение	Весовой коэффициент
Управление учётными записями пользователей	a_1	0,34
Управление устройствами (фандоматами)	a_2	0,24
Автономность и устойчивость работы	a_3	0,16
Визуализация и аналитика данных	a_4	0,11
Безопасность и защита данных	a_5	0,15

Полученные результаты показывают, что наибольшую значимость имеют критерии «управление учётными записями пользователей» (0,34) и «управление устройствами» (0,24). Это свидетельствует о том, что при разработке административной системы для сети фандоматов ключевое внимание должно уделяться централизованному контролю пользователей и мониторингу состояния устройств. Критерий «автономность» (0,16) также важен, но не доминирует. Меньшие веса получили «визуализация и аналитика» (0,11) и «безопасность» (0,15) – последний критерий

рассматривается как обязательный базовый, не требующий дополнительного приоритета при выборе платформы.

Таким образом, результаты применения метода анализа иерархий подтверждают, что при разработке веб-интерфейса административной панели для управления системой сбора батареек основное внимание должно быть сосредоточено на реализации функционала управления пользователями и устройствами при обеспечении достаточной автономности. Указанные выводы легли в основу проектирования архитектуры разрабатываемого решения.

Расчёт интегрального показателя качества для рассматриваемых веб-интерфейсов был выполнен на основании весовых коэффициентов a_i . Для этого те же 12 экспертов оценили каждый из пяти программных продуктов по каждому из пяти критериев по пятибалльной шкале. Полученные оценки r_{ij} были нормализованы методом нормировки по минимальному и максимальному значениям для устранения масштабных различий. При этом $\min_k$ и $\max_k$ определялись по всем шести сравниваемым системам (пять аналогов + разработанная веб-панель):

$$X_{ij} = \frac{r_{ij} - \min_k r_{ik}}{\max_k r_{ik} - \min_k r_{ik}},$$

где X_{ij} – нормализованная оценка j -го приложения по i -му критерию. Интегральный показатель качества Q_j для каждого интерфейса рассчитывался по формуле:

$$Q_j = \sum_{i=1}^n a_i \cdot X_{ij}.$$

Результаты количественной оценки качества пяти веб-интерфейсов (Ubidots, Blynk IoT, AWS IoT Core, Kaa IoT Platform, ThingsBoard) представлены в таблице 2.

Таблица 2

Интегральные показатели качества веб-интерфейсов для управления IoT-устройствам

Table 2

Integral quality indicators of web interfaces for managing IoT devices

№	Наименование программного продукта	Интегральный показатель качества Q
1	ThingsBoard	0,81
2	Kaa IoT Platform	0,75
3	AWS IoT Core	0,36
4	Ubidots	0,20
5	Blynk IoT	0,20

Полученные значения Q_j лежат в интервале $[0,1]$ и составляют: ThingsBoard – 0,81, Kaa IoT Platform – 0,75, AWS IoT Core – 0,36, Ubidots – 0,20, Blynk IoT – 0,20

Данные таблицы 2 подтвердили доминирование решений ThingsBoard и Kaa IoT Platform, что обусловлено их сбалансированным функционалом, включающим развитые средства управления пользователями, широкие возможности администрирования устройств, а также высокий уровень автономности и гибкости настройки системы.

Сравнительный анализ продемонстрировал, что существующие решения, несмотря на высокий уровень функциональности, ориентированы на универсальные задачи управления IoT-устройствами и не учитывают особенности систем сбора и утилизации батареек. В частности, в рассмотренных платформах отсутствуют специализированные инструменты для централизованного управления фандоматами, а также механизмы, учитывающие специфику обработки данных о сдаче отходов и начислении пользовательских баллов.

В рамках работы разрабатывается веб-интерфейс административной панели для управления системой сбора и утилизации батареек. Исходя из требований к удобству, быстродействию и эффективности взаимодействия с пользователем, клиентская часть реализована в архитектуре одностраничного приложения (SPA). Данный подход, в отличие от традиционных

многостраничных решений, обеспечивает динамическую загрузку контента без полной перезагрузки страницы, что сокращает время реакции интерфейса и обеспечивает плавность работы. Для административных инструментов, предполагающих оперативную обработку данных и частое переключение между разделами, SPA позволяет снизить нагрузку на сервер за счёт уменьшения повторных запросов и эффективно управлять состоянием приложения на клиентской стороне.

В качестве инструмента реализации выбрана библиотека React. Согласно сравнительному анализу производительности фронтенд-фреймворков [2], React обеспечивает оптимальное соотношение скорости рендеринга и удобства разработки для SPA-приложений средней и высокой сложности, что подтверждается его высокой популярностью в корпоративной разработке. Дополнительными преимуществами React являются компонентный подход, позволяющий разбивать интерфейс на независимые переиспользуемые элементы, а также механизм виртуального DOM, обеспечивающий эффективное обновление пользовательского интерфейса. Развитая экосистема инструментов (управление состоянием, маршрутизация, взаимодействие с API) делает React подходящим выбором для разработки масштабируемых и поддерживаемых веб-интерфейсов.

Таким образом, использование архитектуры SPA в сочетании с библиотекой React позволяет обеспечить высокую производительность, удобство использования и расширяемость разрабатываемой панели администрирования.

Для повышения наглядности представления информации и удобства её анализа в административной панели реализованы средства визуализации данных. В качестве инструмента построения графиков и диаграмм используется библиотека Chart.js.

Серверная часть разрабатываемой системы реализована в виде программного интерфейса (API), построенного в соответствии с архитектурным стилем REST [9]. Данный подход широко применяется при создании распределённых веб-приложений благодаря своей простоте, масштабируемости и независимости клиентской и серверной частей. Взаимодействие клиентской части с серверной строится на основе REST. Применение стандартных HTTP-методов даёт унифицированный доступ к ресурсам системы, а также упрощает подключение внешних сервисов.

Основным средством хранения данных выбрана реляционная СУБД PostgreSQL. Дополнительно задействовано расширение TimescaleDB, ориентированное на обработку временных рядов. С его помощью оптимизируется хранение и обработка информации о событиях, привязанных ко времени: активность фандоматов, приём батареек, системные логи. В итоге аналитические запросы выполняются с высокой производительностью, а реализация мониторинга и анализа работы системы становится менее трудоёмкой.

Безопасности при разработке системы уделяется повышенное внимание. Такая необходимость продиктована защитой пользовательских данных, недопущением несанкционированного доступа и требованием устойчивости к типовым атакам [4].

Аутентификация и авторизация пользователей реализуются с использованием современных подходов, включая применение JSON Web Token (JWT) и протокола OAuth 2.0 [3]. Использование JWT позволяет организовать безопасную передачу информации о пользователе между клиентом и сервером в виде подписанных токенов, что исключает возможность их подмены. Применение OAuth 2.0 обеспечивает гибкий механизм делегированной авторизации и может быть использовано для интеграции с внешними сервисами, а также для управления доступом на основе ролей и прав пользователей.

Для защиты веб-приложения от распространённых уязвимостей реализован комплекс мер безопасности [1]. В частности, предусмотрена защита от XSS-атак (межсайтового скриптинга), достигаемая за счёт экранирования пользовательского ввода и контроля отображаемого контента. Защита от SQL-инъекций обеспечивается использованием параметризованных запросов и механизмов ORM, что исключает возможность выполнения произвольных SQL-команд через пользовательский ввод [17].

Дополнительно реализована защита от CSRF-атак (подделки межсайтовых запросов), что особенно важно при использовании cookie-based аутентификации. Для этого применяются CSRF-

токены, позволяющие удостовериться в подлинности источника запроса и предотвратить выполнение несанкционированных действий от имени пользователя.

Архитектура и программная реализация веб-интерфейса. Администратор представляет собой пользователя с расширенными правами доступа, осуществляющего управление пользователями, фандоматами, а также анализ статистических данных системы (рис. 1).




Рис. 1. Архитектура веб-интерфейса административного управления распределенной сетью устройств

Fig. 1. Architecture of a web interface for administrative management of a distributed network of devices

В структуре клиентского приложения предусмотрены основные функциональные разделы, включающие панель мониторинга (Dashboard) для отображения ключевых показателей, раздел управления пользователями, страницу работы с фандоматами, модуль уведомлений, а также раздел для просмотра ошибок. Отдельно реализованы страницы аутентификации и регистрации пользователей.

Для обеспечения единообразия интерфейса используется общая компоновка страниц, включающая боковую навигационную панель и верхнюю панель управления. Маршрутизация в приложении реализована с поддержкой защищённых маршрутов, что ограничивает доступ к функционалу системы только авторизованными пользователями. Состояние аутентификации хранится в глобальном состоянии приложения и включает данные о текущем пользователе, его сессии и возможности завершения сеанса.

Взаимодействие клиентской части с сервером осуществляется через специализированный API-клиент, представляющий собой централизованный модуль для выполнения HTTP-запросов. Он обеспечивает единый механизм работы с серверным API, реализует cookie-based аутентификацию и включает защиту от CSRF-атак для изменяющих запросов. При получении от сервера ответа с кодом 401 (неавторизованный доступ) клиентская часть API инициирует попытку обновить access-токен, после чего повторяет изначально отправленный запрос. Если же обновление токена оказывается невозможным, выполняется принудительный выход пользователя из системы – все текущие сессии завершаются.

Серверная сторона спроектирована как REST-ориентированный веб-сервис. На него возложены функции обработки входящих запросов, реализации предметной логики и обеспечения связи с базой данных. В составе серверной архитектуры можно выделить два крупных блока. Первый – модуль аутентификации: он отвечает за вход и регистрацию пользователей, ротацию токенов, завершение сеансов работы, а также за генерацию и верификацию CSRF-токенов. Второй

блок – административный модуль, через который предоставляется доступ к системной статистике, управлению фандоматами (добавление, редактирование, удаление) и получению информации об устройствах с сопутствующими данными.

Обработка всех запросов проходит через слой промежуточного программного обеспечения (middleware). Именно на этом уровне выполняются проверка JWT-токенов, оценка прав доступа пользователей, защита от CSRF-атак, настройка CORS-политики, ограничение интенсивности запросов (rate limiting) и логирование событий. Наличие такого слоя заметно усиливает защищённость системы и даёт дополнительный контроль над выполняемыми операциями.

В качестве хранилища данных используется реляционная база данных, содержащая информацию о пользователях, фандоматах, операциях сдачи батареек (депозитах) и сессионных данных. База данных обеспечивает выполнение основных операций по созданию, чтению, обновлению и удалению информации, а также гарантирует целостность и согласованность данных.

Взаимодействие компонентов системы организовано следующим образом. Администратор работает с системой через клиентское приложение, которое отправляет HTTP-запросы к серверу с использованием API-клиента. Серверная часть принимает запрос, выполняет проверку аутентификации, прав доступа и корректности CSRF-токена, после чего передаёт его в соответствующий модуль бизнес-логики. Модули взаимодействуют с базой данных с использованием ORM (GORM), после чего сформированный результат возвращается клиенту в формате JSON. Клиентское приложение, в свою очередь, обновляет пользовательский интерфейс в соответствии с полученными данными.

При истечении срока действия access-токена клиентская часть инициирует процедуру его обновления. В случае успешного обновления пользователь продолжает работу без прерывания сессии. При неудачном обновлении выполняется автоматический выход из системы, что обеспечивает дополнительный уровень безопасности.

Таким образом, предложенная архитектура обеспечивает надёжное, безопасное и эффективное взаимодействие между компонентами системы и создаёт основу для дальнейшего расширения функциональности административной панели.

На рисунке 2 представлена ER-диаграмма логической модели реляционной базы данных, разработанной для информационной поддержки административной панели управления сетью фандоматов. В предложенной логической схеме базы данных выделены три ключевые сущности: «Пользователи» (users), «Устройства» (devices) и «Операции сдачи» (deposits). Такой состав полностью покрывает функциональные требования, предъявляемые к системе.

Сущность «Пользователи» предназначена для хранения данных, необходимых при идентификации, аутентификации и управлении учётной записью. В качестве первичного ключа выступает поле id типа bigint – это обеспечивает уникальность каждой записи. Набор полей включает email, password_hash, nickname, avatar, role, is_verified, verification_token и points; через них реализовано хранение регистрационной информации, разграничение ролей (администратор или оператор), отслеживание статуса верификации, а также накопленных баллов в рамках геймификации. Для служебных целей добавлены атрибуты created_at, updated_at, deleted_at с типом timestampz – они фиксируют временные отметки жизненного цикла записи и позволяют применять механизм «мягкого удаления».

Сущность «Устройства» описывает фандоматы, то есть автоматизированные пункты, принимающие использованные батарейки. Уникальный идентификатор каждой единицы оборудования задаётся первичным ключом id (bigint). Другие атрибуты: serial_number (серийный номер), name (наименование), location (местонахождение), status (текущее состояние: активен, неактивен, требуется обслуживание), current_load (наполненность в данный момент), max_capacity (предельная вместимость) и last_ping (метка времени последнего успешного сигнала от устройства). Эти данные необходимы для мониторинга и администрирования фандоматов. Поля created_at, updated_at, deleted_at позволяют отслеживать изменения в конфигурации устройств и факты их удаления.




Рис. 2. ER-диаграмма логической модели базы данных (пользователи, фандоматы, депозиты)
Fig. 2. ER diagram of the logical database model (users, reverse vending machines, deposits)

Сущность «Операции сдачи» служит для фиксации каждого факта приёма батареек от пользователя. Первичный ключ id (bigint) однозначно определяет одну операцию. Внешние ключи user_id и device_id (оба типа bigint) ссылаются на соответствующие записи в таблицах users и devices; так реализованы связи типа «один ко многим» (один пользователь может сдавать батарейки многократно, один фандомат способен принять множество депозитов). Содержательные параметры транзакции представлены атрибутами battery_type (тип батареек), count (количество) и points (начисленные баллы). Поле created_at хранит момент выполнения сдачи, updated_at – время последней корректировки записи (например, при изменении начисленных баллов), а deleted_at поддерживает мягкое удаление.

Выбор типов данных обоснован следующим образом: bigint применяется для числовых идентификаторов и счётчиков (это даёт хорошую масштабируемость при росте объёмов данных); для строковых полей переменной длины (email, хэш пароля, никнейм, серийный номер, наименование, местоположение) используется тип text; для атрибутов с ограниченным набором допустимых значений (role, status) выбран varchar(20); логические флаги (is_verified) представлены типом boolean; для временных меток с учётом часового пояса – timestampz. Благодаря механизму мягкого удаления (поле deleted_at) сохраняется история операций и появляется возможность восстановить ошибочно удалённые записи без физического удаления данных из таблиц.

Связи между сущностями обеспечивают целостность ссылочной целостности: каждая операция сдачи обязательно привязана к существующему пользователю и существующему устройству. Такая структура позволяет эффективно выполнять аналитические запросы – вычислять суммарное количество баллов на пользователя, отслеживать наполненность конкретного фандомата во времени, формировать отчёты по типам батареек и другие статистические показатели, необходимые для административной панели.

Разработанная логическая модель полностью соответствует требованиям, сформулированным в таблице 1 (весовые коэффициенты критериев), и обеспечивает основу для реализации функций

управления пользователями, фандоматами и визуализации данных.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЕ

В ходе исследования разработано веб-приложение административной панели, предназначенное для управления системой сбора и утилизации батареек с использованием фандоматов. Реализованное решение обеспечивает централизованное управление пользователями и устройствами, а также предоставляет инструменты мониторинга и анализа данных.

Разработанная система реализует полный цикл административного взаимодействия: от управления учётными записями пользователей и фандоматами до анализа статистических показателей работы системы. Ключевые функциональные и технические особенности разработанного решения включают следующие аспекты.

Во-первых, реализован централизованный механизм управления пользователями, включающий просмотр и контроль состояния учётных записей (рис. 3). Администратор имеет возможность управлять их доступом. Это позволяет эффективно контролировать пользовательскую активность и обеспечивает безопасность системы.

Email	Никнейм	Дата регистрации	Баллы	Статус	Действия
admin@fondo.local	admin	2026-01-12	1240	Активен	Заблокировать
anna@mail.com	anna	2026-01-20	380	Активен	Заблокировать
nikita@mail.com	nik	2026-01-25	520	Активен	Заблокировать
olga@mail.com	olga	2026-02-03	470	Заблокирован	Разблокировать
daniil@mail.com	dani	2026-02-10	190	Активен	Заблокировать
alisa@mail.com	alisa	2026-02-15	415	Активен	Заблокировать

Рис. 3. Страница пользователи
Fig. 3. Users page

Во-вторых, реализован модуль управления фандоматами (рис. 4), обеспечивающий просмотр списка устройств, их текущего состояния, местоположения. Отображение параметров, таких как текущая вместимость и время последнего сигнала, позволяет оперативно выявлять неактивные устройства. Это существенно упрощает процесс мониторинга инфраструктуры и повышает эффективность её эксплуатации.




Рис. 4. Страница фандоматы
Fig. 4. Veding Machines Page

С целью детального анализа состояния каждого из устройств в составе интерфейса реализован специализированный режим отображения, объединяющий два компонента: индикатор типа «спидометр», отображающий актуальный уровень заполнения, и график, фиксирующий динамику изменения данного показателя за семидневный интервал (рис. 5). Предложенная форма визуализации даёт возможность оперативно судить о целесообразности проведения вывоза накопленных батареек, а также отслеживать тенденции изменения степени наполнения контейнера во времени.

Мониторинг состояния фандомата «Фондомат №42» (г. Волжский, ул. Энгельса)




Рис. 5. Пример гибридного дашборда для мониторинга состояния фандомата
Fig. 5. Example of a hybrid dashboard for monitoring the status of a reverse vending machine

В-третьих, реализована система отображения статистических данных с использованием графической визуализации (рис. 6). Администратору предоставляется возможность анализировать ключевые показатели, включая график наполненности устройств. Использование графика позволяет выявлять тенденции и отклонения в работе системы, что способствует принятию обоснованных управленческих решений.




Рис. 6. Главная страница
Fig. 6. Main page

Для разработанной системы экспертные оценки (таблица 3) были нормализованы по тем же минимальным и максимальным значениям, что и аналогичные системы. Интегральный показатель качества разработанной системы составил $Q_{разр}=0,78$.

Таблица 3

Экспертные оценки разработанной системы (средние баллы, $n=12$)

Table 3

Expert evaluations of the developed system (average scores, $n=12$)

Критерий	Весовой коэффициент
Управление учётными записями пользователей (a_1)	5
Управление устройствами (a_2)	5
Автономность и устойчивость работы (a_3)	4,3
Визуализация и аналитика данных (a_4)	4,2
Безопасность и защита данных (a_5)	4,4

Примечание: приведены средние баллы ((оценки даны по шкале от 1 до 5). После того min-max нормализация – с привлечением данных по всем шести системам – итоговая величина $Q_{разр}=0,78$.

Интегральный показатель качества разработанной системы после нормализации составил 0,78, что превышает показатели Kaa IoT Platform (0,75) и значительно выше AWS IoT Core (0,36), Ubidots (0,20) и Blynk (0,20), но несколько ниже ThingsBoard (0,81). Тем не менее, с учётом приоритетности критериев «управление учётными записями» и «управление устройствами», по которым разработанная система получила максимальные нормализованные оценки (1,0 и 1,0 соответственно), её можно считать конкурентоспособной с лучшими аналогами.

Апробация системы проводилась с участием 30 пользователей, включающих разработчиков и администраторов информационных систем. Критериями включения являлись наличие опыта администрирования информационных систем не менее 1 года и опыт работы с веб-интерфейсами управления устройствами. Внутренняя согласованность анкеты, оцененная по коэффициенту α Кронбаха, составила 0,84, что свидетельствует о высокой надёжности инструмента [19]. Опрос проводился с использованием стандартизированной анкеты, содержащей вопросы по четырём блокам: удобство интерфейса, эффективность управления, наглядность данных и скорость работы. Каждый пункт оценивался по шкале Лайкерта от 1 до 5. Анализ данных, полученных в ходе опроса

(табл. 4), позволил выделить несколько ключевых преимуществ разработанного решения. Наиболее высокую оценку (92% от числа респондентов) получила скорость работы интерфейса – пользователи отметили отсутствие задержек и плавность взаимодействия, что обусловлено применением архитектуры SPA. Удобство интерфейса признали 90% опрошенных; при этом среднее время, необходимое для первичного освоения системы, составило менее 10 минут, что свидетельствует о простоте навигации. Эффективность выполнения административных операций (управление пользователями и фандоматами) была положительно оценена 87% участников. Наглядность представления данных, реализованная с помощью графиков и диаграмм, получила удовлетворительные отклики от 85% респондентов.

Таблица 4

Результаты апробации (опрос пользователей)

Table 4

Results of Approbation (User Survey)

Показатель	Средняя оценка (1-5)	Доля положительных ответов (4-5)	Стандартное отклонение
Простота навигации и скорость освоения	4,7	90%	0,52
Удобство управления пользователями и фандоматами	4,5	87%	0,63
Наглядность графиков и диаграмм	4,4	85%	0,71
Отсутствие задержек, плавность интерфейса	4,8	92%	0,41

В ходе анализа обратной связи от участников опроса выявлены два основных типа замечаний: во-первых, недостаточная детализация фильтрации в таблице учётных записей пользователей, во-вторых, отсутствие функционала выгрузки данных в формат CSV. Перечисленные недостатки зафиксированы в журнале требований, и их устранение запланировано на последующие релизы разрабатываемой системы.

Апробация системы подтвердила высокое удобство интерфейса и эффективность управления. Полученные результаты (таблица 4) свидетельствуют о практической пригодности разработанного решения для задач администрирования сети фандоматов.

Для количественного обоснования снижения времени выполнения типовых операций (поиск пользователя, просмотр состояния устройства) была использована модель сравнения производительности традиционного многостраничного приложения (MPA) и одностраничного приложения (SPA). Время отклика при работе с MPA можно представить как:

$$T_{MPA} = \sum_{k=1}^m (t_{req}^{(k)} + t_{render}^{(k)}),$$

где m – количество переходов между страницами, $t_{req}^{(k)}$ – время загрузки HTML-документа и связанных ресурсов при k -м переходе, $t_{render}^{(k)}$ – время полной перерисовки страницы.

Для SPA:

$$T_{SPA} = t_{init} + \sum_{k=1}^m t_{api}^{(k)} + \sum_{k=1}^m t_{patch}^{(k)},$$

где t_{init} – время начальной загрузки приложения, $t_{api}^{(k)}$ – время выполнения API-запроса для получения данных, $t_{patch}^{(k)}$ – время точечного обновления DOM. В разработанной системе за счёт исключения полной перезагрузки страницы и использования асинхронных запросов удалось

достичь снижения общего времени выполнения последовательности операций на 30–35% по сравнению с типовыми МРА-решениями, что согласуется с приведённой моделью.

ПЕРСПЕКТИВЫ ДАЛЬНЕЙШИХ ИССЛЕДОВАНИЙ

Разработанная система создаёт основу для внедрения математических моделей оптимизации инфраструктуры сбора и прогнозирования её загрузки. В качестве перспективных направлений выделяются:

1. *Оптимизация размещения фандоматов.* Задача может быть сформулирована как максимизация покрытия спроса при ограниченных ресурсах. Выбор целочисленного линейного программирования обусловлен дискретной природой размещения устройств (установить/не устанавливать) и наличием эффективных решателей. Пусть U – множество потенциальных мест установки, V – множество пользователей (или зон спроса), w_{uv} – ожидаемый спрос от пользователя v при размещении устройства в точке u , c_u – затраты на установку и обслуживание, $y_u \in \{0,1\}$ – индикатор размещения, $x_{uv} \in \{0,1\}$ – назначение пользователя к устройству. Тогда модель имеет вид:

$$\sum_{u \in U} \sum_{v \in V} w_{uv} x_{uv} - \lambda \sum_{u \in U} c_u y_u \rightarrow \max,$$

При ограничениях $\sum_{v \in V} x_{uv} \leq 1, x_{uv} \leq y_u, y_u \in \{0,1\}$, где λ – коэффициент, балансирующий экономическую эффективность.

2. *Прогнозирование наполненности устройств.* На основе временных рядов, хранимых в *TimescaleDB*, можно построить модель авторегрессии для прогнозирования уровня заполнения фандомата:

$$y_t = \mu + \sum_{i=1}^p \phi_i y_{t-i} + \varepsilon_t,$$

где y_t – уровень наполненности в момент t , ϕ_i – коэффициенты авторегрессии, ε_t – белый шум. Выбор авторегрессии как начальной модели обусловлен её интерпретируемостью, вычислительной простотой и возможностью реализации непосредственно среде БД (через оконные функции SQL). В перспективе возможно сравнение методами машинного обучения при накоплении достаточного объёма исторических данных. Это позволит перейти к проактивному управлению вывозом отходов.

3. *Оценка надёжности системы.* Для характеристики готовности инфраструктуры может быть использован коэффициент готовности:

$$A = \frac{MTBF}{MTBF + MTTR},$$

где $MTBF$ – средняя наработка на отказ, $MTTR$ – среднее время восстановления. Для распределённой сети фандоматов общая готовность может оцениваться с учётом структуры связей.

Интеграция перечисленных моделей в разработанный веб-интерфейс будет осуществляться через добавление новых REST-эндпоинтов, вызывающих модули аналитики, которые, в свою очередь, обращаются к данным из *TimescaleDB* и возвращают результаты оптимизации или прогноза в виде JSON для последующей визуализации на дашборде администратора.

Реализация указанных моделей позволит повысить эффективность управления системой сбора батареек и обеспечит научно обоснованное принятие решений.

ЗАКЛЮЧЕНИЕ

В ходе исследования реализованы архитектурные и технологические решения, включающие применение одностраничного приложения (SPA), RESTful API, а также комплекс мер по обеспечению информационной безопасности (JWT-аутентификация, защита от CSRF, XSS и SQL-

инъекций). Совокупность применённых подходов позволила создать масштабируемую, отказоустойчивую и эргономичную систему.

Разработанное веб-приложение предоставляет администратору функциональные средства централизованного управления пользователями и фандоматами, а также инструменты визуализации и анализа статистических данных, что обеспечивает поддержку принятия обоснованных управленческих решений. Высокая интегральная оценка качества разработанной системы и положительные результаты апробации подтверждают её соответствие современным требованиям, предъявляемым к административным интерфейсам.

Предложенное решение вносит вклад в цифровизацию экологического мониторинга и инфраструктуры обращения с отходами. Оно создаёт основу для повышения вовлечённости населения в раздельный сбор посредством интеграции с пользовательскими приложениями и реализации механизмов мотивации, в том числе элементов геймификации.

Разработанная система способствует повышению прозрачности процессов сбора батареек и упрощению контроля за состоянием устройств, что соответствует современным тенденциям экологической ответственности и снижения антропогенной нагрузки на окружающую среду.

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Список литературы

1. Винарчук А.В. Безопасность веб-приложений: основные уязвимости и способы защиты // Научный Лидер. – 2024. – № 3 (153). – С. 29-30. – EDN: VOFHRO.
2. Гончар Д.О. Сравнение производительности фронтенд-фреймворков React, Angular, Vue.js и Svelte // Молодой ученый. – 2023. – № 36 (483). – С. 11-15. – EDN: LTERGF.
3. Девицына С.Н., Пилькевич П.В., Удод Е.В. Способы улучшения защищённости сервисов, использующих JWT-токены // Экономика. Информатика. – 2023. – Т. 50, № 1. – С. 144-151. DOI: 10.52575/2687-0932-2023-50-1-144-151. EDN: AGOVQI.
4. Ефремов М.А., Калущий И.В., Таныгин М.О., Рудак И.И. Безопасность персональных данных, социальные сети и реклама в глобальной сети Internet // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. – 2017. – Т. 7, № 1 (22). – С. 27-33. – EDN: YKKKLJ.
5. Кейметинова В.П., Герасимова Л.В. Сбор и утилизация батареек в городе Якутске // Булатовские чтения. – 2020. – Т. 6. – С. 130-132. – EDN CQTPEV.
6. Климов К.О., Пискун Г.А., Лихачевский Д.В., Алексеев В.Ф., Шаталова В.В. Аналитика IoT данных с использованием сервиса AWS IoT Analytics при исследовании загазованности окружающей среды // Big Data and Advanced Analytics. – 2021. – № 7-1. – С. 131-137. EDN: SFAVIY.
7. Кнауб В.В., Коваленко А.Е. Влияние батареек на окружающую среду и здоровье человека // Молодой ученый. – 2021. – № 3 (345). – С. 343-345.
8. Московкин В.М. Системы сбора и рециклинга батарей и аккумуляторов по европейскому образцу // Твёрдые бытовые отходы. – 2022. – № 9 (195). – С. 60-64. – EDN: MITNPL.
9. Тукаев И.Р., Беспоясова В.А. Сравнение технологий API для интеграции с корпоративными системами: REST, SOAP, WebSocket, GraphQL // Системная инженерия и информационные технологии. – 2024. – Т. 6, № 2 (17). – С. 78-85. DOI: 10.54708/2658-5014-SIIT-2024-no2-p78. EDN: KCYBPB.
10. Утилизация батареек в России и мире / Лопатко Н., Кених А., Яковлев А., Тян Е., Пирогова В.Ю. // Вестник Камчатского политехнического техникума. – 2015. – № 13. – С. 46-51. – EDN VYUBPN.
11. Цибизова Т.Ю., Карпунин А.А. Применение метода анализа иерархий в оценке качества процессов управления // Современные проблемы науки и образования. – 2015. – № 2-1. – С. 200. – EDN UHWZPP.
12. Al Rasyid M.U.H., Mubarrok M.H., Nur Hasim Ja.A. Implementation of environmental monitoring based on KAA IOT platform // Bulletin of Electrical Engineering and Informatics. – 2020. – Vol. 9, No. 6. – P. 2578-2587. DOI: 10.11591/eei.v9i6.2578. EDN: PKGAJF.
13. Hamari J., Koivisto J., Sarsa H. Does Gamification Work? – A Literature Review of Empirical Studies on Gamification // 2014 47th Hawaii International Conference on System Sciences. – Waikoloa, HI, 2014. – С. 3025-3034. DOI: 10.1109/HICSS.2014.377.

14. Jaafar H., Aminuddin N.S. Comparison between NodeMCU ESP8266 and Uno R3 for software development using Ubidots // Malaysian Journal of Bioengineering and Technology (MJBET). – 2024. – Т. 1, № 1. – С. 36-40. DOI: 10.70464/mjbet.v1i1.1320. EDN: NAJOAV.

15. Looyestyn J., Kernot J., Boshoff K., Ryan J., Edney S., Maher C. Does gamification increase engagement with online programs? A systematic review // PLoS One. – 2017. – Vol. 12, № 3. – P. e0173403. DOI: 10.1371/journal.pone.0173403. PMID: 28362821; PMCID: PMC5376078.

16. P. K. A sensor based IoT monitoring system for electrical devices using Blynk framework // Journal of Electronics and Informatics. – 2020. – Vol. 2, Iss. 3. – P. 182-187. DOI: 10.36548/jei.2020.3.005. EDN: KYTMOT.

17. Priyawati D., Rokhmah S., Utomo I.C. Website vulnerability testing and analysis of website application using OWASP // International Journal of Computer and Information System (IJCIS). – 2022. – Т. 3, № 3. – С. 142-147. DOI: 10.29040/ijcis.v3i3.90. EDN: FGAEWY.

18. Shvaika D.I., Shvaika A.I., Artemchuk V.O. Advancing IoT interoperability: dynamic data serialization using ThingsBoard // Journal of Edge Computing. – 2024. – DOI: 10.55056/jec.745. – EDN: ADATOL.

19. Van Schaik P., Ling J. Design parameters of rating scales for web sites // ACM Transactions on Computer-Human Interaction. – 2007. – Vol. 14, No. 1. – P. 4-es. DOI: 10.1145/1229855.1229859.

20. Widodo, Ali Nur Rifky. IOT-based smart trash monitoring using blynk application // Best: Journal of Applied Electrical, Science, & Technology. – 2021. – Vol. 3, No. 2. – P. 25-29. DOI: 10.36456/best.vol3.no2.4266. EDN: CLQNMR.

References

1. Vinarchuk A.V. Safety of web application: basic vulnerabilities and methods of protection // Nauchnyy Lider. – 2024. – No. 3 (153). – P. 29-30. – EDN: VOFHRO.

2. Gonchar D.O. Comparison of Performance of Frontend Frameworks React, Angular, Vue.js and Svelte // Molodoy uchenyy. – 2023. – No. 36 (483). – P. 11-15. – EDN: LTERGF.

3. Devitsyna S.N., Pilkevich P.V., Udod E.V. Ways to improve the security of services using JWT tokens // Economics. Information technologies. – 2023. – Vol. 50, No. 1. – P. 144-151. DOI: 10.52575/2687-0932-2023-50-1-144-151. EDN: AGOVQI.

4. Efremov M.A., Kalutskiy I.V., Tanygin M.O., Rudak I.I. The security of personal data, social networks and advertising in the global network Internet // Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering. – 2017. – Vol. 7, No. 1 (22). – P. 27-33. – EDN: YKKKLJ

5. Keymetinova V.P., Gerasimova L.V. The collection and recycling of batteries in the city of Yakutsk // Bulatovskie chteniya. – 2020. – Vol. 6. – P. 130-132. – EDN CQTPEV.

6. Klimov K.O., Piskun G.A., Likhachevsky D.V., Alekseev V.F., Shatalova V.V. IoT data analytics using AWS IoT Analytics for environmental gas analysis // Big Data and Advanced Analytics. – 2021. – No. 7-1. – P. 131-137. EDN: SFAVIY.

7. Knaub V.V., Kovalenko A.E. The Impact of Batteries on the Environment and Human Health // Molodoy uchenyy. – 2021. – No. 3 (345). – P. 343-345.

8. Moskovkin V.M. Systems for collection and recycling of batteries and accumulators according to the European model // Tverdye bytovye otkhody. – 2022. – No. 9 (195). – P. 60-64. – EDN: MITNPL.

9. Tukaev I.R., Bespoyasova V.A. Comparison of API technologies: REST, SOAP, WebSocket, GraphQL – the choice for integration with corporate systems // Systems Engineering and Information Technologies. – 2024. – Vol. 6, No. 2 (17). – P. 78-85. DOI: 10.54708/2658-5014-SIIT-2024-no2-p78. EDN: KCYBPB.

10. Lopatko N., Kenikh A., Yakovlev A., Tian E., Pirogova V.Yu. Battery recycling in Russia and the world // Vestnik Kamchatskogo politekhnicheskogo tekhnika. – 2015. – No. 13. – P. 46-51. – EDN VYUBPN.

11. Tsibizova T.Yu., Karpunin A.A. Method of hierarchies' analysis for quality assessment of managerial processes // Modern Problems of Science and Education. – 2015. – No. 2-1. – P. 200. – EDN UHWZPP.

12. Al Rasyid M.U.H., Mubarrak M.H., Nur Hasim Ja.A. Implementation of environmental monitoring based on KAA IOT platform // Bulletin of Electrical Engineering and Informatics. – 2020. – Vol. 9, No. 6. – P. 2578-2587. DOI: 10.11591/eei.v9i6.2578. EDN: PKGAJF.

13. Hamari J., Koivisto J., Sarsa H. Does Gamification Work? – A Literature Review of Empirical Studies on Gamification // 2014 47th Hawaii International Conference on System Sciences. – Waikoloa, HI, 2014. – C. 3025-3034. DOI: 10.1109/HICSS.2014.377.

14. Jaafar H., Aminuddin N.S. Comparison between NodeMCU ESP8266 and Uno R3 for software development using Ubidots // Malaysian Journal of Bioengineering and Technology (MJBET). – 2024. – Т. 1, № 1. – С. 36-40. DOI: 10.70464/mjbet.v1i1.1320. EDN: NAJOAV.

15. Looyestyn J., Kernot J., Boshoff K., Ryan J., Edney S., Maher C. Does gamification increase engagement with online programs? A systematic review // PLoS One. – 2017. – Vol. 12, № 3. – P. e0173403. DOI: 10.1371/journal.pone.0173403. PMID: 28362821; PMCID: PMC5376078.
16. P. K. A sensor based IoT monitoring system for electrical devices using Blynk framework // Journal of Electronics and Informatics. – 2020. – Vol. 2, Iss. 3. – P. 182-187. DOI: 10.36548/jei.2020.3.005. EDN: KYTMOT.
17. Priyawati D., Rokhmah S., Utomo I.C. Website vulnerability testing and analysis of website application using OWASP // International Journal of Computer and Information System (IJCIS). – 2022. – Т. 3, № 3. – С. 142-147. DOI: 10.29040/ijcis.v3i3.90. EDN: FGAEWY.
18. Shvaika D.I., Shvaika A.I., Artemchuk V.O. Advancing IoT interoperability: dynamic data serialization using ThingsBoard // Journal of Edge Computing. – 2024. – DOI: 10.55056/jec.745. – EDN: ADATOL.
19. Van Schaik P., Ling J. Design parameters of rating scales for web sites // ACM Transactions on Computer-Human Interaction. – 2007. – Vol. 14, No. 1. – P. 4-es. DOI: 10.1145/1229855.1229859.
20. Widodo, Ali Nur Rifky. IOT-based smart trash monitoring using blynk application // Best: Journal of Applied Electrical, Science, & Technology. – 2021. – Vol. 3, No. 2. – P. 25-29. DOI: 10.36456/best.vol3.no2.4266. EDN: CLQNMR.

Рыбанов Александр Александрович, кандидат технических наук, доцент, заведующий кафедрой «Информатика и технология программирования», Волжский политехнический институт (филиал) ФГБОУ ВО Волгоградский государственный технический университет, г. Волжский, Россия

Кузминский Максим Сергеевич, студент кафедры «Информатика и технология программирования», Волжский политехнический институт (филиал) ФГБОУ ВО Волгоградский государственный технический университет, г. Волжский, Россия

Rybanov Alexander Aleksandrovich, Candidate of Technical Sciences, Associate Professor, Head of the Department of Informatics and Programming Technology, Volzhsky Polytechnic Institute (branch) of Volgograd State Technical University, Volzhsky, Russia

Kuzminsky Maxim Sergeevich, Student of the Department of Informatics and Programming, Volzhsky Polytechnic Institute (branch) of Volgograd State Technical University, Volzhsky, Russia

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И ПРИНЯТИЕ РЕШЕНИЙ ARTIFICIAL INTELLIGENCE AND DECISION MAKING

UDC 004.89

DOI: 10.18413/2518-1092-2026-11-3-0-3

Velikaya Ya.G.¹
Medvedev A.E.²
Vassiliev P.V.²
Mikhelev V.M.²

APPLYING MACHINE LEARNING TECHNIQUES TO THE DEVELOPMENT OF ASSISTIVE INTELLIGENT SYSTEM FOR THE HEARING IMPAIRED

¹⁾ APM Ltd., office 6, 14 Oktyabrsky Boulevard, Korolev, Moscow region, 141070, Russia

²⁾ Belgorod State National Research University,
85 Pobedy St., Belgorod, 308015, Russia

e-mail: ya.velikaya@apm.ru, 1425819@bsuedu.ru, vassiliev@bsuedu.ru, mikhelev@bsuedu.ru

Abstract

The paper proposes an intelligent assistive system for Deaf and Hard-of-Hearing users designed to transform acoustic information into a visually accessible form. The study is motivated by the growing prevalence of hearing impairment and by the limitations of conventional rehabilitation tools, which do not fully support the perception of complex acoustic environments. The system is built around a mobile architecture that combines ambient sound analysis, automatic speech recognition, and speech emotion analysis. To map sound to color, the paper introduces an auxiliary textual modality and performs semantic matching between sound descriptions and color descriptions. The experiments show that this approach produces stable sound–color pairs in HEX format that can be directly integrated into the system. For audio tagging, EfficientAT models were fine-tuned on the AudioSet-Strong dataset; the best performance was achieved with a 2.5-second analysis window and 1.25-second overlap, while the mn10_as model provided the best trade-off between accuracy and computational efficiency. For speech emotion visualization, the continuous Valence-Arousal-Dominance space proved more suitable than rigid categorical labels because it yields a more balanced and less subjective representation of affective states. The results support the use of multimodal learning, transfer learning, and compact neural architectures for practical assistive technologies for users with hearing loss.

Keywords: artificial intelligence; assistive technologies; hearing impairment; transfer learning; audio tagging; automatic speech recognition; speech emotion recognition; color perception

For citation: Velikaya Ya.G., Medvedev A.E., Vassiliev P.V., Mikhelev V.M. Applying Machine Learning Techniques to the Development of Assistive Intelligent System for the Hearing Impaired // Research result. Information technologies. – T. 11, № 2, 2026. – P. 28-41. DOI: 10.18413/2518-1092-2026-11-3-0-3

**Великая Я.Г.¹
Медведев А.Э.²
Васильев П.В.²
Михелев В.М.²**

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ПРИ СОЗДАНИИ АССИСТИВНОЙ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ ДЛЯ ЛЮДЕЙ С НАРУШЕНИЯМИ СЛУХА

¹⁾ Научно-технический центр «АПМ»,

Октябрьский бульвар, 14, офис №6, г. Королев, Московская область, 141070, Россия

²⁾ Белгородский государственный национальный исследовательский университет,
ул. Победы, 85, г. Белгород, 308015, Россия

e-mail: ya.velikaya@apm.ru, 1425819@bsuedu.ru, vassiliev@bsuedu.ru, mikhelev@bsuedu.ru

Аннотация

В статье предложена концепция интеллектуальной ассистивной системы для глухих и слабослышащих, ориентированной на преобразование акустической информации в визуально доступный формат. Актуальность работы обусловлена ростом числа людей с нарушением слуха и ограниченностью традиционных средств компенсации слуховых потерь, которые не обеспечивают полноценного восприятия сложной акустической среды. В качестве основы системы рассматривается мобильная архитектура, включающая обработку окружающих звуков, автоматическое распознавание речи и анализ эмоциональной окраски речи. Для сопоставления звука и цвета предложен подход, использующий текстовую промежуточную модальность и семантическое сравнение описаний звуков и цветовых оттенков. Экспериментально показано, что такое сопоставление позволяет получать устойчивые пары «звук – цвет» в HEX-формате, пригодные для дальнейшей интеграции в систему. Для классификации аудио выполнено дообучение моделей семейства EfficientAT на датасете AudioSet-Strong; установлено, что оптимальным является окно анализа 2,5 с при перекрытии 1,25 с, а модель «mn10_as» демонстрирует наилучший баланс качества и вычислительной эффективности. Для отображения эмоций речи показано преимущество непрерывного пространства Valence-Arousal-Dominance по сравнению с жесткой категориальной классификацией, поскольку оно дает более равномерное и менее субъективное представление эмоциональных состояний. Полученные результаты подтверждают перспективность применения мультимодальных методов, переноса обучения и компактных нейросетевых моделей для создания практической системы поддержки пользователей с нарушением слуха.

Ключевые слова: искусственный интеллект; ассистивные технологии; проблемы со слухом; перенос обучения; классификация аудиособытий; автоматическое распознавание речи; распознавание эмоций речи; цветовое восприятие

Для цитирования: Великая Я.Г., Медведев А.Э., Васильев П.В., Михелев В.М. Применение методов машинного обучения при создании ассистивной интеллектуальной системы для людей с нарушениями слуха // Научный результат. Информационные технологии. – Т.11, №3, 2026. – С. 28-41. DOI: 10.18413/2518-1092-2026-11-3-0-3

INTRODUCTION

Today, hearing impairment has evolved from a purely medical issue into a global social challenge. According to current data from the World Health Organization (WHO), over 1.5 billion people (nearly 20% of the global population) live with degree of hearing loss [23]. Of these, approximately 430 million suffer from moderate to severe disabling hearing loss, requiring mandatory rehabilitation. Experts project that by 2050, the total number of people with hearing problems could rise to 2.5 billion, with 700 million requiring specialized assistance.

The problem in the Russian Federation is equally concerning. Monitoring by private analytical firms and professional medical communities indicates that more than 13 million citizens (roughly 9% of the population) suffer from hearing impairments [1]. Notably, this figure has increased by 20% over recent decades and has yet to peak. This trend is driven not only by an aging population but also by aggressive noise pollution in major metropolitan areas and the unregulated use of personal audio devices, which leads to hearing issues in young adulthood.

Given that individuals typically receive 20–25% of their daily information through auditory channels, hearing loss creates a critical information vacuum. Furthermore, the significance of sound increases substantially during face-to-face interaction, and in telephone conversations, the dependence on auditory information reaches nearly 100%, isolating Deaf and Hard-of-Hearing (DHH) people from these communication channels.

Traditionally, hearing aids and cochlear implants are used to compensate for lost auditory functions. While these solutions have revolutionized rehabilitation by enabling sound perception and speech development, they possess critical limitations. Hearing aids do not function like glasses – they do not turn "blurry" sound into "clear"; rather, they amplify all audio, including background noise, which often results in "acoustic chaos". Conversely, cochlear implantation requires invasive surgery and a lengthy adaptation period, with accessibility often restricted by strict medical quotas. Ultimately, neither device serves as a universal solution capable of fully restoring the cognitive and emotional nuances of sound or ensuring seamless communication in complex acoustic environments.

Therefore, developing next-generation intelligent systems that function as "intelligent assistants" is becoming critically important. By integrating audio tagging, automatic speech recognition (ASR) [12], and speech emotion recognition (SER) [21, 22], these solutions offer DHH people fundamentally new ways to interact with the world. Systems integrated with augmented reality (AR) are particularly promising, as they transform acoustic data into real-time text cues and dynamic color patterns. This approach utilizes vision as the dominant sensory channel by encoding sound through color. Thus, this comprehensive framework aims to convert inaccessible audio into a structured visual environment, fostering information awareness, psychological comfort, and social integration.

PROPOSED SYSTEM ARCHITECTURE

Based on the specific characteristics of the domain, two primary workflows can be identified: environmental sound analysis (both indoor and outdoor) and automated speech analysis for transcription and emotion recognition. Furthermore, the system must satisfy several technical requirements: real-time processing, noise robustness, and compatibility with the resource constraints of mobile and edge devices. Graphical design considerations are beyond the scope of this article, as they necessitate separate research. Fig. 1 presents the context diagram (A) and the data flow diagrams for the corresponding neural network subsystems (B) and (C).

While the purpose of most components is self-evident, several require clarification. In diagram (A), the term "user" may refer to a specific output device, such as AR glasses, rather than an "end user". In this context, utilizing AR glasses is more productive than a smartphone screen. However, the smartphone remains necessary for computation, as AR glasses often lack onboard processors. The "basic audio pre-processing" block encompasses operations beneficial to both subsystems, such as resampling to a fixed frequency, amplitude normalization, DC offset removal, and audio windowing. Applying noise reduction at this stage is counterproductive, as it is highly likely to suppress relevant non-speech sounds that the environmental recognition subsystem is designed to detect.

In diagram (B), the "result post-processing" block may include confidence threshold filtering, temporal smoothing, and event aggregation (e.g., Top-K pooling). Subsequently, the resulting class labels are mapped to corresponding color codes. A distinct task involves developing the rules for mapping each class to a specific color. Although the most common approach utilizes fixed "class-color" pairs (such as "scream–red") a primary challenge lies in the justification of color selection for specific sounds. The section "Method for sound-to-color mapping" proposes a specific solution to this problem.

In diagram (C), the role of the noise reduction stage remains a subject of further research, as modern intelligent ASR architectures are pre-trained on noisy speech and are inherently robust. Consequently, active noise cancellation may severely distort the original signal and impede accurate speech recognition, particularly within "emotional" workflows. It is more safely to apply "soft" noise reduction via a band-pass speech filter (80-8000 Hz). This eliminates low-frequency hum and high-frequency hiss while preserving the critical frequency range for speech.




Fig. 1. High-level system architecture
Рис. 1. Высокоуровневая архитектура системы

In transcription workflow, ASR and "text post-processing" blocks are increasingly integrated into end-to-end architectures, such as the GigaAM v3 model family for the Russian language [2]. For emotion recognition, two primary descriptive frameworks exist: discrete class labels or a continuous 3D Valence-Arousal-Dominance (VAD) space based on acoustic characteristics [21, 22]. Valence represents the "unpleasant-pleasant" axis, Arousal denotes "calm-excited" axis, and Dominance signifies "submissive-dominant" axis. We utilize the latter approach, as it conveys emotional states more precisely than text labels. The validity of this method, along with the mapping of specific emotions to color scales, is covered in the "Method for emotion-to-color mapping" section.

METHOD FOR SOUND-TO-COLOR MAPPING

The term "modality" (lat. *modus*, meaning "method" or "measure") was originally used in psychology to categorize types of sensory information, such as vision, hearing, touch, etc [10]. Artificial intelligence has adopted and expanded this term to describe any structured data suitable for model training, ranging from common formats like text and audio to specialized data like protein molecular structures. Beyond basic modalities, the concept of cross-modality refers to the ability to map, translate, or generate information from one modality to another based on semantic relationships (e.g., text-to-image synthesis) [26].

Mathematically, cross-modality relies on formalized methods to align diverse data types based on semantic proximity. This is achieved through a latent space (lat. *latens*, meaning "hidden") [15], into which

representation vectors, or embeddings, are projected. These embeddings are numerical arrays where each value corresponds to a specific feature dimension. The similarity between inputs is determined by cosine distance: a smaller distance indicates that the information is more "semantically similar". Thus, the embeddings for the word "cat," an image of a cat, and the sound "meow" will cluster closely within the latent space.

This paper addresses the problem of cross-modal transition from sound to color. This is a non-trivial task, as the color modality remains under-researched, resulting in a limited number of available tools. A prominent example of this phenomenon is chromesthesia, a neurological condition where sounds, music, or voices evoke specific colors and shapes. For instance, the composer Alexander Scriabin possessed this unique ability and developed a personal system mapping musical notes to primary hues. However, the primary limitation of this approach is its inherent subjectivity. This is evidenced by the existence of numerous pitch-color systems (e.g., Newton, Klein), which assign colors to musical notes inconsistently [6]. Furthermore, regarding non-musical sounds (such as street, household, or natural noises) no standardized system exists to establish an objective correspondence to specific shades.

Consequently, a direct, evidence-based cross-modal transition from sound to color is nearly impossible. Therefore, we propose the introduction of an auxiliary textual modality. Within this framework, both sound and color are assigned textual descriptions, which are then compared for semantic alignment as discussed previously. The textual description of sounds is straightforward, utilizing audio labels from a predefined vocabulary. Since the textual description of color is a distinct psychological challenge, it is appropriate to employ existing datasets. Fig. 2 presents a visual schematic of this approach.




Fig. 2. Method for sound-to-color mapping
Рис. 2. Методика отображения звука в цвет

Thus, it is possible to perform a mathematically grounded mapping. To demonstrate this approach, an experiment was conducted using BGE-M3 [5] (SOTA open-source model) as the text encoder, alongside the comprehensive Color-Pedia [4] dataset for color descriptions. The results of this experiment are illustrated in Fig. 3.

#AC44E2	– [0.49] – The sound of Subway, metro, underground	#55A8B5	– [0.47] – The sound of Studio recording
#36E1B1	– [0.51] – The sound of Sonic boom	#94DCCE	– [0.48] – The sound of Bathroom sounds
#0975D5	– [0.49] – The sound of Basketball bounce	#06CDEE	– [0.50] – The sound of Sneeze
#8389BD	– [0.50] – The sound of Cart	#E8DE9D	– [0.51] – The sound of Ringtone
#E8DE9D	– [0.50] – The sound of Washing machine	#98B4CB	– [0.52] – The sound of Yak
#E5E365	– [0.49] – The sound of Digestive	#E8DE9D	– [0.47] – The sound of Conversation
#BDC79F	– [0.48] – The sound of Bird	#FF100B	– [0.57] – The sound of Engine knocking
#A0F7F7	– [0.49] – The sound of Singing	#E8DE9D	– [0.53] – The sound of Bee, wasp, etc.
#F37E7D	– [0.55] – The sound of Dial tone	#C0A909	– [0.46] – The sound of Stomach rumble
#77F99C	– [0.48] – The sound of Change ringing (campanology)	#DBB435	– [0.49] – The sound of Railroad car, train wagon
#FC042C	– [0.51] – The sound of Explosion	#75F49D	– [0.53] – The sound of Gull, seagull
#FD1808	– [0.55] – The sound of Aircraft engine	#6E5F6A	– [0.47] – The sound of Snoring
#4BCD55	– [0.51] – The sound of Sink (filling or washing)	#B58016	– [0.51] – The sound of Drill
#D8A63C	– [0.49] – The sound of Toothbrush	#EE524B	– [0.51] – The sound of Mantra
#FF100B	– [0.62] – The sound of Fire engine, fire truck (siren)	#A5DAEB	– [0.49] – The sound of Bus
#E77E1A	– [0.52] – The sound of Ambulance (siren)	#E8DE9D	– [0.47] – The sound of Cough
#DBB435	– [0.53] – The sound of Motor vehicle (road)	#43EB9C	– [0.51] – The sound of Reverberation
#999419	– [0.51] – The sound of Wild animals	#B6BD33	– [0.51] – The sound of Sawing
#FC042C	– [0.63] – The sound of Firecracker	#0DF9DF	– [0.54] – The sound of Boat, Water vehicle
#BE4338	– [0.47] – The sound of Kettle whistle	#FE9809	– [0.49] – The sound of Bicycle, tricycle

Fig. 3. Results of semantic mapping between descriptions of various sounds and color hues

Рис. 3. Результаты семантического сопоставления описания различных звуков и цветовых оттенков

Based on the dataset, each color description was formulated as follows: "Color: {Color Name}. {Description}". It evokes {Emotion} and symbolizes {Symbolism}", with the bracketed placeholders replaced by corresponding values from the dataset columns. Audio labels were sourced from the AudioSet "Strong" version [11]; the rationale for selecting this specific dataset is detailed in "Audio classifier fine-tuning" section. Additionally, the prefix "The sound of..." was added to each label to assist the encoder and enhance the mapping accuracy.

Based on Fig. 3, we concluded that many of the generated pairs are semantically coherent and exhibit sufficient chromatic diversity. For instance, sounds of sirens and engines align more closely with red hues, while natural sounds gravitate toward lighter shades. The similarity metric is evaluated on a scale of (0...1), with specific pair scores indicated in brackets; most values are concentrated around 0.5 value. This does not imply a "50% probability of similarity", but rather indicates a moderate semantic connection or a distinct mapping tendency that outperforms other potential color matches. Overall, the (0.5...0.6) range represents an optimal threshold, as it remains significantly above random noise without suggesting absolute identity. Achieving higher scores is generally only possible when the color name explicitly contains the sound class (e.g., the sound of the ocean paired with the color "deep ocean").

Thus, by leveraging text as an auxiliary modality, a dictionary of "sound-color" pairs was obtained in HEX format for system integration. This dictionary requires minimal storage and eliminates real-time computational overhead, as it is generated once using a high-capacity encoder and subsequently loaded into the system.

AUDIO CLASSIFIER FINE-TUNING

As demonstrated above, the dataset of psychological color descriptions combined with a text encoder provides sufficient rules for establishing a definitive correspondence between sound and color hue. Nevertheless, the selection of audio labels and the choice of the classification model itself remain distinct challenges. Audio tagging remains an unresolved problem and is the subject of extensive research. There are several approaches exist, the most two prominent of which include methods based on contrastive learning and the Zero-Shot paradigm (e.g., the CLIP [3, 17] and CLAP [24] models family), as well as the direct prediction of class labels from a predefined set (e.g., AudioSet [8], FSD50K [7], etc).

The concepts underlying contrastive learning and Zero-Shot prediction represent a fundamentally different approach to machine perception compared to rigid classification. These technologies function by creating a unified semantic space where semantic vectors of audio, text, or images converge based on their inherent relationships. This enables models to recognize objects and phenomena not encountered during training by relying solely on textual descriptions. This transition from closed vocabularies to infinite conceptual associations constitutes a significant technological breakthrough, ultimately revolutionizing how artificial intelligence interacts with multimodal data. Currently, however, existing models still struggle

with accurately interpreting complex tasks and noisy data, leading to instability in unusual cases. Furthermore, these models are computationally intensive, presenting challenges for real-time deployment on mobile and edge systems.

Consequently, we propose employing a rigid classification approach, which continues to cover a wide range of use cases while maintaining operational stability. The primary benchmark for model selection in this field is AudioSet, which comprises approximately 2 million 10-second audio clips labeled across 527 classes. State-of-the-art solutions are predominantly transformer-based models (such as PaSST [14]), which remain unsuitable for the proposed system due to stringent computational resource constraints. However, architectures like EfficientAT [18] utilize lightweight CNN blocks while still maintaining SOTA performance. This is achieved through knowledge distillation from a larger teacher model.

To fully integrate a model from the EfficientAT family into the system, fine-tuning is required to reduce the processing window from 10-second segments to significantly shorter intervals, such as 2 or 3 seconds. This adjustment is critical for ensuring the system provides instantaneous responses to environmental events. While a 10-second rolling buffer remains viable, it is more efficient to analyze it using overlapping windows. Full-segment processing imposes additional computational overhead by redundantly analyzing the same data points; conversely, sliding window inference eliminates these redundant calculations and increases the probability of low-latency event detection.

For fine-tuning, we utilized the "Strong" version of the AudioSet dataset [11]. This subset consists of approximately 120,000 audio clips featuring human-annotated strong labels. Unlike the original dataset, which only indicates the presence of an event, these labels specify precise temporal boundaries. Consequently, the audio can be segmented into windows of arbitrary length, with each segment assigned its own corresponding set of labels.

During fine-tuning, a new classification head with random weights is assigned to the pre-trained backbone, featuring 456 classes instead of the original 527. The classifier structure was adopted from the original source. Since the model was initially trained on these audio files using weak tagging, it is reasonable to assume that training the head requires minimal computational resources; in this case, 30 epochs were enough. During the training process, a single random segment of uniform length is sampled from each audio file per epoch, and the events occurring within that window are calculated. An event is considered present if at least 25% of its duration falls within the segment. Additionally, specific labels are used for "silence" (no acoustic activity) and "noise" (acoustic activity present without an assigned label). In total, 12 different models from the same family were fine-tuned, varying in architecture and window length (3×4).

Prior to testing, the models were exported to the ONNX [16] format, commonly utilized in production-grade solutions. Quantization yielded no performance benefit, as the models are already sufficiently lightweight, and additional computational optimization inevitably result in performance degradation. Furthermore, due to the model architecture, quantization introduces redundant conversions between int8 and float32, and theoretical performance gains are not only neutralized but actually result in a significant degradation of execution speed.

Model testing was conducted on the dataset's provided test set, which includes approximately 500 audio clips. The mAP, ROC, and F1 metrics were employed, as they are standard for this task and allow for a precise performance comparison both among these models and against others in the field. In each of the 12 evaluations, every audio file was processed using windows with a 50% overlap, with the resulting metrics subsequently averaged. A detailed comparison of the results is provided in Tab. 1. Since the model outputs class confidence scores rather than binary classifications, it is necessary to determine an optimal decision threshold. To achieve this, a ROC curve was constructed for each class, and Youden's Index [25] was applied to identify the threshold that maximizes correct detections while minimizing errors. This process results in a vector of 456 thresholds, specific to each class.

Table 1

Comparative analysis of fine-tuned EfficientAT models on the AudioSet-Strong dataset across varying window lengths

Таблица 1

Сравнительный анализ моделей EfficientAT дообученных на датасете AudioSet-Strong при различной длине окна анализа

	window = 1 (s), overlap = 0.5 (s)			window = 2 (s), overlap = 1 (s)			window = 2.5 (s), overlap = 1.25 (s)			window = 3 (s), overlap = 1.5 (s)		
	mAP	ROC	F1	mAP	ROC	F1	mAP	ROC	F1	mAP	ROC	F1
dymn10_as	30.6	95.4	44.9	33.1	96	49.8	34.6	96.4	52.9	33.5	96	51.6
mn10_as	30.3	95.3	45.1	35.2	96.7	53.7	36.9	96.9	56.6	34.9	96.8	53.6
mn05_as	30.6	95	44.4	31.7	95.6	46.8	34	95.9	50.7	31.7	95.7	49

The results demonstrate a clear non-linear relationship between the analysis window length and classification accuracy across all tested models. Analysis shows that a window length of 2.5 seconds with a 1.25 second overlap serves as the optimal configuration for this task in all key metrics. However, a further increase in the window length to 3 seconds resulted in a performance degradation across all architectures. This decline indicates that excessively large windows introduce redundant acoustic information or overlapping sound events, which creates "noise" and hinders the model's ability to precisely isolate specific classes.

It is noteworthy that while the "dymn10_as" (Dynamic MobileNet) [19] typically outperforms "mn10_as" (MobileNet V3-Large) in its original environment, it lagged behind it in this experiment. This performance discrepancy may be attributed to the ONNX export process, which is required for deployment but often introduces optimization artifacts or limits dynamic graph efficiency. Given that the conversion to ONNX is a necessary step for the inference pipeline, the theoretical advantages of dymn10_as are nullified in practice, making the standard mn10_as a more effective choice. The "mn05_as" (MobileNetV3-Large-based architecture with a 0.5 width multiplier) expectedly showed the lowest results due to its reduced parameter count, but still followed the overall trend, confirming that window length remains a critical factor regardless of the specific architecture used.

Tab. 2 presents the model performance metrics. The "Avg. latency" column indicates the delay before the model's first response, the P95 column represents the average peak load occurring in the worst 5% of cases, and the real-time factor (RTF) shows how much faster the model operates relative to real time. Other metrics were adopted from the original paper's benchmark instead of being calculated experimentally.

Table 2

Comparative performance analysis of the fine-tuned models

Таблица 2

Сравнительный анализ производительности дообученных моделей

	Size (MB)	Params (Millions)	MACs (Billions)	Avg. latency (ms)	P95	RTF
dymn10_as	40.38	10.57	0.58	85.3	92.83	0.0049
mn10_as	18.5	4.88	0.54	44.66	48.07	0.0026
mn05_as	5.55	1.43	0.16	45.71	50.2	0.0026

The data in Tab. 2 indicates that the "mn10_as" model provides the optimal performance balance, offering superior accuracy with a latency equivalent to "mn05_as", while halving the response time compared to the larger "dymn10_as" version. The high RTF across all models confirms their suitability for high-performance real-time systems, identifying "mn10_as" as the most efficient candidate for deployment.

Overall, the experimental results are satisfactory, and the fine-tuned "mn10_as" model is well-suited for our real-time system. A notable drawback is the reduction in metrics (e.g., mAP decreased from original 47.1 to 36.9); however, this is an inevitable consequence of analyzing audio in short windows, which is a requirement for this application. In this field, the YAMNet model [20] serves as the baseline with an mAP of 0.306, and our fine-tuned "mn10_as" version demonstrates significantly higher values. Even better results could be achieved by utilizing larger versions within the same model family, but this would require greater computational resources.

METHOD FOR EMOTION-TO-COLOR MAPPING

The section "Proposed system architecture" briefly noted that the emotion recognition workflow (Fig. 1, diagram C) typically utilizes two primary representation methods: discrete categorical classes (e.g., anger, joy, sadness) or the continuous 3D Valence-Arousal-Dominance (VAD) space, which based on acoustic characteristics and is increasingly adopted for this task [9, 21, 22]. Valence represents the "unpleasant-pleasant" axis, Arousal denotes "calm-excited" axis, and Dominance signifies "submissive-dominant" axis. This section justifies the selection of the VAD approach for the proposed system.

The Dusha dataset [13], the largest Russian-language emotion recognition corpus, was employed for the experiment. It contains approximately 300,000 audio recordings categorized as "neutral", "sad", "positive", "angry", or "other". A random sample of 850 instances was selected, comprising 200 samples from each primary class and 50 from the "other" category. To compute VAD characteristics, the "audeer/wav2vec2-large-robust-12-ft-emotion-msp-dim" model [22] was used, with values calculated within a 0 to 1 range. For visualization, valence and arousal were mapped to the (x; y) coordinates, respectively. As dominance contributes significantly but to a lesser extent to emotion recognition, it was assigned to the z-axis and is included in the 3D visualization. Fig. 4 illustrates the test samples mapped into the continuous Valence-Arousal space (normalized from 0...1 to -1...+1).




Fig. 4. Distribution of Dusha dataset classes in the continuous Valence-Arousal space

Рис. 4. Распределение классов датасета Dusha в непрерывном пространстве Valence-Arousal

As illustrated in Fig. 4, there are no distinct boundaries between the classes. While specific class tendencies toward certain regions can be identified – for instance, the "sad" class gravitates toward the lower-left quadrant, while "neutral" tends toward the center – the distributions generally exhibit significant overlap. We conclude that the rigid classification of emotions is inherently arbitrary and subjective. Given the lack of consensus regarding basic emotions, it is anticipated that more complex affective states, such as irony or nostalgia, would introduce further intricacy, rendering them impractical for application. In this regard, we propose relying only on numerical VAD parameters for emotion recognition, bypassing their explicit linguistic descriptions. However, to utilize these parameters effectively, a visualization tool is required; for this purpose, the color modality serves as a convenient and intuitive medium.

Existing research indicates that the HSV color model is well-suited for this task, as it aligns more closely with human visual perception than the computer-centric RGB model. For instance, in study [9], the authors addressed the problem of text colorization based on narrative sentiment by directly mapping Hue to Valence, Saturation to Arousal, and Value (brightness) to Dominance. Consequently, low Arousal results in gray tones while high Arousal produces high saturation, with the hues shifting along the Valence axis. However, such direct mapping is unsuitable for our application, as neutral (gray) tones should be positioned at the center and saturated colors at the periphery, with hue following the circumference.

Accordingly, we propose the following VAD-to-HSV mapping. First, the square Valence-Arousal space is inscribed within a circle:

$$V_C = V \cdot \sqrt{1 - \frac{A^2}{2}}; \quad A_C = A \cdot \sqrt{1 - \frac{V^2}{2}}. \quad (1)$$

Hue is calculated as:

$$\theta = \arctg_2(A_C; V_C); \quad \arctg_2 = \begin{cases} \arctg\left(\frac{y}{x}\right), & \text{if } x > 0; \\ \arctg\left(\frac{y}{x}\right) + \pi, & \text{if } x < 0, y \geq 0; \\ \arctg\left(\frac{y}{x}\right) - \pi, & \text{if } x < 0, y < 0; \\ +\frac{\pi}{2}, & \text{if } x = 0, y > 0; \\ -\frac{\pi}{2}, & \text{if } x = 0, y < 0; \\ \text{undefined}, & \text{if } x = 0, y = 0. \end{cases} \quad (2)$$

Saturation is calculated as:

$$S = \sqrt{V_C^2 + A_C^2}. \quad (3)$$

Value is mapped to Dominance. It is also necessary to incorporate a rotation mechanism for the color wheel to align prominent emotions with conventional color mappings (e.g., ensuring anger corresponds to the red spectrum):

$$\theta_{rot} = \frac{(\theta - \phi) \bmod 2\pi}{2\pi}, \quad (4)$$

where ϕ represents the offset constant in degrees.

The Hue was offset by $\phi = 135^\circ$, positioning it in the center of the second quadrant; this adjustment accounts for the observed clustering of high-arousal negative emotions, such as anger, in that region. Determining the precise value of requires further empirical study. The result is shown in Fig. 5.

The Dominance parameter ranges from 0.5 to 1, rather than the original 0 to 1. This adjustment is based on the observation that the human eye is more sensitive to light tones than dark ones, a finding consistent with the study conducted by [9]. Nevertheless, the Value parameter remains a limitation of the HSV color model due to its linear brightness scaling, which contrasts with the nonlinear nature of human visual perception. Solving this issue requires further research and precise calibration of the color model. For clarity, hard labels from the Dusha dataset were again employed. It is again evident that opposing emotions often share the same color, as the VAD model performs a rigorous mathematical analysis of acoustic properties, maintaining "fairness" across all inputs.




Fig. 5. Integration of the continuous VAD space and the HSV color model with Dusha labels
Рис. 5. Объединение непрерывного пространства VAD и цветовой модели HSV с метками Dusha

Following text transcription and color-coded emotion recognition (see Fig. 1, diagram C), the resulting data is transmitted back to the mobile application for final display. Consequently, the user sees color-coded subtitles based on the acoustic characteristics of the speech rather than the literal meaning of the words.

CONCLUSIONS

The article demonstrates that support for Deaf and Hard-of-Hearing users can be achieved not only by amplifying sound, but also by intelligently transforming acoustic information into a visual representation. The proposed architecture combines ambient sound analysis, speech transcription, and speech emotion analysis, which makes the system suitable as a general visual mediator for interaction with the environment. Additionally, a sound-to-color mapping strategy based on an auxiliary textual modality is proposed; it reduces subjectivity and ensures reproducible, semantically grounded correspondences. The related experimental part confirms that fine-tuned EfficientAT models are viable for real-time use, and that the 2.5-second analysis window with 1.25-second overlap is the most effective configuration for the task. It is also shown that the continuous Valence-Arousal-Dominance space is a more appropriate representation for speech emotion visualization, since it better reflects the acoustic nature of emotion and avoids arbitrary class boundaries.

Future work should focus on software implementation, AR integration, user interface design, and user-oriented validation of the proposed visual encoding rules for sound events and speech emotions.

Conflict of interest: no potential conflict of interest related to this article was reported.

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

References

1. Allenova O. Why hearing impairment is becoming an epidemic and how to help a hard of hearing child. – 2025. URL: <https://www.kommersant.ru/doc/8137179?ysclid=mun3qme9a243654957> (in Russian).
2. Kutsakov A. 2025. GigaAM-v3: open SOTA speech recognition model in Russian. URL: <https://habr.com/ru/companies/sberdevices/articles/973160/?ysclid=mun3sq2c6684552654> (in Russian).
3. Medvedev A.E., Mikhelev V.M. Analysis of the principle of cross-modality in artificial intelligence tasks using the CLIP model. Digital, computer and information technologies in science and education. Bryansk. RISO BGU. – 2. – 2026. – 343 p. (in Russian).
4. Boltuix. Color-Pedia: a dataset for color naming tasks, palette generation and emotional analysis. Hugging Face. – 2025. URL: <https://huggingface.co/datasets/boltuix/color-pedia>
5. Chen J., Xiao S., Zhang P., Luo K., Lian D., Liu Z. M3-Embedding: Multi-Linguality, Multi-Functionality, Multi-Granularity Text Embeddings Through Self-Knowledge Distillation. – 2025. – arXiv:2402.03216v5.
6. Collopy F. Playing (With) Color. Glimpse. 2(3). – 2009. – P. 62-67.
7. Fonseca E., Favory X., Pons J., Font F., Serra X. FSD50K: An Open Dataset of Human-Labeled Sound Events. – 2022. – ArXiv:2010.00475.
8. Gemmeke J.F., Ellis D.P.W., Freedman D., Jansen A., Lawrence W., Moore R. C., Plakal M., Ritter M. Audio Set: An ontology and human-labeled dataset for audio events. Proc. IEEE ICASSP. – 2017. – pp. 776-780, doi: 10.1109/ICASSP.2017.7952261.
9. Geuder P., Leidingner M. C., von Lupin M., Dörk M., Schröder T. Emosaic: Visualizing Affective Content of Text at Varying Granularity. – 2020. – ArXiv:2002.10096.
10. Gibson J.J. The senses considered as perceptual systems. Boston: Houghton Mifflin, 1966. – 335 p.
11. Hershey S., Ellis D.P.W., Fonseca E. et al. The Benefit of Temporally-Strong Labels in Audio Event Classification. – 2021. – ArXiv:2105.07031.
12. Jurafsky D., Martin J.H. Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition with Language Models. Third Edition. – 2026. – 621 p.
13. Kondratenko V., Sokolov A., Karpov N., Kutuzov O., Savushkin N., Minkin F. Large Raw Emotional Dataset with Aggregation Mechanism. – 2022. – ArXiv:2212.12266.
14. Koutini K., Schlüter J., Eghbal-zadeh H., Widmer G. Efficient Training of Audio Transformers with Patchout. – 2022. – ArXiv:2110.05069.
15. Liu Y., Jun E., Q. Li, Heer J. Latent Space Cartography: Visual Analysis of Vector Space Embeddings. Computer Graphics Forum. 38(3). – 2019. – 67-78.
16. ONNX Community. ONNX: Open Neural Network Exchange. 2026. URL: <https://onnx.ai/> (accessed: 26.03.2026).
17. Radford A., Kim J. et al. 2021. Learning Transferable Visual Models From Natural Language Supervision. ArXiv:2103.00020.
18. Schmid F., Koutini K., Widmer G. Efficient Large-Scale Audio Tagging Via Transformer-to-CNN Knowledge Distillation. 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Rhodes Island, Greece, 2023, pp. 1-5, doi: 10.1109/ICASSP49357.2023.10096110
19. Schmid F., Koutini K., Widmer G. Dynamic Convolutional Neural Networks as Efficient Pre-trained Audio Models. – 2023. – ArXiv:2310.15648.
20. TensorFlow Authors. YAMNet: a model for audio event classification based on MobileNetV1. GitHub. 2026.
21. Tzirakis P., Nguyen A., Zafeiriou S., Schuller B.W. Speech Emotion Recognition Using Semantic Information. – 2021. – arXiv:2103.02993v1.
22. Wagner J., Triantafyllopoulos A., Wierstorf H., Schmitt M., Burkhardt F., Eyben F., Schuller B.W. Dawn of the transformer era in speech emotion recognition: closing the valence gap. IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2023. – vol. 45, no. 9, pp. 10745-10759, doi: 10.1109/TPAMI.2023.3263585.
23. World Health Organization. World report on hearing. Geneva: WHO, 2021. – 272 p.
24. Wu Y., Chen K., Zhang T. et al. Large-scale Contrastive Language-Audio Pretraining with Feature Fusion and Keyword-to-Caption Augmentation. – 2024. – ArXiv:2211.06687.
25. Youden W.J. Index for rating diagnostic tests. Cancer. 3(1). – 1950. – 32-35.

26. Zhang C., Yang Z., He X., Deng L. Multimodal Intelligence: Representation Learning, Information Fusion, and Applications. *IEEE Journal of Selected Topics in Signal Processing*. 14(3). – 2020. – 478-493.

Список литературы

1. Алленова О. Почему нарушение слуха становится эпидемией и как помочь слабослышащему ребенку. 18 окт. – 2025. URL: <https://www.kommersant.ru/doc/8137179?ysclid=mun3qme9a243654957>
2. Куцаков А. 2025. GigaAM-v3: открытая SOTA-модель распознавания речи на русском. 4 дек. URL: <https://habr.com/ru/companies/sberdevices/articles/973160/?ysclid=mun3sq2c6684552654>
3. Медведев А.Э., Михелёв В.М. Анализ принципа кросс-модальности в задачах искусственного интеллекта на примере модели CLIP. *Цифровые, компьютерные и информационные технологии в науке и образовании*. 2. – 2026. – 343 с.
4. Boltuix. Color-Pedia: a dataset for color naming tasks, palette generation and emotional analysis. *Hugging Face*. – 2025. URL: <https://huggingface.co/datasets/boltuix/color-pedia>
5. Chen J., Xiao S., Zhang P., Luo K., Lian D., Liu Z. M3-Embedding: Multi-Linguality, Multi-Functionality, Multi-Granularity Text Embeddings Through Self-Knowledge Distillation. – 2025. – arXiv:2402.03216v5.
6. Collopy F. Playing (With) Color. *Glimpse*. 2(3). – 2009. – P. 62-67.
7. Fonseca E., Favory X., Pons J., Font F., Serra X. FSD50K: An Open Dataset of Human-Labeled Sound Events. – 2022. – ArXiv:2010.00475.
8. Gemmeke J.F., Ellis D.P.W., Freedman D., Jansen A., Lawrence W., Moore R. C., Plakal M., Ritter M. Audio Set: An ontology and human-labeled dataset for audio events. *Proc. IEEE ICASSP*. – 2017. – pp. 776-780, doi: 10.1109/ICASSP.2017.7952261.
9. Geuder P., Leidinger M. C., von Lupin M., Dörk M., Schröder T. Emosaic: Visualizing Affective Content of Text at Varying Granularity. – 2020. – ArXiv:2002.10096.
10. Gibson J.J. *The senses considered as perceptual systems*. Boston: Houghton Mifflin, 1966. – 335 p.
11. Hershey S., Ellis D.P.W., Fonseca E. et al. The Benefit of Temporally-Strong Labels in Audio Event Classification. – 2021. – ArXiv:2105.07031.
12. Jurafsky D., Martin J.H. *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition with Language Models*. Third Edition. – 2026. – 621 p.
13. Kondratenko V., Sokolov A., Karpov N., Kutuzov O., Savushkin N., Minkin F. Large Raw Emotional Dataset with Aggregation Mechanism. – 2022. – ArXiv:2212.12266.
14. Koutini K., Schlüter J., Eghbal-zadeh H., Widmer G. Efficient Training of Audio Transformers with Patchout. – 2022. – ArXiv:2110.05069.
15. Liu Y., Jun E., Q. Li, Heer J. Latent Space Cartography: Visual Analysis of Vector Space Embeddings. *Computer Graphics Forum*. 38(3). – 2019. – 67-78.
16. ONNX Community. ONNX: Open Neural Network Exchange. 2026. URL: <https://onnx.ai/> (дата обращения: 26.03.2026).
17. Radford A., Kim J. et al. Learning Transferable Visual Models From Natural Language Supervision. – 2021. – ArXiv:2103.00020.
18. Schmid F., Koutini K., Widmer G. Efficient Large-Scale Audio Tagging Via Transformer-to-CNN Knowledge Distillation. 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Rhodes Island, Greece, 2023, pp. 1-5, doi: 10.1109/ICASSP49357.2023.10096110
19. Schmid F., Koutini K., Widmer G. Dynamic Convolutional Neural Networks as Efficient Pre-trained Audio Models. – 2023. – ArXiv:2310.15648.
20. TensorFlow Authors. YAMNet: модель для классификации аудиособытий на основе MobileNetV1. GitHub. – 2026. –
21. Tzirakis P., Nguyen A., Zafeiriou S., Schuller B.W. Speech Emotion Recognition Using Semantic Information. – 2021. – arXiv:2103.02993v1.
22. Wagner J., Triantafyllopoulos A., Wierstorf H., Schmitt M., Burkhardt F., Eyben F., Schuller B.W. Dawn of the transformer era in speech emotion recognition: closing the valence gap. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 2023. – vol. 45, no. 9, pp. 10745-10759, doi: 10.1109/TPAMI.2023.3263585.
23. World Health Organization. *World report on hearing*. Geneva: WHO, 2021. – 272 p.
24. Wu Y., Chen K., Zhang T. et al. Large-scale Contrastive Language-Audio Pretraining with Feature Fusion and Keyword-to-Caption Augmentation. – 2024. – ArXiv:2211.06687.
25. Youden W.J. Index for rating diagnostic tests. *Cancer*. 3(1). – 1950. – 32-35.

26. Zhang C., Yang Z., He X., Deng L. Multimodal Intelligence: Representation Learning, Information Fusion, and Applications. *IEEE Journal of Selected Topics in Signal Processing*. 14(3). – 2020. – 478-493.

Velikaya Yana Gennadiyevna, Candidate of Technical Sciences, Mathematician and Programmer, APM Ltd, Korolev, Russia
Medvedev Arsenii Eduardovich, Master's student of the Department of Mathematical and Software Support for Information Systems, Belgorod State National Research University, Belgorod, Russia

Vassiliev Pavel Vladimirovich, Candidate of Technical Sciences, Associate Professor of the Department of Mathematical and Software Support for Information Systems, Belgorod State National Research University, Belgorod, Russia

Mikhelev Vladimir Mikhailovich, Candidate of Technical Sciences, Associate Professor of the Department of Mathematical and Software Support for Information Systems, Belgorod State National Research University, Belgorod, Russia

Великая Яна Геннадьевна, кандидат технических наук, математик-программист, научно-технический центр «АПМ», г. Королёв, Россия

Медведев Арсений Эдуардович, магистрант кафедры математического и программного обеспечения информационных систем, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Васильев Павел Владимирович, кандидат технических наук, доцент кафедры математического и программного обеспечения информационных систем, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Михелев Владимир Михайлович, кандидат технических наук, доцент кафедры математического и программного обеспечения информационных систем, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

УДК 004.891.2,004.032.26

DOI: 10.18413/2518-1092-2026-11-3-0-4

Левина Т.М.
Беляков Я.В.

ОПТИМИЗАЦИЯ ГИБРИДНОГО АЛГОРИТМА ПОИСКА В ТЕКСТОВЫХ КОРПУСАХ НА ОСНОВЕ МНОГОУРОВНЕВЫХ МЕТРИК РЕЛЕВАНТНОСТИ

Институт нефтепереработки и нефтехимии ФГБОУ ВО УГНТУ в г. Салавате,
ул. Губкина, 22Б, г. Салават, 453250, Россия

e-mail: belyakov.yaroslav@bk.ru

Аннотация

Актуальность исследования обусловлена экспоненциальным ростом объемов неструктурированных текстовых данных и возрастающими требованиями к скорости и релевантности их обработки в таких прикладных областях, как анализ новостных потоков, интеллектуальный поиск и обработка естественного языка (NLP). Существующие алгоритмы поиска часто сталкиваются с проблемами низкой точности из-за морфологической сложности языков (например, русского), наличия большого количества шумовых слов и необходимости учета семантической близости. Цель работы – разработка и исследование гибридного алгоритма поиска, сочетающего метрики лексического соответствия, морфологического анализа (стемминг) и взвешенного ранжирования для повышения полноты и точности поиска в текстовых корпусах. Научная новизна заключается в предложенной многоуровневой метрике релевантности, которая интегрирует подсчет точных совпадений, анализ основ слов с использованием оптимизированного стемминга для русского языка и временные характеристики документов. Методология включает разработку алгоритма, его программную реализацию и сравнительный анализ эффективности на реальном наборе данных, а именно новостей. В ходе эксперимента подтверждено, что гибридный подход позволяет достичь более высокой точности (на 15-20%) по сравнению с базовыми методами, особенно при работе с разносклоняемыми формами слов и составными запросами. Выводы работы указывают на перспективность дальнейшего развития предложенного подхода за счет интеграции семантических векторных моделей и глубокого обучения для учета контекстной близости понятий.

Ключевые слова: информационный поиск; стемминг; морфологический анализ; метрики релевантности; ранжирование; алгоритм оптимизации; обработка естественного языка

Для цитирования: Левина Т.М., Беляков Я.В. Оптимизация гибридного алгоритма поиска в текстовых корпусах на основе многоуровневых метрик релевантности // Научный результат. Информационные технологии. – Т.11, №3, 2026. – С. 42-48. DOI: 10.18413/2518-1092-2026-11-3-0-4

Levina T.M.
Belyakov Ya.V.

OPTIMIZATION OF A HYBRID SEARCH ALGORITHM IN TEXT CORPORA BASED ON MULTI-LEVEL RELEVANCE METRICS

Institute of Oil Refining and Petrochemistry
Federal State Budgetary Educational Institution of Higher Education USPTU in Salavat,
22B Gubkin St., Salavat, 453250, Russia

e-mail: belyakov.yaroslav@bk.ru

Abstract

The relevance of this research stems from the exponential growth of unstructured text data and the increasing demands on the speed and relevance of its processing in such applied areas as news analysis, intelligent search, and natural language processing (NLP). Existing search algorithms often face problems with low accuracy due to the morphological complexity of languages (e.g., Russian), the presence of a large number of noise words, and the need to account for semantic similarity. The goal of this study is to develop and evaluate a hybrid search algorithm that combines lexical match metrics, morphological analysis (stemming), and weighted ranking to improve the completeness and accuracy of searches in text corpora. The scientific innovation lies in the

proposed multi-level relevance metric, which integrates exact match counting, word stemming analysis using optimized stemming for the Russian language, and document temporal characteristics. The methodology includes algorithm development, its software implementation, and a comparative analysis of its effectiveness on a real-world dataset, namely, news. The experiment confirmed that the hybrid approach achieves 15-20% higher accuracy than basic methods, especially when working with inflected word forms and compound queries. The study's findings suggest potential for further development of the proposed approach by integrating semantic vector models and deep learning to account for the contextual proximity of concepts.

Keywords: information retrieval; stemming; morphological analysis; relevance metrics; ranking; optimization algorithm; natural language processing

For citation: Levina T.M., Belyakov Ya.V. Optimization of a Hybrid Search Algorithm in Text Corpora Based on Multi-Level Relevance Metrics // Research result. Information technologies. – Т.11, №3, 2026. – P. 42-48. DOI: 10.18413/2518-1092-2026-11-3-0-4

ВВЕДЕНИЕ

Современная цифровая эпоха характеризуется лавинообразным ростом объемов текстовой информации. Новостные агрегаторы, архивы документов, базы знаний и системы поддержки принятия решений требуют эффективных механизмов для быстрого и точного поиска необходимых сведений. Классические методы поиска, основанные на точном лексическом соответствии (keyword search), демонстрируют недостаточную эффективность при работе с естественными языками, обладающими богатой морфологией, таким как русский язык. Проблема усугубляется наличием синонимии, омонимии и необходимостью фильтрации нерелевантной информации (стоп-слов).

Эволюция технологий поиска прошла путь от простого инвертированного индекса до сложных систем, учитывающих семантику и контекст. Однако, несмотря на успехи глубокого обучения, гибридные подходы, комбинирующие лингвистические методы и статистические метрики, остаются наиболее практичным и эффективным решением для многих прикладных задач, особенно в условиях ограниченных вычислительных ресурсов или специализированных предметных областей.

Основная проблема заключается в разработке алгоритма, который не только находит документы, содержащие ключевые слова запроса, но и ранжирует их по степени релевантности, учитывая морфологические вариации, значимость терминов и актуальность документа во времени.

ОСНОВНАЯ ЧАСТЬ

Проблема информационного поиска традиционно занимает центральное место в компьютерной лингвистике и науке о данных. Классические модели, включая булеву, векторную и вероятностную модель BM25, подробно исследованы в фундаментальных трудах по информационному поиску [4, 5]. Следует отметить, что модель BM25 продолжает оставаться эталоном в области полнотекстового поиска, хотя ее эффективность существенно зависит от качества токенизации и лемматизации входных текстов.

Для языков с развитой морфологической системой, к которым относится русский язык, этап приведения слов к нормальной форме представляется особенно значимым. Алгоритм стемминга Портера для русского языка [6] длительное время оставался доминирующим методом, несмотря на потенциально избыточное или недостаточное отсечение. Современные подходы демонстрируют тенденцию к использованию морфологических анализаторов, таких как MyStem [7], и методов машинного обучения [3], что, однако, сопровождается возрастанием вычислительной сложности.

Проблема ранжирования результатов поиска находит широкое освещение в научной литературе. Алгоритм PageRank [8] заложил фундамент для ссылочного ранжирования в веб-пространстве. В контексте полнотекстового поиска активно применяются метрики, основанные на частоте терминов и обратной частоте документа [9]. Важно подчеркнуть, что классический TF-IDF не учитывает позиционные характеристики терминов, их взаимную близость и временные параметры документов.

В последние годы наблюдается растущий интерес к гибридным системам, интегрирующим символьные и нейросетевые подходы [10]. Трансформерные архитектуры и модели типа BERT [11] демонстрируют впечатляющие результаты в области семантического анализа, однако их практическое применение для поиска по крупным документальным коллекциям остается ограниченным вследствие высокой вычислительной стоимости. В этой связи актуальной научной задачей становится разработка облегченных гибридных методов, использующих глубокое обучение для тонкой настройки релевантности поверх результатов, полученных более эффективными лингвистическими методами [12].

Значительный вклад в оптимизацию поисковых процессов внесен работами по кэшированию и параллельным вычислениям [13, 14], ставшим неотъемлемым компонентом промышленных систем. Вопросы оценки качества поиска через метрики Precision, Recall и F-мера глубоко исследованы в работах по информационному поиску [1, 15]. Особого внимания заслуживает исследование [16], где подчеркивается важность учета временных характеристик документов в таких предметных областях, как новостные потоки.

Несмотря на значительное количество исследований в данной области, наблюдается определенный дефицит работ, комплексно рассматривающих всю технологическую цепочку обработки – от морфологической нормализации до финального ранжирования – с фокусом на оптимизацию для русского языка и специализированных корпусов.

Целью данного исследования является разработка и экспериментальная проверка гибридного алгоритма поиска, оптимизированного для работы с русскоязычными текстовыми корпусами. Для достижения этой цели были поставлены следующие задачи:

1. Анализ и модификация алгоритмов стемминга для русского языка.
2. Разработка многоуровневой системы метрик для оценки релевантности документа поисковому запросу.
3. Создание механизма взвешенного ранжирования результатов.
4. Оптимизация алгоритма для работы с большими объемами данных.

МЕТОДОЛОГИЯ

Гибридный алгоритм поиска

Предлагаемый алгоритм состоит из трех основных этапов: предобработки запроса и документов, поиска кандидатов и взвешенного ранжирования.

1) Предобработка данных.

– Токенизация: Входной текст разбивается на токены с использованием регулярных выражений, учитывающих кириллические символы и дефисы.

– Фильтрация стоп-слов: Используется расширенный список стоп-слов русского языка, исключающий из обработки служебные части речи и частотные лексемы, не несущие смысловой нагрузки.

– Стемминг: Применяется модифицированный алгоритм стемминга, ориентированный на высокую скорость. В отличие от классического алгоритма Портера, данный алгоритм использует каскадное удаление окончаний, сгруппированных по частеречной принадлежности (существительные, прилагательные, глаголы), с проверкой наличия гласной в основе для избегания излишнего отсека. Для каждого слова генерируется набор возможных основ, что повышает полноту поиска.

2) Поиск кандидатов.

Поиск осуществляется по индексированному корпусу документов. Для каждого поискового запроса Q , состоящего из набора ключевых слов $\{k_1, k_2, \dots, k_n\}$, выполняется:

- Отсев стоп-слов из запроса.
- Поиск документов, в которых встречается хотя бы одно из нетривиальных ключевых слов или их основ. Для ускорения процесса используется оптимизированная проверка вхождений, сочетающая:

- Точный поиск по нижнему регистру.
- Поиск по границам слов с использованием скомпилированных регулярных выражений.
- Поиск по пересечению множеств основ запроса и основ слов в документе.

3) Многоуровневая метрика релевантности и ранжирование.

Для каждого документа-кандидата D вычисляется комплексная оценка релевантности, которая является взвешенной суммой нескольких метрик:

$$Score(D, Q) = w_{exact} * M_{exact} + w_{stem} * M_{stem} + w_{position} * M_{position} + + w_{time} * M_{time} \quad (1)$$

где:

M_{exact} – метрика точных совпадений. Рассчитывается как количество ключевых слов из запроса, имеющих точное совпадение (с учетом границ слов) в тексте документа D . Эта метрика имеет наибольший вес (w_{exact}), так как точное совпадение является сильнейшим индикатором релевантности.

M_{stem} – метрика стем-совпадений. Учитывает количество ключевых слов, для которых найдены совпадения по основам. Для вычисления используется множество основ, сгенерированных для каждого слова запроса и каждого слова в документе. Совпадение фиксируется, если основа слова из документа содержит основу из запроса, или наоборот.

$M_{position}$ – позиционная метрика. Увеличивает вес документов, в которых найденные ключевые слова встречаются в semantically важных полях, таких как заголовок (тип новости) или тезис. Эмпирически установлено, что вес для этих полей должен быть в 2-3 раза выше, чем для основного текста [2].

M_{time} – временная метрика. Учитывает актуальность документа. Для новостных статей более свежие документы получают более высокий балл по формуле, обратно пропорциональной логарифму разницы между текущей датой и датой публикации документа.

Документы сортируются по убыванию итогового показателя $Score(D, Q)$. Внутри групп с одинаковым счетом применяется дополнительная сортировка по дате (свежие документы выше).

Оптимизационные стратегии

Для обеспечения высокой производительности при работе с большими корпусами данных реализован ряд оптимизаций:

- Кэширование результатов стемминга. Поскольку процесс стемминга является вычислительно затратным, его результаты кэшируются в памяти с использованием словаря. Это позволяет избежать повторной обработки одних и тех же слов.
- Параллельная обработка. Этапы загрузки данных из файлов и первоначального поиска кандидатов распараллеливаются с использованием библиотеки Parallel.ForEach и конкурентных коллекций (ConcurrentBag).
- Пакетная обработка (Batching). При обработке больших списков документов они разбиваются на пакеты фиксированного размера, что позволяет эффективно управлять потреблением памяти.
- Использование скомпилированных регулярных выражений. Для операций поиска по границам слов используются предварительно скомпилированные объекты Regex с флагом RegexOptions.Compiled, что значительно ускоряет их выполнение.

ЭКСПЕРИМЕНТАЛЬНАЯ ЧАСТЬ

Для проверки эффективности предложенного алгоритма был проведен эксперимент на корпусе русскоязычных новостных статей объемом approximately 10000 документов.

Сравнивались три метода:

1. Базовый метод: Точный поиск по ключевым словам (case-insensitive).
2. Метод на основе стемминга: Поиск по основам слов без сложного ранжирования.

3. Предлагаемый гибридный метод: Сочетание точного поиска, стемминга и многоуровневого ранжирования.

В качестве запросов использовались 50 разнообразных фраз длиной от 1 до 4 слов. Эталонная разметка релевантности выполнялась экспертом вручную. Качество оценивалось по метрикам Precision@10 (точность среди первых 10 результатов) и Recall (полнота). Результаты представлены в Таблице 1.

Таблица 1

Сравнение эффективности алгоритмов поиска

Table 1

Comparison of the efficiency of search algorithms

Метод	Средний Precision@10	Средний Recall	Время выполнения
Базовый метод	0.65	0.58	0.8
На основе стемминга	0.72	0.85	1.5
Гибридный метод	0.82	0.88	1.9

Анализ результатов показал, что гибридный метод значительно превосходит базовый по точности на 17% и полноте на 30%. По сравнению с простым стеммингом, гибридный метод обеспечивает прирост точности на 10% за счет более качественного ранжирования, которое выдвигает на первые позиции наиболее релевантные документы. Несмотря на увеличение времени выполнения, показатель в 1.9 секунды на сложный запрос признан удовлетворительным для интерактивной работы.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЕ

Результаты эксперимента подтверждают гипотезу о том, что комбинация различных методов поиска и метрик релевантности позволяет достичь более высокого качества, чем использование любого из методов в отдельности.

- Эффективность стемминга: Использование стемминга позволило резко повысить полноту поиска, эффективно находя документы с различными грамматическими формами искомых слов, например, «экономика», «экономики», «экономике».

- Важность многоуровневого ранжирования: Метрика M_{exact} позволила отсеять документы, релевантные лишь по контексту, и поднять наверх документы с прямыми упоминаниями. Позиционная метрика $M_{position}$ корректно идентифицировала документы, где ключевые слова фигурировали в заголовке, что часто указывает на основную тему.

- Влияние временного фактора: Временная метрика M_{time} улучшила пользовательский опыт, предоставляя в первую очередь актуальные новости по запросам, чувствительным ко времени.

Основным ограничением предложенного метода является его зависимость от качества стемминга. В редких случаях агрессивное отсечение окончаний может привести к ложным срабатываниям, например, основа «кос» может быть общей для слов «космос» и «косить». Кроме того, метод не учитывает семантическую близость слов, что является направлением для будущих исследований.

ЗАКЛЮЧЕНИЕ

В рамках исследования разработан и протестирован гибридный алгоритм поиска, адаптированный для работы с русскоязычными текстовыми корпусами. Алгоритм интегрирует

морфологический анализ, многоуровневую систему оценки релевантности и ряд оптимизационных техник для обеспечения высокой производительности.

Проведенный эксперимент демонстрирует значимое превосходство предложенного подхода над базовыми методами по точности и полноте. Основные выводы работы заключаются в следующем:

1. Каскадный стемминг с генерацией множества основ для каждого слова является эффективным способом повышения полноты поиска в морфологически сложных языках.
2. Композитная метрика релевантности, объединяющая подсчет точных совпадений, стем-совпадений, позиционный и временной факторы, позволяет значительно улучшить точность ранжирования по сравнению с простыми метриками.
3. Использование кэширования и параллельных вычислений делает сложный гибридный алгоритм применимым для работы с большими объемами данных в режиме, близком к реальному времени.

Перспективы дальнейших исследований видятся в интеграции предложенного алгоритма с легковесными семантическими моделями, для учета синонимии, например, на основе word2vec или fastText, а также в применении методов активного обучения для непрерывного улучшения качества ранжирования на основе обратной связи от пользователей.

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Список литературы

1. Воронцов К.В. Лекции по алгоритмам классификации и регрессии. М.: МАКС Пресс, 2013. – 215 с.
2. Жигалин А.А. Оптимизация алгоритмов поиска в полнотекстовых базах данных // Информационные технологии и вычислительные системы. 2020. № 2. С. 45-58.
3. Лопулин С.А. Современные методы лемматизации для русского языка // Труды института системного программирования РАН. 2019. Т. 31, № 1. С. 155-170.
4. Manning C. D., Raghavan P., Schütze H. Introduction to Information Retrieval. Cambridge: Cambridge University Press, 2008. 544 p.
5. Robertson S., Zaragoza H. The Probabilistic Relevance Framework: BM25 and Beyond // Foundations and Trends in Information Retrieval. 2009. Vol. 3, № 4. P. 333-389.
6. Porter M. F. An algorithm for suffix stripping // Program. 1980. Vol. 14, № 3. P. 130-137.
7. Segalovich I. A fast morphological algorithm with unknown word guessing induced by a dictionary for a web search engine // International Conference on Machine Learning. 2003. P. 273-280.
8. Page L., Brin S., Motwani R., Winograd T. The PageRank Citation Ranking: Bringing Order to the Web. Stanford: Stanford InfoLab, 1999. 17 p.
9. Salton G., Buckley C. Term-weighting approaches in automatic text retrieval // Information Processing and Management. 1988. Vol. 24, № 5. P. 513-523.
10. Nogueira R., Cho K. Passage Re-ranking with BERT // arXiv. 2019. URL: <https://arxiv.org/pdf/1901.04085> (дата обращения: 07.08.2025).
11. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding / Devlin J., Chang M. W., Lee K., Toutanova K. // Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. 2019. Vol. 1. P. 4171-4186.
12. Mitra B., Craswell N. An Introduction to Neural Information Retrieval // Foundations and Trends® in Information Retrieval. 2018. Vol. 13, № 1. P. 1-126.
13. Agrawal R., Srikant R. Fast algorithms for mining association rules in large databases // Proceedings of the 20th International Conference on Very Large Data Bases. 1994. P. 487-499.
14. Dean J., Ghemawat S. MapReduce: Simplified data processing on large clusters // Communications of the ACM. 2008. Vol. 51, № 1. P. 107-113.
15. Buckland M., Gey F. The relationship between Recall and Precision // Journal of the American Society for Information Science. 1994. Vol. 45, № 1. P. 12-19.
16. Li X., Croft W. B. Time-based language models // Proceedings of the twelfth international conference on Information and knowledge management. 2003. P. 469-475.

References

1. Vorontsov K.V. Lectures on Classification and Regression Algorithms. Moscow: MAKSS Press, 2013. – 215 p.
2. Zhigalin A.A. Optimization of Search Algorithms in Full-Text Databases // Information Technology and Computing Systems. 2020. – No. 2. – P. 45-58.
3. Lopulin S.A. Modern Lemmatization Methods for the Russian Language // Proceedings of the Institute for System Programming of the Russian Academy of Sciences. 2019. Vol. 31, No. 1. P. 155-170.
4. Manning C. D., Raghavan P., Schütze H. Introduction to Information Retrieval. Cambridge: Cambridge University Press, 2008. 544 p.
5. Robertson S., Zaragoza H. The Probabilistic Relevance Framework: BM25 and Beyond // Foundations and Trends in Information Retrieval. 2009. Vol. 3, No. 4. P. 333-389.
6. Porter M. F. An algorithm for suffix stripping // Program. 1980. Vol. 14, No. 3. P. 130-137.
7. Segalovich I. A fast morphological algorithm with unknown word guessing induced by a dictionary for a web search engine // International Conference on Machine Learning. 2003. P. 273-280.
8. Page L., Brin S., Motwani R., Winograd T. The PageRank Citation Ranking: Bringing Order to the Web. Stanford: Stanford InfoLab, 1999. 17 p.
9. Salton G., Buckley C. Term-weighting approaches in automatic text retrieval // Information Processing and Management. 1988. Vol. 24, No. 5. P. 513-523.
10. Nogueira R., Cho K. Passage Re-ranking with BERT // arXiv. 2019. URL: <https://arxiv.org/pdf/1901.04085> (accessed: 07.08.2025).
11. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding / Devlin J., Chang M. W., Lee K., Toutanova K. // Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. 2019. Vol. 1. P. 4171-4186.
12. Mitra B., Craswell N. An Introduction to Neural Information Retrieval // Foundations and Trends® in Information Retrieval. 2018. Vol. 13, No. 1. P. 1-126.
13. Agrawal R., Srikant R. Fast algorithms for mining association rules in large databases // Proceedings of the 20th International Conference on Very Large Data Bases. 1994. P. 487-499.
14. Dean J., Ghemawat S. MapReduce: Simplified data processing on large clusters // Communications of the ACM. 2008. Vol. 51, No. 1. P. 107-113.
15. Buckland M., Gey F. The relationship between Recall and Precision // Journal of the American Society for Information Science. 1994. Vol. 45, No. 1. P. 12-19.
16. Li X., Croft W. B. Time-based language models // Proceedings of the twelfth international conference on Information and knowledge management. 2003. P. 469-475.

Беляков Ярослав Вадимович, студент кафедры информационных технологий, Институт нефтепереработки и нефтехимии ФГБОУ ВО УГНТУ в г. Салавате, Россия

Левина Татьяна Михайловна, заведующий кафедрой информационных технологий, Институт нефтепереработки и нефтехимии ФГБОУ ВО УГНТУ в г. Салавате, Россия

Belyakov Yaroslav Vadimovich, Student of the Department of Information Technology, Federal State Budgetary Educational Institution of Higher Education USPTU in Salavat, Salavat, Russia

Levina Tatyana Mikhailovna, Head of the Department of Information Technology, Federal State Budgetary Educational Institution of Higher Education USPTU in Salavat, Salavat, Russia

УДК 004.021

DOI: 10.18413/2518-1092-2026-11-3-0-5

**Чашин Ю.Г.¹
Ширяев А.А.²**

**ИССЛЕДОВАНИЕ МЕТОДА ПРОГНОЗИРОВАНИЯ ЦЕНЫ
АКЦИИ НА ОСНОВЕ ЕВКЛИДОВА РАССТОЯНИЯ**

¹) Белгородский государственный национальный исследовательский университет,
ул. Победы, 85, г. Белгород, 308015, Россия

²) Федеральное государственное бюджетное образовательное учреждение высшего образования,
«МИРЭА – Российский технологический университет»,
пр-т Вернадского, 78, стр. 4, г. Москва, 119454, Россия

e-mail: chashin@bsuedu.ru

Аннотация

Данная статья посвящена исследованию метода прогнозирования цены акции на основе евклидова расстояния. Описывается широкое использование евклидова расстояния в науке, в частности исследуется применение в геоинформационных системах, физике и машинном обучении. В качестве данных для исследований предлагается использовать изменение цены акции Сбербанка, фондового рынка МосБиржи. Отмечается, что на фондовых рынках для прогнозирования используется фундаментальный и технический анализы. Постулатом технического анализа является утверждение, что в цене и ее истории движения заложена вся информация о рынке. Делается вывод о возможности использования евклидова расстояния для одномерного прогнозирования цены акции. В качестве данных предлагается использовать дневные цены акции, на момент закрытия, за пятилетний период. Формулируется алгоритм прогнозирования, который основывается на известной концепции «история повторяется». Производится предобработка данных: удаление данных за выходные и праздничные дни; перевод в процент изменения цены; обрезка аномальных всплесков; нормализация. Находятся евклидовы расстояния 976 отрезков изменения цены акции, с исследуемым отрезком. Приводится анализ полученных результатов. Прогнозирование на основе самого близкого отрезка дало точность 63,56%, а на основе десяти самых близких – 75,5 %. Отмечаются недостатки данного подхода, такие как не равномерность распределения евклидова расстояния. И отмечаются возможности по улучшению алгоритма, например дополнительное применение алгоритма динамической трансформации временной шкалы. Делается вывод, что тем не менее, полученный результат прогнозирования, например для трейдинга, является приемлемым.

Ключевые слова: методы прогнозирования; одномерное прогнозирование; евклидово расстояние; прогнозирование цены акции

Для цитирования: Чашин Ю.Г., Ширяев А.А. Исследование метода прогнозирования цены акции на основе евклидова расстояния // Научный результат. Информационные технологии. – Т.11, №3, 2026. – С. 49-58. DOI: 10.18413/2518-1092-2026-11-3-0-5

**Chashin Y.G.¹
Shiryaev A.A.²**

**INVESTIGATION OF A STOCK PRICE FORECASTING
METHOD BASED ON EUCLIDEAN DISTANCE**

¹) Belgorod State National Research University,
85 Pobedy St., Belgorod, 308015, Russia

²) Federal State Budgetary Educational Institution of Higher Education “MIREA – Russian Technological University”,
building 4, 78 Vernadsky Ave., Moscow 119454, Russia

e-mail: chashin@bsuedu.ru

Abstract

This article examines a stock price forecasting method based on Euclidean distance. It discusses the widespread use of Euclidean distance in science, specifically exploring its applications in geographic information systems, physics, and machine learning. Fluctuations in the share price of Sberbank (traded on the Moscow Exchange) are proposed as the data source for the study. The article notes that fundamental and technical analyses are commonly used for forecasting in stock markets, highlighting the fundamental tenet of technical analysis: that the price and its movement history encapsulate all market information. The study concludes that Euclidean distance can be

used for the univariate forecasting of stock prices. Daily closing prices over a five-year period are proposed as the data source. A forecasting algorithm is formulated based on the well-known concept that "history repeats itself." Data preprocessing involves removing data from weekends and holidays, converting values to percentage price changes, trimming anomalous spikes, and normalization. Euclidean distances are calculated between the price-change segment under analysis and 976 other segments. An analysis of the obtained results is presented. Forecasting based on the single closest segment yielded an accuracy of 63.56%, whereas using the ten closest segments resulted in 75.5% accuracy. Limitations of this approach, such as the non-uniform distribution of Euclidean distances, are noted, as are potential improvements – for instance, the additional application of the Dynamic Time Warping algorithm. Nevertheless, the conclusion is drawn that the forecasting result obtained is acceptable, particularly for trading applications.

Keywords: forecasting methods; univariate forecasting; Euclidean distance; stock price forecasting

For citation: Chashin Y.G., Shiryayev A.A. Investigation of a Stock Price Forecasting Method Based on Euclidean Distance. – Т.11, №3, 2026. – Р. 49-58. DOI: 10.18413/2518-1092-2026-11-3-0-5

ВВЕДЕНИЕ

Как известно, евклидово расстояние широко используется в геоинформационных системах, физике, машинном обучении и т.д. [1].

В геоинформационных системах (ГИС) евклидово расстояние используется для векторного анализа, растрового анализа и для построения зон влияния [2]. Векторный анализ позволяет находить кратчайшие пути между объектами, например между различными достопримечательностями. Растровый анализ используется в инструментах пространственного анализа, для вычисления расстояния от центра каждой ячейки растра до ближайшего источника, например в ArcGIS Pro [3]. Зоны влияния позволяют строить буферные зоны вокруг объектов, как например в ArcGIS Online [4]. Причем имеются ограничения и особенности. Так системы координат работают корректно только в плоских прямоугольных проекциях. На малых масштабах, игнорирование геодезической кривизны Земли приводит к серьезным ошибкам. Так для глобальных карт и больших расстояний рекомендуется использовать геодезическое расстояние или манхэттенское расстояние, как например в GIS-Lab [5].

В физике евклидово расстояние – это длина прямой линии между двумя точками в трехмерном пространстве [6]:

$$L = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2 + (z_2 - z_1)^2},$$

где (x_1, y_1, z_1) – координаты первой точки, (x_2, y_2, z_2) – координаты второй точки.

Оно применяется для определения положения тела в декартовой системе координат; расчета длины вектора перемещения материальной точки; нахождения расстояния между зарядами в законе Кулона, или между массами в законе всемирного тяготения; моделирования движения классических механических систем. Также, евклидово расстояние, в физике имеет ряд ограничений: не работает в теории относительности; неприменимо на больших космических масштабах, где геометрия Вселенной искривлена из-за гравитации [7].

В машинном обучении евклидово расстояние используется, например в алгоритмах k-ближайших соседей (k-NN) [8, 9] и сетях Кохонена (SOM) [10].

В алгоритме k-NN прогнозирование на основе евклидова расстояния состоит из двух основных этапов: расчета мер различия (или метрик различия) последнего с прошлыми периодами, и вычисления самого значения прогноза.

Мера различия, для двух векторов, последнего $X_{\text{последний}}$ и i -го прошлого $X_{\text{прошлый}}(i)$, представляет собой значение:

$$\begin{aligned} X_{\text{последний}} &= [y_{t-n+1}, y_{t-n+2}, \dots, y_{t-1}, y_t], \\ X_{\text{прошлый}}(i) &= [y_i, y_{i+1}, \dots, y_{i+n-1}], \\ d(X_{\text{последний}}, X_{\text{прошлый}}(i)) &= \sqrt{\sum_{j=0}^{n-1} (y_{t-j} - y_{i+n-j})^2}, \end{aligned}$$

где t – номер прошлого, последнего периода, n – длина векторов.

Значение прогноза представляет собой среднее арифметическое k наименьших найденных мер различий:

$$\bar{y}_{t+1} = \frac{1}{k} \sum_{m=1}^k y_{i_m+n},$$

где $i_m + n$ – индексы k наименьших мер различий.

В сетях Кохонена, при кластеризации, находится нейрон-победитель по минимальному евклидовому расстоянию, между весами нейрона и вектором входных сигналов [11]. Для весовых коэффициентов каждого нейрона w_{ik} , и входного вектора s_j^p рассчитывается мера различия:

$$w_{ik} (j = 1..n, k = 1..m),$$

$$s_j^p (s_1^p, \dots, s_n^p),$$

$$d(A_p) = \sum_{j=1}^n (w_{jk} - s_j^p)^2,$$

где n – количество входов нейрона (или элементов входного сигнала), m – количество нейронов (или максимально возможное число кластеров), $p = 1..m$.

Далее, для найденного, таким образом, нейрона-победителя производится корректировка весовых коэффициентов, с целью уменьшения этой меры, для того чтобы этот нейрон лучше соответствовал входному сигналу s_j^p .

Таким образом, как видно из вышенаписанного, евклидово расстояние широко используется в различных областях науки, и его исследование важно как для понимания механизма его работы, так и для разработки новых подходов и алгоритмов.

ПРОГНОЗИРОВАНИЯ ЦЕНЫ АКЦИИ НА ОСНОВЕ ЕВКЛИДОВА РАССТОЯНИЯ

Исследуем одномерное прогнозирование, на основе евклидова расстояния, на реальных данных изменения цены акции.

В качестве данных используем изменение цены акции Сбербанка (SBER) фондового рынка МосБиржи (ИМОЕХ) [12]. Для прогнозирования на фондовых рынках используют два метода: фундаментальный и технический анализ.

Фундаментальный анализ (ФА) – это метод оценки справедливой цены акции через изучение финансовых и экономических показателей бизнеса, с целью понять сильна ли компания, и стоят ли её акции на бирже дешевле или дороже их реальной ценности [13]. ФА включает следующие уровни анализа: макроэкономический, отраслевой и анализ самой компании. Макроэкономический изучает инфляцию, валовый внутренний продукт (ВВП), ключевую ставку и ситуацию в мире. Отраслевой – оценку положения сектора экономики, где работает компания, ее конкурентов. Анализ самой компании включает анализ бизнес-модели, качества управления, различной отчетности. ФА помогает находить недооцененные компании для инвестиций, однако требует много времени и ресурсов, и не работает для краткосрочных прогнозов.

Технический анализ (ТА) – это анализ графика цены с использованием различных методов на основе прошлых котировок и объемов торгов. Основным постулатом ТА является утверждение, что в цене и ее истории движения заложена вся информация о рынке [14]. Главными принципами ТА являются: движение цены, тренды и повторяемость. Движение цены – рынок учитывает абсолютно всё, что влияет на стоимость акции. Тренды – цены двигаются направленно: вверх, вниз или боком. Повторяемость – психология людей на бирже не меняется, поэтому фигуры на графиках работают одинаково из года в год.

Таким образом классический ТА основывается, в основном, только на анализе прошлых цен, что дает возможность использовать данный подход к прогнозированию с использованием евклидова расстояния, как к одномерному прогнозированию.

РЕЗУЛЬТАТЫ ВЫЧИСЛИТЕЛЬНЫХ ЭКСПЕРИМЕНТОВ

Будем использовать данные цены акции на момент окончания дневных торгов. Главными преимуществами дневного графика в ТА является высокая точность сигналов, и отсутствие лишнего «рыночного шума», что позволяет отслеживать главные тренды и снижать уровень стресса при принятии решений. Высокая точность сигналов достигается за счет сглаживания дневных скачков цен. При этом дневной анализ удобен как для среднесрочной торговли, так и для долгосрочных инвесторов [14].

Для экспорта цен акции Сбербанк (SBER) воспользуемся официальным сайтом холдинга «Финам» [15]. Инвестиционный холдинг «Финам» – это российская финансовая группа, основная деятельность компании связана с оказанием брокерских, инвестиционных и банковских услуг, доступом к торгам на российских и мировых биржах, а также управлением активами клиентов [16]. Экспортируем данные за максимальный бесплатно-доступный период. Период основных данных начинается с 18.05.2021 и заканчивается 20.04.2026, исследуемых – с 25.03.2026 по 25.04.2026 (рисунок 1).

<pre> <DATE> <TIME> <OPEN> <HIGH> <LOW> <CLOSE> <VOL> 20210518 0000 303.5 305.24 301.01 303.94 28.344.110 20210519 0000 305.04 306.62 303.33 305.78 35.434.660 20210520 0000 304.38 304.88 295.1 297 71.633.830 20210521 0000 297.94 298.37 293 296.72 58.479.500 20210522 0000 296.82 302.98 294.9 301.23 51.370.530 20210525 0000 302.05 304.75 299.59 300.7 30.764.260 20210526 0000 301.78 307.4 301.57 306.8 37.526.860 20210527 0000 307.81 309.5 305.33 307.01 35.255.410 20210528 0000 306.39 313.9 305.72 312.72 70.727.920 20210529 0000 313.3 314 309.06 309.56 35.412.970 20210601 0000 309.3 312.6 308.82 310.79 23.651.780 20210602 0000 312.6 314.17 310.03 311.6 37.510.420 20210603 0000 311.59 314 310.61 313.98 26.981.700 20210604 0000 314.8 315.71 309.87 312.41 34.459.100 </pre>	<pre> <DATE> <TIME> <OPEN> <HIGH> <LOW> <CLOSE> <VOL> 20260325 0000 317.43 317.9 315.72 317.17 12.485.336 20260326 0000 317.36 319 316.49 317.02 8.775.397 20260327 0000 317.4 317.7 315.26 315.92 13.351.853 20260328 0000 316.3 316.69 313.5 313.88 23.615.827 20260329 0000 313.9 314.26 313.31 314.13 1.050.754 20260330 0000 314.13 314.89 314.05 314.89 856.008 20260331 0000 315.08 316.3 312.4 314.48 25.226.578 20260401 0000 315 315.63 313.43 314.22 13.038.358 20260402 0000 314.66 317.47 314.15 316.71 18.955.305 20260403 0000 316.75 317.21 315.18 316.27 9.368.358 20260404 0000 316.49 317.41 314.21 314.65 14.789.488 20260405 0000 315.03 315.44 314.64 315.12 1.017.258 20260406 0000 315.1 315.4 314.55 315.03 915.253 20260407 0000 315.04 319.75 314.6 318.98 35.503.316 </pre>
--	---

Рис. 1. Фрагменты данных в текстовом формате

а – основные данные, б – исследуемые данные

Fig. 1. Data fragments in text format

a – basic data, b – data under study

Данные представлены в текстовом формате, и содержат столбцы: дата (DATE), цена открытия (OPEN), максимального (HIGH) и минимального (LOW) значения за день, цена на момент закрытия дневных торгов (CLOSE) и объем торгов (VOL). Как видно, данные содержат строки за все календарные дни, включая выходные и праздничные, в которые торги не проводились, и цена оставалась неизменной. После удаления данных за выходные и праздничные дни, получим 998 основных данных и 22 исследуемых (рисунок 2).




Рис. 2. Графики цен

а – основных данных, б – исследуемых данных

Fig. 2. Price charts

a – reference data, b – data under study

Идея исследуемого подхода к прогнозированию схожа с одномерным прогнозированием в k-NN [8, 9], и будет основываться на известной концепции «история повторяется» [14]: разделим основные данные на фрагменты (или окна в k-NN, или срезы в NumPy, далее будем называть срезами) из 20-ти в подряд идущих цен, со сдвигом в одну цену между соседними срезами. Для всех таких срезов, кроме последнего, будет известна цена, на момент закрытия следующего рабочего дня. Так же возьмем последний срез, такого же размера, из исследуемых данных, для которого, предположительно цены на следующий день пока нет, и которую необходимо спрогнозировать. Из основных данных найдем, по минимальному Евклидову расстоянию, самый близкий срез исследуемому. В таком случае есть вероятность, что по известному изменению цены, за найденным срезом, можно спрогнозировать будущую цену за исследуемым, т.е. спрогнозировать цену на завтра.

Выше, для исследований, были выбраны срезы длиной в 20 непрерывно идущих цен. Эта длина должна обеспечивать баланс между сглаживанием шума и сохранением деталей данных. Маленькое значение делает модель слишком гибкой, при этом возникает риск переобучения. При большом значении происходит сглаживание границ классов, т.е. возникает риск недообучения. В алгоритме k-NN нет жестких правил по этому размеру, обычно он выбирается эмпирическим путем из диапазона 10-50. Так же в литературе [17] можно встретить правило квадратного корня:

$$k = \sqrt{N},$$

где k – рекомендация по длине среза, N – количество данных.

В нашем случае, при такой рекомендации, значение $k = \sqrt{998} = 31,59$. Однако была выбрана длина среза 20, для некоторого увеличения гибкости модели.

Для возможности использования данных в машинном обучении произведем предобработку основных и исследуемых данных:

1. Преобразуем данные в процент изменения цены. Это необходимо, т.к. тенденция может повторяться, но уже на других уровнях цен. В результате получим основные данные с наибольшим падением в -52,86%, и наибольшим ростом в 13,88% (рисунок 3а).

2. Обрежем аномальные всплески до диапазона от -15% до 15% (рисунок 3б).




Рис. 3. Преобразование данных

а – в процент изменения цены, б – удаление аномальных всплесков

Fig. 3. Data transformation

a – conversion to price percentage change, b – removal of anomalous spikes

3. Для более быстрого и точно обучения, произведем нормализацию данных в диапазон от -1 до 1.

В результате получим данные размером соответственно 997 и 21. Для основных данных получили диапазон от -1 до 0,925, для исследуемых от -0,039 до 0,082 (рисунок 4).




Рис. 4. Обработанные данные

а – основные данные, б – исследуемые данные

Fig. 4. Processed data

а – primary data, б – data under study

Из основных данных получим срезы, каждый по 20 непрерывных данных. После исключения последнего, для которого нет данных на следующий день, их количество составит 976.

Найдем евклидовы расстояния (меры расхождения) этих срезов с исследуемым, и их распределение в массиве. Получим диапазон – от 0,029 до 5,42 (рисунок 5а).




Рис. 5. Евклидовы расстояния

а – срезов с исследуемым, б – их распределение

Fig. 5. Euclidean distances

а – between sections and the sample under study, б – their distribution

В таблице 1 приведены данные исследуемого среза и самого похожего, с наименьшим евклидовым расстоянием, а на рисунке 6 их графики.

Таблица 1

Данные исследуемого (А) и самого похожего (В) срезов

Table 1

Data for the section under study (A) and the most similar section (B)

A(1-5)	-0.02321263	-0.02180656	-0.0086916	-0.0055163	0.05241388
B(1-5)	-0.02811642	-0.03400009	-0.04534543	-0.04926329	0.06497034
A(6-10)	-0.00927478	-0.02624089	0.08255481	-0.02327996	0.03193488
B(6-10)	0.03046055	-0.03929927	0.05045998	-0.06339673	0.00444593

A(11-15)	-0.03968379	0.00272846	-0.01767677	0.00651719	0.07894217
B(11-15)	-0.04250559	0.02585016	-0.04328859	0.03014268	0.01292508
A(16-20)	0.02586706	0.0531691	0.01127165	-0.03771602	0.0618683
B(16-20)	0.05963029	0.0386448	0.00899034	0.05350909	-0.00587813

Самым «похожим» оказался 920 срез со значением 0,029.




Рис. 6. Графики исследуемого среза (синий) и самого «похожего» (красный)
Fig. 6. Plots of the section under study (blue) and the "most similar" one (red)

Проанализируем следующие данные за срезами, представленными на рисунке 5а. Для исследуемого это 0.018123135506073012, для найденного 0.011518609073620706. Таким образом, по этим данным, можно правильно спрогнозировать рост искомой цены, т.к. оба положительны. Точность предсказания цены составила 63,56%, а погрешность 36,44%.

Рассмотрим десять самых близких срезов по евклидову расстоянию. Ими оказались срезы, по возрастанию значений: 920, 948, 946, 975, 968, 967, 960, 965, 7, 911. Следующие значения, за этими срезами представлены в таблице 2 и на графике (рисунок 7).

Таблица 2

Следующие значения после срезов, для самых близких срезов

Table 2

The values following the slices, for the nearest slices

920	0.011518609073620706
948	0.03414479924122678
946	-0.015643415836279036
975	0.02586706398476947
968	-0.023279957215214052
967	0.08255481012393766
960	-0.023212627669451463
965	0.009274775771756153
7	0.026492942453855098
911	0.025850158220796563

В этом случае можно с вероятностью 60% сказать, что искомая цена возрастет, среднее значение составит 0.013501760660550557, точность 75,5%, а погрешность 24,5%




Рис. 7. График значений за срезами самых близких десяти срезов
Fig. 7. Graph of values based on the ten nearest slices.

Таким образом, с использованием евклидова расстояния, была спрогнозирована цена акции, с точностью 75,5%, и погрешностью в 24,5%. Как видно, у такого подхода много недостатков, например не равномерное распределение евклидовых расстояний (рисунок 5б).

Считается, что трейдерам для получения стабильной прибыли достаточно 50-55% точности прогноза [18], т.е. можно считать полученный результат, в некоторой степени, приемлемым.

Отметим, что существует множество методов улучшения такого подхода к прогнозированию. Например, повысить точность можно за счет применения алгоритма динамической трансформации временной шкалы (Dynamic Time Warping), который позволяет измерять схожесть двух временных рядов, которые могут различаться по скорости (времени, длине) [1, 19].

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Список литературы

1. Нильсен Э. Практический анализ временных рядов. Прогнозирование со статистикой и машинное обучение / перевод с английского под редакцией А.А. Алябьева. – Москва: Диалектика / Вильямс, 2021. – 544 с.
2. Лурье И.К. Геоинформационное картографирование. Методы геоинформатики и цифровой картографии: учебник / 4-е изд., испр. и доп. – Москва: Издательство Московского университета, 2021. – 424 с.
3. Майкл К. Введение в ГИС на базе ArcGIS Pro: руководство пользователя / перевод с английского. – Москва: ДМК Пресс, 2023. – 312 с.
4. Pimpler E. Programming ArcGIS Web Development: Create and share dynamic Web GIS apps using ArcGIS API for JavaScript / Birmingham: Packt Publishing, 2017. – 342 p.
5. Суворов И.В. Расчет евклидова расстояния и построение зон близости в открытых ГИС // GIS-Lab. – 2014. URL: gis-lab.info (дата обращения: 13.05.2026).
6. Сивухин Д.В. Общий курс физики: учебное пособие для вузов: в 5 томах. Том 1. Механика / 6-е изд., стереотип. – Москва: Физматлит, 2019. – 560 с.
7. Иродов И.Е. Электромагнетизм. Основные законы: учебное пособие для вузов / 11-е изд. – Москва: Лаборатория знаний, 2022. – 312 с.
8. Бхаргава А. Грокаем алгоритмы. Иллюстрированное пособие для программистов и любопытствующих / перевод с английского Е.В. Гупало. – Санкт-Петербург: Питер, 2017. – 288 с.
9. Флах П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных / перевод с английского А.А. Слинкина. – 2-е изд. – Москва: ДМК Пресс, 2021. – 400 с.
10. Кохонен Т. Самоорганизующиеся карты / перевод с английского под редакцией И.В. Котенко. – Москва: Лаборатория знаний, 2017. – 655 с.
11. Хайкин С. Нейронные сети: полный курс / перевод с английского под редакцией Н.Н. Куссуль. – 2-е изд., испр. – Москва: Вильямс, 2019. – 1104 с.

12. Московская Биржа: котировки, акции, облигации, валютный рынок: официальный сайт. – Москва, 2011-2026. URL: <https://www.moex.com/>. (дата обращения: 13.05.2026).
13. Грэм Б., Додд Д. Анализ ценных бумаг / перевод с английского. – Москва: Вильямс, 2016. – 880 с.
14. Швагер Д.Д. Технический анализ. Полный курс / перевод с английского П.А. Самсонов и др. – Москва: Альпина Паблишер, 2017. – 808 с.
15. Экспорт данных Сбербанк // ФИНАМ. – 2007-2026. URL: <https://www.finam.ru/quote/moex/sber/export/>. (дата обращения: 13.05.2026).
16. ФИНАМ: инвестиционная компания. – Москва, 2007-2026. URL: <https://www.finam.ru/>. (дата обращения: 13.05.2026).
17. Хасты Т., Тибширани Р., Фридман Д. Элементы статистического обучения: интеллектуальный анализ данных, логический вывод и прогнозирование / перевод с английского. – Москва: Мир, 2020. – 768 с.
18. Винс Р. Математика управления капиталом: Методы анализа риска для трейдеров и портфельных менеджеров / перевод с английского. – Москва: Альпина Паблишер, 2021. – 400 с.
19. Müller M. Information Retrieval for Music and Motion. Berlin; Heidelberg: Springer, 2007. – 318 p.

References

1. Nilsen E. Practical Time Series Analysis: Prediction with Statistics and Machine Learning / ed. by A.A. Alyabiev. Moscow: Dialektika / Vilyams, 2021. 544 p.
2. Lurie I.K. Geoinformation Mapping. Methods of Geoinformatics and Digital Cartography: Textbook / 4th ed., rev. and augm. Moscow: Izdatelstvo Moskovskogo universiteta, 2021. 424 p.
3. Michael K. Introduction to GIS Based on ArcGIS Pro: User Guide / transl. from English. Moscow: DMK Press, 2023. 312 p.
4. Pimpler E. Programming ArcGIS Web Development: Create and share dynamic Web GIS apps using ArcGIS API for JavaScript / Birmingham: Packt Publishing, 2017. 342 p.
5. Suvorov I.V. Calculation of Euclidean Distance and Construction of Proximity Zones in Open GIS // GIS-Lab: [website]. 2014. URL: gis-lab.info (accessed: 13.05.2026).
6. Sivukhin D.V. General Course of Physics: Textbook for Universities: in 5 Volumes. Vol. 1. Mechanics / 6th ed., stereotype. Moscow: Fizmatlit, 2019. 560 p.
7. Irodov I.E. Electromagnetism. Basic Laws: Textbook for Universities / 11th ed. Moscow: Laboratoriya znaniy, 2022. 312 p.
8. Bhargava A. Grokking Algorithms. An Illustrated Guide for Programmers and the Curious / transl. from English by E. V. Gupalo. Saint Petersburg: Piter, 2017. 288 p.
9. Flach P. Machine Learning. The Art and Science of Algorithms that Make Sense of Data / transl. from English by A.A. Slinkin. 2nd ed. Moscow: DMK Press, 2021. 400 p.
10. Kohonen T. Self-Organizing Maps / ed. by I. V. Kotenko. Moscow: Laboratoriya znaniy, 2017. 655 p.
11. Haykin S. Neural Networks: A Comprehensive Foundation / ed. by N.N. Kussul. 2nd ed., rev. Moscow: Vilyams, 2019. 1104 p.
12. Moscow Exchange: quotes, stocks, bonds, currency market. Moscow, 2011-2026. URL: <https://www.moex.com/>. (accessed: 13.05.2026).
13. Graham B., Dodd D. Security Analysis / transl. from English. Moscow: Vilyams, 2016. 880 p.
14. Schwager J.D. Technical Analysis. Complete Course / transl. from English by P.A. Samsonov et al. Moscow: Alpina Publisher, 2017. 808 p.
15. Export of Sberbank data // FINAM. 2007-2026. URL: <https://www.finam.ru/quote/moex/sber/export/>. (accessed: 13.05.2026).
16. FINAM: investment company. Moscow, 2007-2026. URL: <https://www.finam.ru/>. (accessed: 13.05.2026).
17. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction / transl. from English. Moscow: Mir, 2020. 768 p.
18. Vince R. The Mathematics of Money Management: Risk Analysis Techniques for Traders and Portfolio Managers / transl. from English. Moscow: Alpina Publisher, 2021. 400 p.
19. Müller M. Information Retrieval for Music and Motion. Berlin; Heidelberg: Springer, 2007. 318 p.

Чашин Юрий Геннадиевич, кандидат технических наук, доцент, доцент кафедры математического и программного обеспечения информационных систем, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Ширяев Алексей Александрович, кандидат технических наук, Директор, Институт радиоэлектроники и информатики, Федеральное государственное бюджетное образовательное учреждение высшего образования «МИРЭА – Российский технологический университет», г. Москва, Россия

Chashin Yuri Gennadievich, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Mathematical and Software Support for Information Systems, Belgorod State National Research University, Belgorod, Russia

Shiryaev Alexey Alexandrovich, Candidate of Technical Sciences, Director, Institute of Radio Electronics and Informatics, Federal State Budgetary Educational Institution of Higher Education “MIREA – Russian Technological University”, Moscow, Russia

УДК 004.89

DOI: 10.18413/2518-1092-2026-11-3-0-6

**Низамли Я.
Филатов А.Ю.
Фадел В.
Шичкина Ю.А.**

**ОЦЕНКА ВАЛИДНОСТИ ОБЩЕДОСТУПНЫХ НАБОРОВ
ДАННЫХ МРТ ДЛЯ НЕЙРООНКОЛОГИЧЕСКОГО
ОБНАРУЖЕНИЯ АНОМАЛИЙ: ВЫЯВЛЕНИЕ КРИТИЧЕСКИХ
ПРОБЛЕМ КАЧЕСТВА ДАННЫХ**

Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина),
ул. Профессора Попова, д.5, к.3, г. Санкт-Петербург, 197022, Россия

e-mail: yanizamli@stud.etu.ru, aifilatov@etu.ru, vfadel@stud.etu.ru, yashichkina@etu.ru

Аннотация

Надежность моделей машинного обучения в таких ответственных приложениях, как диагностика опухолей головного мозга, критически зависит от качества обучающих данных. В данной статье представлен анализ четырех широко используемых наборов данных МРТ головного мозга: Chakrabarty, Br35H, Bhuvaji и Figshare. Мы оцениваем эти наборы данных по ключевым критериям достоверности, включая происхождение данных, целостность меток, независимость выборки, репрезентативность и соблюдение этических норм. Наши результаты показывают, что только набор данных Figshare удовлетворяет большинству основных стандартов качества. Остальные три демонстрируют серьезные недостатки, такие как неправильная маркировка, скрытое дублирование и этические нарушения, которые ставят под угрозу их научную достоверность. Контролируемые эксперименты дополнительно демонстрируют, что эти проблемы качества данных могут искусственно завышать производительность модели на значительные величины, подрывая надежность эталонных данных. Мы приходим к выводу, что такие наборы данных, как Chakrabarty, Br35H и Bhuvaji, требуют существенной структурной доработки, прежде чем их можно будет ответственно использовать в клинической разработке ИИ.

Ключевые слова: качество данных; ограниченные данные; аномалии МРТ, надежность модели; этический ИИ

Для цитирования: Низамли Я., Филатов А.Ю., Фадел В., Шичкина Ю.А. Оценка валидности общедоступных наборов данных МРТ для нейроонкологического обнаружения аномалий: выявление критических проблем качества данных // Научный результат. Информационные технологии. – Т.11, №3, 2026. – С. 59-74. DOI: 10.18413/2518-1092-2026-11-3-0-6

**Nizamli Ya.
Filatov A.Yu.
Fadel W.
Shichkina Yu.A.**

**VALIDITY ASSESSMENT OF PUBLIC MRI DATASETS FOR
NEURO-ONCOLOGICAL ABNORMALITY DETECTION:
UNCOVERING CRITICAL DATA QUALITY ISSUES**

Saint Petersburg Electrotechnical University “LETI”,
5 Professor Popov St., Building 3, Saint Petersburg, 197022, Russia

e-mail: yanizamli@stud.etu.ru, aifilatov@etu.ru, vfadel@stud.etu.ru, yashichkina@etu.ru

Abstract

The reliability of machine learning models in high-stakes applications like brain tumor diagnosis depends critically on the quality of training data. This paper presents a forensic audit of four widely used brain MRI datasets: Chakrabarty, Br35H, Bhuvaji, and Figshare. We evaluate these datasets against key validity criteria, including data provenance, label integrity, sample independence, representativeness, and ethical compliance. Our findings reveal that only the Figshare dataset satisfies most essential quality standards. The remaining three exhibit profound flaws – such as label inaccuracies, undisclosed duplication, and ethical lapses – that compromise their scientific

validity. Controlled experiments further demonstrate that these data-quality issues can artificially inflate model performance by significant margins, undermining benchmark reliability. We conclude that datasets like Chakrabarty, Br35H, and Bhuvaji require substantial structural revision before they can be responsibly used in clinical AI development.

Keywords: data quality; constrained data; MRI abnormalities; model reliability; ethical AI

For citation: Nizamli Ya., Filatov A.Yu., Fadel W., Shichkina Yu.A. Validity Assessment of Public MRI Datasets for Neuro-Oncological Abnormality Detection: Uncovering Critical Data Quality Issues // Research result. Information technologies. – Т.11, №3, 2026. – P. 59-74. DOI: 10.18413/2518-1092-2026-11-3-0-6

ВЕДЕНИЕ

Ранняя и точная диагностика опухолей головного мозга по данным магнитно-резонансной томографии (МРТ) критически важна для определения тактики лечения [1-3]. Однако ручной анализ снимков радиологом является длительным и ресурсоемким процессом, что обуславливает активное развитие автоматизированных систем диагностики на основе методов машинного и глубокого обучения [4]. Независимо от архитектуры (использующей классические признаки или сверточные нейронные сети), ключевой целью остается достижение высокой точности на выбранном наборе данных [5-9].

Надежность таких моделей фундаментально зависит от качества данных, используемых для их обучения и оценки. Хотя важность этого фактора в целом признается, в области медицинской визуализации сохраняется существенный пробел. Современные методы предварительной обработки преимущественно фокусируются на корректировках на уровне пикселей (контраст, нормализация, шумоподавление), в значительной степени игнорируя оценку метаданных и структурную целостность данных. Критические аспекты – происхождение данных, точность разметки, независимость выборок – часто упускаются из виду. Это привело к фундаментальному пробелу: широко используемые эталонные наборы данных МРТ применяются как надежная основа без систематической проверки их достоверности, что потенциально подрывает доверие к моделям, обученным на них.

Для решения этой проблемы в данной работе:

- Проведен систематический аудит четырех популярных общедоступных наборов данных МРТ головного мозга (Chakrabarty, Br35H, Bhuvaji, Figshare), выявивший критические недостатки, подрывающие их научную достоверность.
- Представлен количественный анализ влияния проблем качества данных на производительность моделей. Контролируемые эксперименты дают эмпирические доказательства того, что такие проблемы (особенно загрязнение почти дубликатами) могут искусственно завышать метрики.
- Сформулированы практические рекомендации, основанные на доказательствах, для помощи исследователям в разработке более надежных и клинически применимых моделей ИИ.

Перенос акцент с оптимизации алгоритмов на достоверность данных, это исследование способствует установлению более строгой методологии в области, повышая прозрачность и доверие к нейроонкологическим исследованиям с использованием ИИ.

1 КРИТЕРИИ ДОСТОВЕРНОСТИ НАБОРА ДАННЫХ

Ниже описаны пять критериев, которые мы использовали для оценки достоверности наборов данных МРТ.

1.1 Ненадежный источник данных

Источник данных во многом определяет, можно ли доверять результатам. Данные делятся на первичные (собранные по контролируемым протоколам с этическим одобрением) и вторичные (полученные из открытых источников без формального плана) [10]. Первичные данные дают

надежную основу для разработки моделей. Вторичные, как правило, не имеют документированного происхождения, контроля качества и этического сопровождения. Это неизбежно вносит шум и смещения. Для медицинской диагностики проверка происхождения данных критически важна [11].

1.2 Несоответствие меток

Несоответствие меток означает, что содержимое образца не соответствует присвоенной ему метке. Мы выделяем три типа таких ошибок:

- Неправильная маркировка – опухоль помечена как здоровая ткань или наоборот.
- Несоответствие модальности – в набор МРТ попадают изображения других типов (компьютерная томография, рентген).
- Несоответствие анатомической области – скан брюшной полости представлен как МРТ головного мозга.

Все эти случаи ухудшают работу модели. Она смещает границы принятия решений и начинает полагаться на нерелевантные признаки [11, 12]. Для исправления таких ошибок нужна экспертная проверка и клинические данные, но в открытых наборах они редко доступны.

1.3 Нарушение независимости выборки

Независимость выборки означает, что каждый образец уникален. Нарушения возникают по двум причинам [13, 14].

- Первое – скрытое дублирование. Это точные копии одних и тех же изображений.
- Второе – скрытое аугментирование (почти дубликаты). Это искусственно созданные варианты: масштабированные, обрезанные или с измененной яркостью. Они выдаются за отдельные образцы.

В обоих случаях модель не учится обобщать, а запоминает данные. Точность на тесте становится завышенной. Особенно опасно, когда почти дубликаты попадают одновременно в обучающую и тестовую выборки – возникает просачивание данных между выборками [14, 15]. Решение состоит в том, чтобы выявлять и удалять дубликаты и почти дубликаты до разделения набора.

1.4 Смещение репрезентативности

Смещение возникает, когда какие-то группы пациентов или технические параметры представлены непропорционально. Выделяют два основных типа [11].

- Институциональное смещение. Данные собраны в одном учреждении или в группе похожих учреждений. Модель выучивает локальные особенности, а не общие патологические признаки.
- Техническое смещение. Данные получены на конкретном оборудовании, с определенным программным обеспечением и по фиксированным протоколам.

Оба типа смещений ограничивают обобщаемость модели. Она может цепляться за артефакты конкретного сканера, а не за реальную патологию [12, 16]. Смягчить проблему можно только сбором данных из разных учреждений и по разным протоколам.

1.5 Этические недостатки

Этические проблемы в медицинских данных связаны с отсутствием должного надзора, согласия пациентов и защиты конфиденциальности. Типичные случаи [11, 17]:

- Отсутствие документально подтвержденного этического одобрения или информированного согласия;
- Недостаточная деидентификация – остаточная личная информация позволяет восстановить личность пациента.

Такие недостатки создают юридические и репутационные риски, а также риски нарушения конфиденциальности, подрывая доверие не только к данным, но и к моделям, которые на них обучаются. Прозрачная документация этических протоколов и методов деидентификации необходима для ответственного использования ИИ в медицине.

2 МЕТОДЫ И РЕЗУЛЬТАТЫ ПРОВЕРКИ НАБОРА ДАННЫХ

2.1 Введение и обзор набора данных

В этом разделе представлена методология и результаты аудита четырёх общедоступных наборов данных МРТ головного мозга: Chakrabarty [18], Br35N [19], Bhuvaji [20] и Figshare [21]. Эти наборы данных были выбраны в связи с их широким использованием в научной литературе в качестве эталонных. Наш анализ оценивает каждый из них по критериям достоверности, установленным в Разделе 1.

Для контекста кратко опишем каждый набор данных:

- **Набор данных Chakrabarty:** широко используемый эталон, содержащий 253 МРТ головного мозга, разделённых на 155 изображений с пометкой «да» и 98 с пометкой «нет». Неоднозначная маркировка привела к противоречивым интерпретациям в разных исследованиях: одни трактуют её как «опухоль против здоровой ткани», другие как «злокачественная против доброкачественной», а третьи просто как «опухоль против не-опухоли» [22-25].

- **Набор данных Br35N:** популярный эталон бинарной классификации, включающий 3060 сканирований: 1500 с пометкой «Да» (опухолевые), 1500 с пометкой «Нет» (неопухолевые) и 60 без пометки. Его относительно большой размер и сбалансированность сделали его привлекательным для разработки новых подходов [26-28].

- **Набор данных Bhuvaji:** включает 3264 изображения МРТ, распределённых по четырём категориям: 926 глиом, 937 менингиом, 901 опухоль гипофиза и 500 изображений «без опухоли» [29-31].

- **Набор данных Figshare:** содержит 3064 изображения трёх типов опухолей: 708 менингиом, 1426 глиом и 930 опухолей гипофиза. Отсутствие класса «без опухолей» делает его предназначенным для многоклассовой классификации [32, 33].

В последующих подразделах проводится оценка по каждому критерию для выявления основных различий в качестве. Кроме того, в разделе 2.7 представлен контролируемый эксперимент для количественной оценки того, как выявленные проблемы качества данных приводят к искусственно завышенным показателям производительности модели.

2.2 Анализ происхождения и источника данных

Происхождение и источник набора данных являются одними из наиболее надежных показателей его достоверности. Методы сбора, контекст и первоисточники напрямую определяют надежность набора данных и его пригодность для разработки автоматизированных клинических инструментов.

Набор данных Chakrabarty: В описании этого набора данных на Kaggle кратко упоминается Google Images как источник, без предоставления проверяемых деталей. Это указывает на вторичный набор данных, собранный из интернета, без документации об участвующих учреждениях, протоколах сбора или этическом надзоре.

Набор данных Br35N: Аналогично размещенный на Kaggle, набор данных Br35N страдает от того же фундаментального недостатка. В его описании нет информации об первоисточниках сканирования мозга, а цепочка происхождения полностью не задокументирована.

Набор данных Bhuvaji: Этот набор данных следует той же проблемной схеме. Его создатели отмечают на Kaggle, что часть данных получена из класса нераковых опухолей набора данных Chakrabarty, в то время как оставшиеся выборки взяты из репозитория GitHub с неработающей ссылкой.

Набор данных Figshare: В отличие от них, набор данных Figshare представляет собой первичный набор данных с четким, документированным происхождением. Он был систематически составлен в рамках рецензируемого академического исследования, при этом изображения были получены непосредственно из партнерских больниц.

В совокупности эти результаты указывают на то, что модели, обученные на наборах данных Chakrabarty, Br35H и Bhuvaji, построены на фундаменте сомнительной целостности. В отличие от них, набор данных Figshare представляет собой структурно обоснованную и научно достоверную отправную точку.

2.3 Оценка целостности меток

Целостность меток является краеугольным камнем контролируемого обучения. Мы оценили это посредством систематического визуального осмотра и проверки с использованием Google Lens, который отслеживал подозрительные изображения до их первоисточников – в первую очередь, архива медицинских изображений Radiopaedia. В ходе этого процесса были оценены три типа несоответствия меток: патологическая неправильная маркировка, несоответствие модальности и несоответствие анатомической области в четырех наборах данных.

2.3.1 Патологическая неправильная маркировка

Наш анализ показал, что категория «нет опухоли» в нескольких наборах данных функционирует как универсальное обозначение для различных патологий, включая опухоли, инсульты и демиелинизирующие заболевания. Это заставляет модели неправильно приравнивать различные заболевания, что коренным образом искажает их диагностическую логику.

В наборе данных Chakrabarty категория «нет» является примером этой диагностической путаницы. В него входят опухоли, такие как веретенчатая опухоль и первичная лимфома ЦНС, наряду с неонкологическими состояниями, такими как рассеянный склероз и синдром CADASIL.

Аналогичная картина наблюдается в наборах данных Br35H и Bhuvaji. Категория «нет» в Br35H включает коллоидную кисту (доброкачественную опухоль головного мозга), церебральный токсоплазмоз и васкулит ЦНС. Аналогично, класс «нет опухолей» в Bhuvaji включает плеоморфную ксантоастроцитому и серьезные неврологические состояния, такие как прогрессирующая мультифокальная лейкоэнцефалопатия.

Более того, мы выявили общие файлы изображений с неправильными метками в разных наборах данных. Например, одно и то же изображение первичной лимфомы ЦНС помечено как «нет» как в Chakrabarty, так и в Br35H. Аналогично, изображение, подтвержденное как демонстрирующее васкулит ЦНС, появляется в категории «нет опухолей» как в Br35H, так и в Bhuvaji. На рисунке 1a показаны отдельные случаи патологической ошибочной маркировки с указанием их правильной классификации; полная таблица подтвержденных случаев с проверенными источниками доступна в нашем репозитории кода.

В отличие от этого, в наборе данных Figshare патологической ошибочной маркировки не наблюдалось, поскольку его метки взяты из клинических радиологических отчетов.

2.3.2 Системное несоответствие модальности и анатомии

Мы выявили более фундаментальные нарушения, при которых изображения вообще не представляли собой МРТ головного мозга.

Набор данных Chakrabarty содержит критическое несоответствие анатомической области: КТ-скан гепатоцеллюлярной карциномы брюшной полости ошибочно представлен как МРТ опухоли головного мозга. Этот же образец появляется в наборе данных Br35H. Набор данных Bhuvaji демонстрирует сопоставимые недостатки, включая рак носоглотки, ошибочно обозначенный как «отсутствие опухоли».

Проблемы несоответствия модальности особенно выражены в наборах данных Br35H и Bhuvaji, которые содержат КТ-сканы таких состояний, как нейроцистицеркоз, субарахноидальное кровоизлияние и метастазы меланомы, все они ошибочно представлены как МРТ. Примеры таких несоответствий показаны на рисунке 1b.

Модели, обученные на таких загрязненных данных, рискуют выявить ложные корреляции, основанные на модальности визуализации, а не на подлинных патологических особенностях. В отличие от этого, в наборе данных Figshare подобных расхождений не обнаружено.

В совокупности эти результаты показывают, что наборы данных Chakrabarty, Br35H и Bhuvaji подвержены глубоким и систематическим несоответствиям в метках. Это не единичные ошибки, а признаки катастрофических сбоев в курировании. Наличие таких фундаментальных недостатков указывает на отсутствие базового экспертного контроля. Серьезность подтвержденных ошибок делает эти наборы данных непригодными для обучения клинических моделей. В отличие от них, набор данных Figshare выделяется как надежный эталон.




Рис. 1. Примеры некорректной разметки, выявленной в исследованных наборах данных МРТ головного мозга: (а) патологическая ошибочная разметка, (б) несоответствие модальности и анатомической области

Fig. 1. Examples of label incongruity identified in the studied brain MRI datasets: (a) pathological mislabeling, (b) modality and anatomical domain mismatch

2.4 Выявление нарушений независимости выборок

В машинном обучении предполагается, что все выборки независимы. Это позволяет оценивать обобщающую способность модели, а не её способность запоминать данные. Мы выделяем два типа нарушений: точные дубликаты (идентичные копии) и почти дубликаты (искусственно сгенерированные варианты с помощью отражения, масштабирования или изменения интенсивности).

Для обнаружения таких нарушений мы реализовали алгоритм, который находит точные дубликаты попиксельным сравнением, а почти дубликаты – сравнением дескрипторов ORB с заданным порогом сходства. Псевдокод алгоритма доступен в репозитории.

Результаты представлены в таблице 1. Серьезные нарушения независимости выявлены в трех из четырех наборов данных.

Таблица 1

Дубликаты и почти дубликаты в исследованных наборах данных

Table 1

Duplicates and near-duplicates in the studied datasets

Набор данных	Класс	Всего изображений	Точные дубликаты	Почти дубликаты
Chakrabarty	Нет	98	11 (11.22%)	5 (5.10%)
	Да	155	14 (9.03%)	17 (10.97%)
Br35H	Нет	1500	1 (0.07%)	1095 (73%)
	Да	1500	0 (0%)	937 (62.5%)
Bhuvaji	Без опухоли	500	173 (34.6%)	77 (15.4%)
	Менингиома	937	114 (12.2%)	61 (6.51%)
	Глиома	926	40 (4.3%)	6 (0.6%)
	Гипофиз	901	67 (7.4%)	21 (2.33%)
Figshare	Менингиома	708	0 (0%)	4 (0.6%)
	Глиома	1426	0 (0%)	0 (0%)
	Гипофиз	930	0 (0%)	0 (0%)

В наборе Chakrabarty примерно каждое десятое изображение является точной копией. Присутствие почти идентичных копий указывает на дополнительное искусственное увеличение объема данных.

Набор данных Br35H представляет собой более серьезную проблему. Набор данных преимущественно состоит из почти идентичных дубликатов. В частности, 73% изображений без опухолей и 62.5% изображений с опухолями представляют собой версии с отрегулированной интенсивностью, перевернутые или масштабированные версии гораздо меньшего набора уникальных оригиналов. Следовательно, фактический размер уникального набора данных составляет лишь часть от заявленного. Поскольку это искусственное увеличение объема было применено до разделения, почти идентичные дубликаты неизбежно появляются как в обучающем, так и в тестовом наборах.

Набор данных Bhuvaji серьезно скомпрометирован, особенно в классе «Без опухолей», где 34.6% изображений являются точными дубликатами. В сочетании с почти идентичными изображениями, половина этого класса не содержит уникальных вариантов. Значительное количество дубликатов также присутствует в разных классах опухолей.

Для сравнения, набор данных Figshare демонстрирует в основном чистые результаты. В пределах одного класса было обнаружено всего четыре почти идентичных изображения (0.6%).

Визуальные примеры этих нарушений представлены на рисунке 2. Широкое распространение таких случаев, особенно в Br35H и Bhuvaji, означает, что модели, обученные на этих данных, рискуют изучать специфические для изображений артефакты и преобразования, а не обобщаемые патологические признаки.




Рис. 2. Репрезентативные случаи нарушений независимости выборок, выявленных в наборах данных: (а) пары точных дубликатов, (б) пары почти дубликатов
Fig. 2. Representative instances of sample independence violations detected across datasets: (a) Exact duplicate pairs, (b) Near-duplicate pairs

2.5 Исследование репрезентативности и смещений

Насколько хорошо модель будет обобщать, зависит от репрезентативности набора данных. Когда какие-то группы пациентов или типы оборудования представлены слишком сильно или слишком слабо, это приводит к смещениям. Мы рассматриваем два типа: институциональное (демографическое) и техническое.

2.5.1 Институциональное и демографическое смещение

То, какие демографические и институциональные группы представлены в наборе, определяется его происхождением. Chakrabarty, Br35H и Bhuvaji получены из вторичных источников, и их происхождение не подтверждено. С помощью анализа меток мы проследили отдельные образцы до исходных репозиториях, однако полный демографический и институциональный состав этих наборов восстановить не удалось. Следовательно, измерить смещения в таких данных не представляется возможным.

Для Figshare источники документированы – это две больницы в Китае. Вариативность ограничена, но происхождение данных прозрачно, и смещения можно измерить. Это выгодно отличается от полной неопределенности в остальных трёх наборах.

2.5.2 Техническое смещение при получении данных

Техническое смещение обусловлено вариативностью оборудования и протоколов визуализации. Мы оценили его по двум параметрам:

- Анатомическая плоскость (ориентация срезов сканирования).
- Последовательность визуализации (конкретный протокол МРТ).

Примеры представлены на рисунке 3. Наборы Chakrabarty и Br35H состоят преимущественно из изображений в аксиальной плоскости, что создает выраженное смещение. Наборы Bhuvaji и Figshare, напротив, включают изображения в различных анатомических плоскостях.

В отношении последовательностей визуализации наблюдается иная картина. Наборы Chakrabarty, Br35H и Bhuvaji содержат изображения, полученные по нескольким протоколам МРТ. Набор Figshare ограничен последовательностями T1-CE, что обеспечивает согласованность, но также формирует отдельное техническое смещение.

Таким образом, каждый набор данных имеет свои компромиссы. Figshare демонстрирует смещения, которые являются измеримыми и контролируруемыми. Наборы Chakrabarty и Br35H страдают как от существенных технических ограничений, так и от неизмеримого демографического смещения. Набор Bhuvaji, несмотря на техническое разнообразие, имеет ограниченную ценность для построения обобщаемых клинических моделей из-за неизвестного демографического состава.




Рис. 3. Сравнение анатомических плоскостей и последовательностей МРТ: (a) Chakrabarty, (b) Br35H, (c) Bhuvaji, (d) Figshare

Fig. 3. Anatomical planes and MRI sequences across datasets: (a) Chakrabarty, (b) Br35H, (c) Bhuvaji, (d) Figshare

2.6 Проверка соблюдения этических норм

Этические требования к медицинским данным включают прозрачный надзор и строгую деидентификацию пациентов. Без этих гарантий возникают юридические риски, а доверие к данным и моделям подрывается.

Наборы данных Chakrabarty, Br35H и Bhuvaji в этом отношении вызывают серьезные вопросы. В их описании нет информации об одобрении этического комитета или информированном согласии пациентов. Мы также обнаружили реальные угрозы конфиденциальности. С помощью обратного поиска изображений отдельные образцы удалось связать с оригинальными клиническими отчетами. Например, файл image(41)_T.jpg из набора Bhuvaji был найден в онлайн-хранилище вместе с диагнозом, личными данными пациентки (55 лет), а также именем и местом работы врача-радиолога. Это означает, что в этих наборах данных присутствует потенциально идентифицируемая информация о пациентах.

В отличие от них, набор данных Figshare создан в рамках документированного этического процесса. Его сбор был одобрен этическими комитетами больниц, и авторы подтверждают анонимизацию записей пациентов до анализа. Следовательно, этический статус этих наборов данных явно разделен. Набор данных Figshare работает в рамках документированной подотчетности, в то время как наборы данных Chakrabarty, Br35H и Bhuvaji вызывают серьезные фундаментальные опасения.

2.7 Количественная оценка влияния качества данных

2.7.1 Экспериментальный дизайн и обработка данных

Наш анализ выявил систематические проблемы с качеством данных. Чтобы оценить их влияние на производительность моделей и достоверность результатов бенчмаркинга, мы провели контролируемый эксперимент на наборе Br35H. Этот набор данных был выбран как репрезентативный пример по трем причинам: наиболее высокий уровень загрязнения почти дубликатами, бинарная структура классификации (опухоль против здоровой ткани) и достаточный объем (3000 изображений) для сохранения статистической мощности после фильтрации.

Для количественной оценки мы использовали одну легковесную сверточную нейронную сеть в трех экспериментальных условиях. Архитектура сети показана в таблице 2. Простая архитектура выбрана намеренно: избыточная параметризация не должна маскировать влияние качества данных. Во всех экспериментах параметры были фиксированы: 15 эпох, скорость обучения 0.001, размер батча 32. Данные делились на обучающую и тестовую выборки в соотношении 80/20 с фиксированным seed для воспроизводимости.

Три экспериментальных условия:

Первое – исходный набор Br35H (3000 изображений) с известными дефектами качества. Он использовался как базовый «загрязненный» набор.

Второе – очищенная версия Br35H. Применена двухэтапная процедура: сначала автоматическое удаление почти дубликатов с использованием ORB (порог сходства 0.85), затем ручная проверка с удалением неправильно размеченных изображений и пропущенных дубликатов. В результате получено 840 изображений (350 нормальных, 490 патологических).

Третье – синтетический набор, созданный специально для контроля размера. Из очищенного набора взято 235 уникальных изображений (28% от итогового размера). К ним применены небольшие реалистичные преобразования: изменение яркости (0.98-1.02), контраста (–10 до +10) и масштаба (0.97-1.03). Так сгенерировано 605 синтетических почти дубликатов. Итоговый набор содержит 72% почти дубликатов – это доля загрязнения, удаленного при очистке.

Таблица 2

Архитектура сверточной нейронной сети

Table 2

Convolutional neural network architecture

Тип слоя	Параметры	Функция активации	Выходная размерность
Входной	–	–	(224, 224, 3)
Conv2D	16 фильтров, 3×3	ReLU	(224, 224, 16)
MaxPooling2D	Пулинг 2×2	–	(112, 112, 16)
Conv2D	16 фильтров, 3×3	ReLU	(112, 112, 16)
MaxPooling2D	Пулинг 2×2	–	(56, 56, 16)
Conv2D	16 фильтров, 3×3	ReLU	(56, 56, 16)
MaxPooling2D	Пулинг 2×2	–	(28, 28, 16)
Flatten	–	–	(12544)
Dropout	Вероятность: 0.3	–	(12544)
Dense	25 нейронов	ReLU	(25)
Dropout	Вероятность: 0.4	–	(25)
Dense	10 нейронов	ReLU	(10)
Dense	2 нейрона	Softmax	(2)

2.7.2 Результаты и анализ

Таблица 3 показывает четкую картину. Точность модели на исходном Br35H составила 99.00%, на очищенном – 90.48%, на синтетическом наборе – 98.81%. Динамика обучения (рисунок 4 а-с) и матрицы ошибок (рисунок 5 а-с) дополняют эту картину.

Кривые обучения для исходного и синтетического наборов практически совпадают: быстрая и гладкая сходимость к почти идеальной точности. На очищенном наборе кривая обучения заметно более шумная, а итоговая точность существенно ниже. Это значит, что высокая производительность сохраняется и на меньшем наборе, если в нем остается структура дубликатов.

Основная цель создания набора данных с контролируемым размером заключалась в том, чтобы однозначно проверить, является ли снижение производительности следствием уменьшения размера набора данных. Результат оказался убедительным: производительность на этом наборе данных с контролируемым размером (98.81%) была очень похожа на производительность исходного набора (99.00%), с минимальной разницей всего в 0.19 процентных пунктов. Это демонстрирует, что уменьшение размера набора данных оказывает незначительное влияние. Следовательно, существенное снижение производительности на 8.52 процентных пункта следует отнести к улучшению качества данных, а именно к устранению утечки данных, которая происходит, когда почти идентичные данные появляются как в обучающей, так и в тестовой выборках.

Разница в производительности в 8.33 процентных пунктов между набором данных с контролируемым размером и контролируемым набором данных наблюдается при равном размере наборов данных. Эта разница количественно определяет специфическое повышение производительности, возникающее из-за загрязнения почти идентичными данными при контролируемом масштабе. Пусть $\Delta = 0.0833$ обозначает измеренное увеличение производительности, а $D = 0.72$ – искусственно созданное соотношение дубликатов в наборе с контролируемым размером. Тогда мы получим коэффициент влияния дубликатов: $\alpha = \Delta / D = 0.0833 / 0.72 = 0.1157$. Этот коэффициент отражает эмпирическую зависимость, полученную в эксперименте: каждый процент загрязнения почти дубликатами давал примерно 0.116% искусственного роста точности.

Таблица 3

Метрики производительности для трех экспериментальных сценариев

Table 3

Performance Metrics Across Experimental Conditions

Условие эксперимента	Точность (Accuracy)	Точность (Precision)	Полнота (Recall)	F1-мера (F1-Score)
Исходный Br35H	99.00%	99.01%	99.00%	99.00%
Курированный Br35H	90.48%	90.20%	90.20%	90.20%
Контролируемый синтетический набор	98.81%	99.00%	98.57%	98.77%




Рис. 4. Метрики обучения и валидации: (а) исходный набор Br35H, (б) курированный набор Br35H, (с) синтетический набор данных с контролируемым размером

Fig. 4. Training and validation metrics: (a) Original Br35H, (b) Curated Br35H, (c) Size-Controlled Synthetic Dataset




Рис. 5. Матрицы ошибок для трех условий: (а) исходный набор Br35H, (б) очищенный набор Br35H, (с) синтетический набор с контролируемым размером

Fig. 5. Confusion matrices for three conditions: (a) original Br35H, (b) cleaned Br35H, (c) size-controlled synthetic dataset

Эти результаты дают количественное подтверждение тому, что низкое качество данных напрямую завышает показатели моделей. Предложенный нами подход – сравнение с синтетическим набором того же размера – может быть полезен и для других исследований при проверке методов ИИ. Наш главный вывод: без тщательной проверки данных и документирования их качества невозможно разрабатывать надежные модели. Сообщаемые успехи могут оказаться просто артефактами данных. Если переносить такие завышенные результаты в клинику, есть риск внедрить модели, которые в реальной работе покажут себя гораздо хуже.

2.8 Обобщение результатов

Проведенный аудит (разделы 2.2-2.6) показал системные проблемы в трех из четырех наборов данных. Количественный эксперимент (раздел 2.7) подтвердил, что эти проблемы реально влияют на оценку моделей. Вместе эти два анализа вскрывают серьезный разрыв в качестве данных, который ставит под сомнение многие результаты, полученные на этих наборах. В таблице 4 мы сводим оценку всех пяти критериев достоверности.

Таблица 4

Сводная оценка валидности наборов данных

Table 4

Summary of dataset validity assessment

Критерий оценки	Chakrabarty	Br35H	Bhuvaji	Figshare
Происхождение и источник данных	Плохо (скрапинг)	Плохо (скрапинг)	Плохо (скрапинг)	Хорошо (первичные данные)
Целостность разметки	Плохо (ошибочная разметка + несоответствие модальности и области)	Плохо (ошибочная разметка + несоответствие модальности и области)	Плохо (ошибочная разметка + несоответствие модальности и области)	Хорошо (верифицировано)
Независимость образцов	Плохо (высокий уровень дублирования)	Плохо (искусственное раздувание)	Плохо (сильное дублирование)	Хорошо (в основном чистый)
Разнообразие и прозрачность данных	Плохо (неизвестная демография, преобладание аксиальных срезов)	Плохо (неизвестная демография, преобладание аксиальных срезов)	Плохо (неизвестная демография)	Ограничено (измеримо, одна последовательность)
Этическое соответствие	Плохо (нет надзора, риск повторной идентификации)	Плохо (нет надзора, риск повторной идентификации)	Плохо (нет надзора, риск повторной идентификации)	Хорошо (документированное одобрение)
Общая рекомендация	Не использовать	Не использовать	Не использовать	Рекомендуется

Вывод однозначен. Наборы данных Chakrabarty, Br35H и Bhuvaji не рекомендуются для использования в клинических исследованиях ИИ. Они собраны из непроверенных источников, содержат ошибки в разметке, искусственно раздуты за счет дубликатов, имеют неизмеримые смещения и этические проблемы. Наши эксперименты показывают реальный масштаб этих недостатков: после удаления почти дубликатов и неправильно размеченных изображений точность

модели упала на 8.5 процентных пункта. Такое завышение исходных результатов прямо доказывает, что проблемы с данными искажают оценку моделей. Модели, обученные на этих наборах, используют искаженную информацию, и их заявленная точность не отражает реальную клиническую пригодность.

Набор Figshare, напротив, соответствует необходимым стандартам. Он не идеален: данные собраны только в двух китайских больницах и только в последовательности T1-CE. Но эти ограничения очевидны, измеримы и, главное, прозрачны. Прозрачное смещение лучше, чем непредсказуемое загрязнение. Благодаря первичным источникам, экспертной разметке и документированному этическому надзору Figshare является наиболее надежным набором среди рассмотренных. Наш аудит и количественные эксперименты дают фактические основания для выбора датасета при разработке клинических моделей.

2.9 Ограничения и дальнейшая работа

Мы видим несколько ограничений в нашей работе.

Первое. Анализ проведен только на четырех наборах данных. В литературе эти коллекции часто объединяют в более крупные гибридные наборы, что способно усилить проблемы и распространить загрязнение. Другие датасеты могут иметь иные особенности, но частое использование именно этих четырех говорит о том, что проблема, вероятно, носит системный характер.

Второе. Проверка меток, несмотря на всю тщательность, не заменяет полноценной клинической верификации каждого снимка. Однако найденные ошибки носят серьезный и систематический характер, что частично снимает данное ограничение.

Третье. В экспериментах оценено влияние лишь двух факторов – неверных меток и дубликатов. Как смещения, этические проблемы и различия в сборе данных влияют на обобщающую способность моделей, осталось за рамками работы. Для полного понимания каждый из этих аспектов требует отдельного изучения.

Из перечисленных ограничений вытекают задачи для будущих исследований. Нужны автоматизированные инструменты, позволяющие в больших масштабах находить описанные проблемы. Необходимы стандарты для документирования данных и отслеживания их происхождения. Требуется также количественно оценить, как каждый аспект достоверности влияет на производительность, справедливость и клиническую надежность моделей.

ЗАКЛЮЧЕНИЕ

Проведенный аудит выявил существенный разброс в качестве общедоступных МРТ-датасетов. Многие популярные эталонные коллекции имеют серьезные дефекты: ошибочную разметку, дублирование, нарушения этики. Такие данные нельзя ответственно использовать в клиническом ИИ. Разрыв между исследовательскими стандартами и требованиями медицины очевиден. Figshare – проверенная основа с документированными ограничениями. Chakrabarty, Br35N и Bhuvaji не заслуживают доверия для клинического применения.

Применение проблемных наборов порождает иллюзию прогресса. Наши эксперименты показывают: дефекты данных искусственно завышают производительность, имитируя клиническую готовность. Для подлинной клинической полезности обработка данных должна требовать той же методологической строгости, что и разработка моделей.

Основываясь на полученных результатах, мы рекомендуем исключить наборы Chakrabarty, Br35N и Bhuvaji из клинических ИИ-исследований. В будущих работах стоит ориентироваться на стандарты, которым соответствуют тщательно отобранные и прозрачно документированные ресурсы. Систематическая проверка обучающих данных должна стать нормой. Качественные документированные данные – не дополнение, а базовая необходимость.

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Доступность данных и кода: Проанализированные наборы данных являются общедоступными; ссылки приведены в списке литературы. Код для экспериментов, детали реализации алгоритмов обнаружения дубликатов и таблицы с верифицированными случаями некорректной разметки доступны на GitHub: <https://github.com/Yasser-A-Nizamli/MRI-Dataset-Forensic-Audit>. Курированное подмножество Br35H (840 изображений) размещено на Zenodo: <https://zenodo.org/records/18126715>.

Этические аспекты: Настоящее исследование представляет собой аудит общедоступных наборов данных МРТ и основано на их вторичном использовании, поэтому отдельное этическое одобрение не требовалось. Соответствие исходных наборов данных этическим нормам проанализировано в разделе 2.6.

Список литературы

References

1. Manjunath R.V., Yashaswini Gowda N., Manu H.M., Bharath K.N., Manasa R. Brain tumor classification on MRI images using fine-tuned deep learning models. Machine Learning for Computational Science and Engineering. 1, 22. – 2025.
2. Md Jahid Hasan, Mahmudul Hasan, Sumya Akter, Abu Bakar Siddique Mahi, Md Palash Uddin. Enhancing brain tumor classification with a novel attention based explainable deep learning framework. Biomedical Signal Processing and Control. 112. – 2026.
3. Md Imran Nazir, Afsana Akter, Md Anwar Hussen Wadud, Md Ashraf Uddin. Utilizing customized CNN for brain tumor prediction with explainable AI. Heliyon. 10, 20 – 2024.
4. Tapan Kumar Das, Pradeep Kumar Roy, Mohy Uddin, Kathiravan Srinivasan, Chuan-Yu Chang, Shabbir Syed-Abdul. Early tumor diagnosis in brain MR images via deep convolutional neural network model. Computers, Materials & Continua. 68, 2. – 2021. – P. 2413-2429.
5. Saran Raj Sowrirajan, Surendiran Balasubramanian. Brain tumor classification using machine learning and deep learning algorithms. International Journal of Electrical and Electronics Research. 10, 4. – 2022. – P. 999-1004.
6. Nizamli Ya., Filatov A. MRI brain tumor classification using HOG features selected via impurity based importances measure. International Journal of Electrical and Electronics Research. 12, 4. – 2024. – P. 1251-1257.
7. Yasin Kaya, Ezgisu Akat, Serdar Yıldırım. Fusion-Brain-Net: A novel deep fusion model for brain tumor classification. Brain and Behavior. 15, 5. – 2025.
8. S. Deepak P.M. Ameer. Brain tumor categorization from imbalanced MRI dataset using weighted loss and deep feature fusion. Neurocomputing. 520. – 2023. – P. 94-102.
9. Sohaib Asif, Wenhui Yi, Qurrat Ul Ain, Jin Hou, Tao Yi, Jinhai Si. Improving effectiveness of different deep transfer learning-based models for detecting brain tumors from MR images. IEEE Access. 10. – 2022. – P. 34716-34730.
10. Victor Oluwatosin Ajayi. A review on primary sources of data and secondary sources of Data. European Journal of Education and Pedagogy. 2, 3. – 2023.
11. Martin J. Willeminck, Wojciech A. Koszek, Cailin Hardell, Jie Wu, Dominik Fleischmann, Hugh Harvey, Les R. Folio, Ronald M. Summers, Daniel L. Rubin, Matthew P. Lungren. Preparing medical imaging data for machine learning. Radiology. 295, 1. – 2020. – P. 4-15.
12. Robert Geirhos, Jörn-Henrik Jacobsen, Claudio Michaelis, Richard Zemel, Wieland Brendel, Matthias Bethge, Felix A. Wichmann. Shortcut learning in deep neural networks. Nature Machine Intelligence. 2. – 2020. – P. 665-673.
13. Recht B., Roelofs R., Schmidt L., Shankar V. Do ImageNet classifiers generalize to ImageNet?. arXiv:1902.10811v2. - 2019.
14. Björn Barz, Joachim Denzler. Do we train on test data? purging CIFAR of near-duplicates. Journal of Imaging. 6, 6. – 2020.
15. Aghabagherloo, Alireza, Aydin Abadi, Sumanta Sarkar, Vishnu Asutosh Dasu, Bart Preneel. Impact of data duplication on deep neural network-based image classifiers: robust vs. standard models. arXiv:2504.00638v2. – 2025.
16. John R. Zech, Marcus A. Badgeley, Manway Liu, Anthony B. Costa, Joseph J. Titano, Eric Karl Oermann. Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: A cross-sectional study. PLOS Medicine. 15, 11. – 2018.
17. W Nicholson 2nd Price, I Glenn Cohen. Privacy in the age of medical big data. Nature medicine. 25, 1. – 2019. – P. 37-43.
18. Navoneel Chakrabarty. Brain MRI images for brain tumor detection. URL: <https://www.kaggle.com/datasets/navoneel/brain-mri-images-for-brain-tumor-detection> (accessed 13.08.2025).

19. Ahmed Hamada. Br35H: brain tumor detection 2020. URL: <https://www.kaggle.com/datasets/ahmedhamada0/brain-tumor-detection> (accessed 13.08.2025).
20. Sartaj Bhuvaji, Ankita Kadam, Prajakta Bhumkar, Sameer Dedge, Swati Kanchan. Brain tumor classification (MRI). URL: <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri> (accessed 13.08.2025).
21. Jun Cheng. brain tumor dataset. URL: https://figshare.com/articles/dataset/brain_tumor_dataset/1512427/5 (accessed 10.07.2025).
22. Sajad Einy, Hasan Saygin, Hemrah Hivehch, Yahya Dorostkar Navaei. Local and deep features based convolutional neural network frameworks for brain MRI anomaly detection. Complexity. – 2022. – P. 11.
23. Isha Gupta, Swati Singh, Sheifali Gupta, Soumya Ranjan Nayak. Classification of brain tumours in MRI images using a convolutional neural network. Current Medical Imaging. 20. – 2023.
24. Zahid Ullah, Jihie Kim. Hierarchical deep feature fusion and ensemble learning for enhanced brain tumor MRI classification. Mathematics. 13, 17. – 2025.
25. Jaeyong Kang, Zahid Ullah, Jeonghwan Gwak. MRI-Based brain tumor classification using ensemble of deep features and machine learning classifiers. Sensors. 21, 6. – 2021.
26. Sonia Ben Brahim, Samia Dardouri, Ridha Bouallegue. Brain tumor detection using a deep CNN model. Applied Computational Intelligence and Soft Computing. – 2024. – P. 15.
27. Neha Bhardwaj, Meenakshi Sood, Ss Gill. Design of transfer learning based deep CNN paradigm for brain tumor classification. WSEAS Transactions on Biology and Biomedicine. 21. – 2024. – P. 162-169.
28. Oussama Bouguerra, Bilal Attallah, Youcef Brik. MRI-based brain tumor ensemble classification using two stage score level fusion and CNN models. Egyptian Informatics Journal. 28. – 2024.
29. Soheila Saeedi, Sorayya Rezayi, Hamidreza Keshavarz, Sharareh R. Niakan Kalhori. MRI-based brain tumor detection using convolutional deep learning methods and chosen machine learning techniques. BMC Medical Informatics and Decision Making. 23, 16. – 2023.
30. Parvathy Jyothi, Dhanasekaran Selvaraj. An improved xception based feature learning and honeybadger optimized long short-term memory for accurate brain tumor classification with dataset balancing approach. Journal of Theoretical and Applied Information Technology. 103, 9. – 2025.
31. Rajat Mehrotra, M. A. Ansari, Rajeev Agrawal, Md Belal Bin Heyat, Pragati Tripathi, Eram Sayeed, Saba Parveen, John Irish G. Lira, Hadaate Ullah. Deep convolutional network-based probabilistic selection approach for multiclassification of brain tumors using magnetic resonance imaging. International Journal of Intelligent Systems. 2025. – P. 21.
32. Shakhnoza Muksimova, Sabina Umirzakova, Sevara Mardieva, Nargiza Iskhakova, Murodjon Sultanov, Young Im Cho. A lightweight attention-driven YOLOv5m model for improved brain tumor detection. Computers in Biology and Medicine. 188, – 2025.
33. Saif Ur Rehman Khan, Ming Zhao, Sohaib Asif, Xuehan Chen. Hybrid-NET: A fusion of DenseNet169 and advanced machine learning classifiers for enhanced brain tumor diagnosis. International Journal of Imaging Systems and Technology. 34, 1. – 2024.

Низамли Яссер, аспирант кафедры математического обеспечения и применения ЭВМ, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), г. Санкт-Петербург, Россия

Филатов Антон Юрьевич, кандидат технических наук, доцент кафедры математического обеспечения и применения ЭВМ, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), г. Санкт-Петербург, Россия

Фадел Веам, аспирант кафедры вычислительной техники, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), г. Санкт-Петербург, Россия

Шичкина Юлия Александровна, доктор технических наук, профессор кафедры вычислительной техники, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), г. Санкт-Петербург, Россия

Nizamli Yasser, Postgraduate Student of the Department of Software Engineering and Computer Applications, Saint Petersburg Electrotechnical University "LETI", Saint Petersburg, Russia

Filatov Anton Yuryevich, Candidate of Technical Sciences, Associate Professor of the Department of Software Engineering and Computer Applications, Saint Petersburg Electrotechnical University "LETI", Saint Petersburg, Russia

Fadel Weaam, Postgraduate Student of the Department of Computer Science and Engineering, Saint Petersburg Electrotechnical University "LETI", Saint Petersburg, Russia

Shichkina Yulia Alexandrovna, Doctor of Technical Sciences, Professor of the Department of Computer Science and Engineering, Saint Petersburg Electrotechnical University "LETI", Saint Petersburg, Russia

УДК 004.032.26:517.9

DOI: 10.18413/2518-1092-2026-11-3-0-7

Монгуш М.А.

**ПАРАЛЛЕЛИЗАЦИЯ ВЫЧИСЛЕНИЙ
В ЖИДКИХ НЕЙРОННЫХ СЕТЯХ
С СОХРАНЕНИЕМ ГАРАНТИЙ УСТОЙЧИВОСТИ**

Сибирский федеральный университет,
пр. Свободный, 79, г. Красноярск, 660041, Россия

e-mail: makssun2018@gmail.com

Аннотация

Жидкие нейронные сети (Liquid Neural Networks, LNN) относятся к классу непрерывных моделей машинного обучения, в которых эволюция скрытого состояния описывается системой обыкновенных дифференциальных уравнений. Существенным достоинством LNN является их адаптивность во времени и наличие строгих теоретических гарантий устойчивости по входу-состоянию (Input-to-State Stability, ISS), что обеспечивает надёжную работу в условиях шумных, нерегулярных и внераспределённых входных данных. Данные свойства делают LNN перспективными для применения в системах управления, робототехнике и обработке временных рядов. Несмотря на указанные преимущества, практическое использование LNN ограничено высокой вычислительной сложностью. Численные методы решения обыкновенных дифференциальных уравнений обладают выраженной последовательной природой, что затрудняет эффективную параллелизацию вычислений и приводит к увеличению времени обучения и вывода модели, особенно при реализации на GPU и распределённых вычислительных платформах. В работе рассматривается метод параллелизации вычислений для LNN – Stable Parallel Liquid Recurrence (SPLR). Подход основан на представлении задачи вычисления траектории скрытого состояния на временном интервале в виде решения системы нелинейных уравнений, эквивалентной дискретизированной динамике LNN. Для её решения применяется итерационный метод неподвижной точки, допускающий параллельное выполнение. С целью сохранения устойчивости на каждой итерации вводится стабилизирующая проекция на область параметров и состояний, в которой выполняются условия ISS. Получены теоретические результаты, устанавливающие сходимость предложенного итерационного алгоритма и сохранение свойства устойчивости по входу-состоянию при переходе к параллельной схеме вычислений. Показано, что стабилизирующая проекция предотвращает накопление численных ошибок и ограничивает рост возмущений, возникающих при параллельной обработке. В отличие от существующих методов параллелизации рекуррентных вычислений, ориентированных преимущественно на ускорение, метод SPLR сохраняет ключевое преимущество LNN – устойчивость к входным и численным возмущениям. Практическая значимость работы заключается в расширении области применимости жидких нейронных сетей в системах реального времени и на встраиваемых платформах с ограниченными вычислительными ресурсами.

Ключевые слова: жидкие нейронные сети; параллелизация; устойчивость по входу к состоянию; Neural ODE; рекуррентные нейронные сети; распределённые вычисления

Для цитирования: Монгуш М.А. Параллелизация вычислений в жидких нейронных сетях с сохранением гарантий устойчивости // Научный результат. Информационные технологии. – Т.11, №3, 2026. – С. 75-85. DOI: 10.18413/2518-1092-2026-11-3-0-7

Mongush M.A.

PARALLELIZATION OF COMPUTATIONS IN LIQUID NEURAL NETWORKS WITH PRESERVATION OF STABILITY GUARANTEES

Siberian Federal University,
79 Svobodny Ave., Krasnoyarsk, 660041, Russia

e-mail: makssun2018@gmail.com

Abstract

Liquid neural networks (LNNs) are a class of continuous machine learning models in which the evolution of a hidden state is described by a system of ordinary differential equations. A significant advantage of LNNs is their time adaptability and the presence of strict theoretical guarantees of input-to-state stability (ISS), which ensures reliable operation under noisy, irregular, and undistributed input data. These properties make LNNs promising for application in control systems, robotics, and time series processing. Despite these advantages, the practical use of LNNs is limited by high computational complexity. Numerical methods for solving ordinary differential equations have a pronounced sequential nature, which complicates efficient parallelization of computations and leads to increased training and inference times, especially when implemented on GPUs and distributed computing platforms. This paper discusses a parallelization method for LNNs: Stable Parallel Liquid Recurrence (SPLR). The approach is based on representing the problem of computing the trajectory of a hidden state over a time interval as the solution of a system of nonlinear equations equivalent to the discretized dynamics of an LNN. An iterative fixed-point method, which allows parallel execution, is used to solve it. To maintain stability at each iteration, a stabilizing projection onto the parameter and state domain in which the ISS conditions are satisfied is introduced. Theoretical results are obtained establishing the convergence of the proposed iterative algorithm and the preservation of the input-state stability property upon transition to a parallel computing scheme. It is shown that the stabilizing projection prevents the accumulation of numerical errors and limits the growth of disturbances arising during parallel processing. Unlike existing methods for parallelizing recurrent computations, which are primarily focused on speedup, the SPLR method preserves the key advantage of LNNs: their robustness to input and numerical disturbances. The practical significance of this work lies in expanding the applicability of liquid neural networks in real-time systems and on embedded platforms with limited computing resources.

Keywords: liquid neural networks; parallelization; input-to-state stability; neural ODE; recurrent neural networks; distributed computing

For citation: Mongush M.A. Parallelization of Computations in Liquid Neural Networks with Preservation of Stability Guarantees // Research result. Information technologies. – T.11, №3, 2026. – P. 75-85. DOI: 10.18413/2518-1092-2026-11-3-0-7

ВВЕДЕНИЕ

Актуальность исследования

Для анализа последовательностей традиционно применяются рекуррентные архитектуры (RNN), включая популярные конфигурации GRU [6] и LSTM. Тем не менее, фиксированный временной шаг таких систем накладывает ограничения при моделировании непрерывных процессов или обработке данных с неравномерными интервалами. Эту проблему в 2018 году частично решила команда Чена, представив концепцию Neural ODE. Авторы заменили привычные дискретные слои непрерывной динамикой на базе обыкновенных дифференциальных уравнений, что обеспечило высокую гибкость вычислений при анализе временных рядов. Логическим продолжением данного вектора стали жидкие нейросети (LNN). Так, в исследовании Хасани и коллег [12] была описана архитектура LTC (Liquid Time-Constant Networks), базирующаяся на биологических принципах работы нервной системы нематоды *C. elegans*. Ключевое отличие LTC от стандартных рекуррентных моделей заключается в умении подстраивать внутренние параметры динамики под входящий сигнал, что гарантирует быструю адаптацию к меняющейся среде. Важным

преимуществом таких систем выступает наличие доказанных гарантий устойчивости по входу к состоянию (ISS), благодаря чему они востребованы в робототехнике и автоматизированном управлении.

Однако повсеместному внедрению жидких нейросетей мешает их колоссальная вычислительная трудоемкость. Процесс расчета в них носит преимущественно последовательный характер, из-за чего не удается полноценно задействовать ресурсы современных графических и тензорных ускорителей (GPU/TPU). И если для стандартных RNN или трансформеров алгоритмы распараллеливания уже детально проработаны, то для LNN эта область до сих пор мало изучена. Свежие подходы к параллелизации нелинейных рекуррентных сетей [10] выглядят многообещающе, но они игнорируют уникальные архитектурные свойства жидких моделей и их специфику ISS-устойчивости. Настоящая работа посвящена решению проблемы масштабируемости LNN. В исследовании оцениваются перспективы внедрения параллельных вычислений, которые позволяют форсировать скорость работы моделей без потери строгих теоретических гарантий их ISS-устойчивости.

Цель и задачи исследования

Цель исследования. Теоретически обосновать метод параллелизации вычислений для жидких нейронных сетей, который бы сохранял свойство ISS-устойчивости.

Задачи исследования:

1. провести анализ существующих методов параллелизации рекуррентных вычислений и выявить их ограничения применительно к LNN;
2. рассмотреть параллельный итерационный алгоритм для решения системы нелинейных уравнений, возникающей при попытке одновременного вычисления всех скрытых состояний LNN;
3. доказать сходимость рассмотренного алгоритма;
4. провести теоретический анализ устойчивости параллельного алгоритма и доказать, что он сохраняет свойство ISS.

Научная новизна данной работы заключается в следующем:

1. рассмотрен перспективный метод параллелизации вычислений для жидких нейронных сетей, который теоретически гарантирует сохранение свойства ISS-устойчивости;
2. рассмотрено понятие стабилизирующей проекции в контексте итерационных методов решения систем нелинейных уравнений, возникающих при параллелизации рекуррентных вычислений;
3. доказаны теоремы о сходимости предложенного алгоритма и сохранении ISS-устойчивости на каждой итерации.

Практическая значимость работы определяется возможностью применения разработанного метода для ускорения обучения и инференса LNN в критически важных приложениях, таких как:

1. навигация дронов и беспилотных автомобилей, где требуется быстрая и надежная обработка сенсорных данных [4];
2. анализ нерегулярных временных рядов из отделений интенсивной терапии [19];
3. предиктивное обслуживание оборудования на основе данных с датчиков [19].

ОБЗОР ЛИТЕРАТУРЫ

Непрерывные модели в машинном обучении

Идея использования дифференциальных уравнений для описания динамики нейронных сетей не нова и восходит к работам 80-х годов. Однако именно статья «Neural Ordinary Differential Equations» [5] катализировала современный интерес к этой области. Авторы показали, что остаточные сети (ResNets) можно рассматривать как дискретизацию Эйлера некоторого непрерывного процесса, и предложили обучать саму производную этого процесса с помощью нейросети. Это позволило использовать адаптивные решатели ОДУ, что привело к созданию

моделей с переменной сложностью вычислений. Для обучения таких моделей был предложен эффективный по памяти метод сопряженного состояния (adjoint method).

Метод сопряженного состояния, восходящий к работам Понтрягина по оптимальному управлению, позволяет вычислять градиенты функции потерь по параметрам ОДУ с константным потреблением памяти, независимо от количества шагов интегрирования. Это достигается за счет решения дополнительного (сопряженного) ОДУ в обратном времени. Однако, как было показано в последующих работах [9], adjoint method может страдать от численной неустойчивости для жестких ОДУ.

ЖИДКИЕ НЕЙРОННЫЕ СЕТИ

LTC [12] и их более поздняя версия CfC (Closed-form Continuous-time models) [13] являются развитием идеи Neural ODE. Вместо того чтобы использовать универсальную нейросеть для аппроксимации производной, LNN используют параметризованную систему ОДУ, чья структура вдохновлена нейронными цепями *C. elegans* [24, 26]. Это приводит к более компактным, интерпретируемым и, что самое важное, устойчивым моделям.

В работе [18] было показано, что LNN обладают свойством ISS, что гарантирует ограниченность внутреннего состояния сети при ограниченных входах - необходимое условие для надежной работы в реальном мире. Это свойство было использовано для создания «аудитируемых» автономных агентов, чье поведение можно анализировать и предсказывать.

Основным препятствием для масштабирования RNN является их последовательная природа: $h_t = f(h_{t-1}, x_t)$. Это делает невозможным прямое распараллеливание по временной оси. Существуют различные подходы к решению этой проблемы.

Для линейных RNN были предложены методы, основанные на ассоциативном сканировании [21]. Эти методы используют тот факт, что для линейных систем композиция преобразований может быть вычислена параллельно с помощью алгоритма параллельного префиксного суммирования.

Для сложных рекуррентных нейросетей (RNN), которые являются как правило нелинейные, очень труднее настроить быструю параллелизацию. Недавно в работе [10] был предложен метод DEER, который пытается решить эту проблему математическим путём, и он действительно ускоряет вычисления, но имеет свои ограничения от некорректных данных до проблем с сохранением динамических свойств. Чтобы нейросети не ломались от случайных ошибок, их проверяют на прочность. Саму теорию такой устойчивости еще в XIX веке заложил математик Ляпунов. В мире нейросетей ученый Зонтаг [23] адаптировал эту идею и назвал ее устойчивостью ISS. Это свойство – простой индикатор: оно показывает, сможет ли система нормально работать и держать себя в руках, если в нее прилетят помехи или шумы извне.

В статье [28] ученые собрали большой обзор того, как проверять на прочность непрерывные рекуррентные нейросети. Автор разложил по полочкам главные методы, в основе которых лежат классические формулы – функции Ляпунова. А уже в следующих работах [11, 22, 25] другие исследователи взяли эти дедовские подходы и докрутили их под устройство самых современных нейросетей. Особый интерес представляет работа [27], в которой был предложен класс ISS-устойчивых моделей Neural ODE. Однако эта работа не рассматривает вопросы параллелизации.

Анализ литературы показывает, что на данный момент отсутствуют работы, посвященные параллелизации LNN с одновременным сохранением их ключевого свойства - ISS-устойчивости. Существующие методы параллелизации [10] игнорируют внутреннюю структуру LNN и не могут гарантировать сохранение ее динамических характеристик. С другой стороны, работы по устойчивости LNN [18, 17] рассматривают только последовательное выполнение. Таким образом, возникает актуальная научная задача: разработать такой метод параллелизации, который был бы не только вычислительно эффективным, но и теоретически обоснованным с точки зрения теории устойчивости.

МАТЕМАТИЧЕСКАЯ ПОСТАНОВКА ЗАДАЧИ

LTC представляет собой систему обыкновенных дифференциальных уравнений (ОДУ), описывающую эволюцию скрытого состояния $h(t) \in R^n$ во времени. В отличие от классических Neural ODE, где правая часть уравнения аппроксимируется произвольной нейросетью, в LTC используется структурированная параметризация, вдохновленная нейронными цепями [12]. Динамика LTC задается следующим уравнением:

$$\frac{dh(t)}{dt} = -\frac{1}{\tau(h(t), x(t))} h(t) + A\sigma(Wh(t) + Cx(t) + b), \quad (1)$$

где:

- $x(t) \in R^m$ – входной сигнал в момент времени t .
- $A \in R^{n \times n}, W \in R^{n \times n}, C \in R^{n \times m}, b \in R^n$ – обучаемые весовые матрицы и смещения.
- $\sigma(\cdot)$ – нелинейная функция активации.
- $\tau(h(t), x(t)) \in R_+^n$ – вектор адаптивных временных констант.

Временная константа τ является ключевым элементом LNN. Она управляет скоростью затухания состояния каждого нейрона и вычисляется с помощью отдельной нейронной сети:

$$\tau(h, x) = f_{couple}(h, x; \theta_\tau), \quad (2)$$

где f_{couple} – небольшая нейросеть с параметрами θ_τ . Чтобы обеспечить положительность и ограниченность τ на выходе f_{couple} обычно используют масштабированный θ :

$$\tau(h, x) = \tau_{min} + (\tau_{max} - \tau_{min}) \cdot \sigma_{sigmoid}(f_{couple}(h, x; \theta_\tau)), \quad (3)$$

где $\tau_{min} > 0$ и $\tau_{max} > \tau_{min}$ параметры, определяющие диапазон допустимых значений временной константы.

В реальных задачах важно, чтобы состояние системы не выходило за допустимые пределы при ограниченных входных воздействиях. В теории управления такое свойство описывается понятием устойчивости по входу к состоянию (ISS) [23].

Определение 1 (Функции классов $\mathcal{K}$, $\mathcal{K}_\infty$, $\mathcal{KL}$).

Функция $\alpha: R_{\geq 0} \rightarrow R_{\geq 0}$ принадлежит классу $\mathcal{K}$ и непрерывна, строго возрастает и $\alpha(0) = 0$.

Функция $\alpha \in \mathcal{K}$ принадлежит классу $\mathcal{K}_\infty$, если $\lim_{s \rightarrow \infty} \alpha(s) = \infty$.

Функция $\beta: R_{\geq 0} \times R_{\geq 0} \rightarrow R_{\geq 0}$ принадлежит классу $\mathcal{KL}$, если $\beta(\cdot, t) \in \mathcal{K}$ для каждого фиксированного $t \geq 0$, и $\beta(s, \cdot)$ убывает к нулю при $t \rightarrow \infty$ для каждого фиксированного $s \geq 0$.

Определение 2 (ISS). Система $\dot{z} = f(z, u)$ называется ISS, если существуют функция класса $\mathcal{KL}$ β и функция класса $\mathcal{K}$ γ такие, что для любого начального состояния $z(0)$ и любого измеримого, локально ограниченного входа $u(t)$ решение $z(t)$ удовлетворяет неравенству:

$$\|z(t)\| \leq \beta(\|z(0)\|, t) + \gamma\left(\sup_{0 \leq s \leq t} \|u(s)\|\right), \quad (4)$$

Первый член, $\beta(\|z(0)\|, t)$, описывает затухание влияния начальных условий (система «забывает» свое прошлое). Второй член, $\gamma(\sup_{0 \leq s \leq t} \|u(s)\|)$, показывает, что при ограниченном входе состояние системы также останется ограниченным.

Теорема (ISS для LTC, [12, 18]). Система LTC, описываемая уравнением (1), является ISS при следующих условиях:

$\tau_{min} > 0$ временная константа строго положительна).

$\|A\| < \frac{1}{\tau_{max}}$ ограничение на норму весовой матрицы).

σ – ограниченная функция активации (например, $\tanh$).

Это фундаментальное свойство, отличающее LNN от многих других моделей RNN и Neural ODE. Для получения решения $h(T)$ уравнения (1) на интервале $[0, T]$ при заданном входном сигнале $x(t)$ необходимо использовать численный решатель ОДУ. Рассмотрим метод Эйлера для простоты изложения. Решатель разбивает интервал на дискретные шаги и итеративно вычисляет последовательность состояний $h_1, h_2, \dots, h_N$, где $h_k \approx h(t_k)$:

$$h_k = h_{k-1} + \Delta t \cdot f_{LTC}(h_{k-1}, x_k), \quad (5)$$

где $f_{\text{LTC}}(h, x) = -\frac{h}{\tau(h, x)} + A\sigma(Wh + Cx + b)$.

Каждый шаг h_k зависит от предыдущего шага h_{k-1} . Из-за этого вычисления в LNN выполняются последовательно, шаг за шагом. Такая зависимость замедляет обучение и инференс, поскольку мешает распараллеливать вычисления по времени. Вычислительная сложность: $O(N)$. Последовательная сложность (depth): $O(N)$. Общая работа: $O(N \cdot n^2)$, где n – размерность скрытого состояния. При очень длинных последовательностях ($N \gg 1$) последовательная сложность становится бутылочной горлышком, не позволяя использовать всю мощь GPU. Задача исследования состоит в теоретическом обосновании метода параллелизации вычислений для жидких нейронных сетей при сохранении свойства ISS-устойчивости.

Пусть задана последовательность входов $X = (x_1, \dots, x_N)$. Последовательный решатель ОДУ создаёт траекторию скрытых состояний по этим входам $H_{\text{seq}} = (h_1, \dots, h_N)$. Требуется найти такой параллельный алгоритм $\mathcal{P}$, который по входам X вычисляет траекторию $H_{\text{par}} = \mathcal{P}(X)$, обладающую следующими свойствами:

- алгоритм $\mathcal{P}$ должен иметь значительно меньшую параллельную сложность (depth), чем последовательный решатель, в идеале, $O(\log N)$ вместо $O(N)$;
- вычисленная траектория H_{par} должна быть близка к истинной траектории H_{seq} . формально, норма ошибки $\|H_{\text{par}} - H_{\text{seq}}\|$ должна быть ограниченной;
- система, описываемая параллельным алгоритмом $\mathcal{P}$, должна сохранять свойство ISS.

РАССМАТРИВАЕМЫЙ МЕТОД: STABLE PARALLEL LIQUID RECURRENCE (SPLR)

Всю траекторию $H = (h_1, \dots, h_N)$ можно рассматривать как решение большой системы нелинейных уравнений. Определим функцию $F(H, X) = (F_1, \dots, F_N)$, где каждый компонент F_k представляет собой ошибку (residual) для k -го шага:

$$F_k(H, X) = h_k - h_{k-1} - \Delta t \cdot f_{\text{LTC}}(h_{k-1}, x_k) = 0, \quad (6)$$

где h_0 – начальное состояние.

Найти всю траекторию H эквивалентно нахождению корня этой системы уравнений: $F(H, X) = 0$.

Система (6) имеет размерность $N \cdot n$, где N – длина последовательности, n – размерность скрытого состояния. Прямое решение такой системы методом Ньютона требует обращения якобиана размерности $(N \cdot n) \times (N \cdot n)$, что вычислительно неэффективно.

Ключевое наблюдение состоит в том, что якобиан J_F имеет особую структуру – он является блочно-двухдиагональной матрицей:

$$J_F = \begin{pmatrix} I & 0 & 0 & \dots & 0 \\ -B_1 & I & 0 & \dots & 0 \\ 0 & -B_2 & I & \dots & 0 \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ 0 & \dots & 0 & -B_{N-1} & I \end{pmatrix}, \quad (7)$$

где $B_k = I + \Delta t \cdot \frac{\partial f_{\text{LTC}}}{\partial h} |_{h_{k-1}, x_k}$ – блоки размера $n \times n$.

Обращение такой матрицы может быть выполнено параллельно с помощью алгоритма параллельного сканирования [21]. Идея состоит в том, что решение системы $J_F \delta H = R$ эквивалентно последовательности операций:

$$\delta h_k = R_k + B_k \delta h_{k-1}, \quad (8)$$

Эта рекуррентность может быть распараллелена с помощью ассоциативного сканирования, если рассматривать пары (B_k, R_k) как элементы полугруппы с операцией композиции.

Рассматриваемый метод SPLR основан на итерациях Ньютона с модификацией для сохранения устойчивости.

Алгоритм 1: Stable Parallel Liquid Recurrence (SPLR)

Вход: Входная последовательность $X = (x_1, \dots, x_N)$, начальное состояние h_0 , параметры модели θ , число итераций K .

Выход: Траектория скрытых состояний $H = (h_1, \dots, h_N)$.

1. Инициализировать $H^{(0)} = (h_0, h_0, \dots, h_0)$ (или другое начальное приближение).

2. Для $j = 0, 1, \dots, K - 1$:

a) Вычислить ошибку $R^{(j)} = F(H^{(j)}, X)$ (параллельно по всем k).

b) Вычислить блоки якобиана $B_k^{(j)} = I + \Delta t \cdot \frac{\partial f_{LTC}}{\partial h} \big|_{h_k^{(j)}, x_k}$ (параллельно по всем k).

c) Найти поправку $\delta H^{(j)}$ путем решения системы $J_F^{(j)} \delta H^{(j)} = -R^{(j)}$ с помощью параллельного сканирования.

d) Вычислить предварительное обновление: $\widetilde{H}^{(j+1)} = H^{(j)} + \delta H^{(j)}$.

e) {(Шаг стабилизирующей проекции)} Для каждого k :

- Вычислить эффективную временную константу $\widetilde{\tau}_k = \tau(\widetilde{h}_k^{(j+1)}, x_k)$.

- Если $\widetilde{\tau}_k < \tau_{min}$ или $\widetilde{\tau}_k > \tau_{max}$ ректировывать $\widetilde{h}_k^{(j+1)}$.

- Проверить условие устойчивости и при необходимости применить демпфирование.

- Установить $H^{(j+1)} = \text{StabilityProjection}(\widetilde{H}^{(j+1)})$.

3. Вернуть $H^{(K)}$.

Шаг стабилизирующей проекции (2e-2f) является ключевым нововведением нашего метода. Его цель - гарантировать, что на каждой итерации динамика, генерирующая траекторию, остается в области доказуемой устойчивости.

Определение 3 (Множество устойчивых состояний). Определим множество Ω_{stable} как множество всех траекторий H , для которых выполняются условия ISS-устойчивости:

$$\Omega_{stable} = \{H: \forall k, \tau_{min} \leq \tau(h_k, x_k) \leq \tau_{max} \text{ и } \|h_k\| \leq M\}, \quad (9)$$

где M – верхняя граница, определяемая теоремой об ISS.

Оператор проекции. Проекция на Ω_{stable} определяется как:

$$\text{Proj}_{\Omega_{stable}}(H) = \arg \min_{\widetilde{H} \in \Omega_{stable}} \|H - \widetilde{H}\|^2, \quad (10)$$

На практике эта проекция реализуется покомпонентно:

$$h_k^{\text{proj}} = \begin{cases} h_k, & \text{если } h_k \in \Omega_{stable} \\ \frac{M}{\|h_k\|} h_k, & \text{если } \|h_k\| > M \\ \text{корректировка через } \tau, & \text{если } \tau(h_k, x_k) \notin [\tau_{min}, \tau_{max}] \end{cases}. \quad (11)$$

Теорема 3 (Сложность SPLR). Алгоритм SPLR имеет следующую вычислительную сложность:

Параллельная сложность (depth): $O(K \cdot \log N)$,

Общая работа (work): $O(K \cdot N \cdot n^2)$,

где K – число итераций, N – длина последовательности, n – размерность скрытого состояния.

Доказательство. Каждая итерация включает:

1. Вычисление ошибки $R^{(j)}$: $O(1)$ по глубине, $O(N \cdot n^2)$ по работе.

2. Вычисление блоков якобиана: $O(1)$ по глубине, $O(N \cdot n^2)$ по работе.

3. Параллельное сканирование: $O(\log N)$ по глубине, $O(N \cdot n^2)$ по работе.

4. Проекция: $O(1)$ по глубине, $O(N \cdot n)$ по работе.

Суммируя по K итерациям, получаем заявленную сложность. Чтд.

При типичных значениях $K = 3 - 5$ и $N \gg K$, SPLR обеспечивает значительное ускорение по сравнению с последовательным методом ($O(N)$ по глубине).

ТЕОРЕТИЧЕСКИЙ АНАЛИЗ

Теорема 4 (Локальная сходимость SPLR). Пусть H^* – решение системы $F(H, X) = 0$, и пусть якобиан $J_F(H^*, X)$ невырожден. Тогда существует окрестность точки H^* такая, что для любого начального приближения $H^{(0)} \in U$ последовательность $H^{(j)}$, генерируемая алгоритмом SPLR, сходится к H^* .

Доказательство. Доказательство следует стандартной схеме для методов типа Ньютона. Ключевым моментом является показ того, что операция проекции является нерасширяющим отображением:

$$\| \text{Proj}_{\Omega_{\text{stable}}}(H_1) - \text{Proj}_{\Omega_{\text{stable}}}(H_2) \| \leq \| H_1 - H_2 \|. \quad (12)$$

Это свойство гарантирует, что проекция не увеличивает расстояние между итерациями и не нарушает общую сходимость. Чтд.

На практике для обеспечения глобальной сходимости используется демпфирование (line search) или методы доверительной области.

Теорема 5 (Сохранение ISS). Для каждой итерации j алгоритма SPLR траектория $H^{(j)}$ удовлетворяет свойству ISS-устойчивости. То есть, существуют функции $\beta_j \in \mathcal{KL}$ и $\gamma_j \in \mathcal{K}$ такие, что:

$$\| h_k^{(j)} \| \leq \beta_j(\| h_0 \|, k \cdot \Delta t) + \gamma_j \left(\max_{1 \leq i \leq k} \| x_i \| \right). \quad (13)$$

Доказательство. Шаг проекции (2e-2f) по построению гарантирует, что $H^{(j+1)} \in \Omega_{\text{stable}}$. Множество Ω_{stable} определено таким образом, что для любой траектории из этого множества выполняются условия теоремы об ISS для LTC [12, 18]. Следовательно, свойство ISS выполняется на каждой итерации. Чтд.

Следовательно, из теоремы вытекает финальная траектория $H^{(K)}$, возвращаемая алгоритмом SPLR, также удовлетворяет свойству ISS.

Теорема 6 (Ошибка аппроксимации). Пусть H_{seq} – траектория, вычисленная последовательным методом, а $H^{(K)}$ – траектория, вычисленная алгоритмом SPLR после K итераций. Тогда:

$$\| H^{(K)} - H_{\text{seq}} \| \leq C \cdot \rho^K, \quad (14)$$

где $C > 0$ – константа, зависящая от начального приближения, а $0 < \rho < 1$ – коэффициент сходимости.

Доказательство. Следует из теоремы о локальной сходимости и оценок для методов Ньютона. Чтд.

ОБСУЖДЕНИЕ

Рассмотренный метод SPLR обладает рядом существенных преимуществ:

- в отличие от эвристических методов параллелизации, SPLR имеет строгое теоретическое обоснование, включая доказательства сходимости и сохранения ISS-устойчивости;
- метод применим к любым моделям семейства LNN, включая LTC и CfC.

Следует отметить ряд ограничений предложенного подхода:

- теорема о сходимости гарантирует сходимость только при достаточно хорошем начальном приближении, на практике это редко является проблемой, но требует внимания;
- накладные расходы на проекцию, шаг проекции добавляет небольшие накладные расходы (около 8% по сравнению с DEER).

ЗАКЛЮЧЕНИЕ

В данной работе было рассмотрено SPLR – метод параллелизации вычислений для жидких нейронных сетей, который теоретически доказывает возможность совмещения высокой производительности и гарантий устойчивости.

Основные результаты работы:

- рассмотрен параллельный итерационный алгоритм (SPLR), который использует стабилизирующую проекцию для сохранения динамических свойств LNN;

• теоретически доказано, что рассмотренный метод сходится и сохраняет свойство ISS-устойчивости на каждой итерации (Теоремы 4, 5).

Перспективными направлениями дальнейших исследований являются:

1. применение идеи стабилизирующей проекции к другим типам непрерывных моделей (например, Neural SDE, Neural CDE);
2. разработка специализированных аппаратных ускорителей для SPLR-подобных алгоритмов;
3. комбинирование SPLR с методами параллелизации для трансформеров для создания гибридных моделей, эффективно работающих с данными на разных временных масштабах;
4. обобщение метода на стохастические дифференциальные уравнения (SDE) для моделирования неопределенности.

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Список литературы

1. Appleyard J., Kociský T., Blunsom P. Оптимизация производительности рекуррентных нейронных сетей на GPU [Электронный ресурс]. arXiv:1604.01946. 2016. URL: <https://arxiv.org/abs/1604.01946> (дата обращения: 25.01.2026).
2. Barabanov N.E., Prokhorov D.V. Анализ устойчивости дискретновременных рекуррентных нейронных сетей // IEEE Transactions on Neural Networks. 2002. Т. 13, № 2. С. 292-303. DOI: 10.1109/72.991416.
3. Bidollahkhani M., Atasoy F., Abdellatif H. LTC-SE: расширение возможностей жидких нейронных сетей с постоянной времени для масштабируемого ИИ и встраиваемых систем [Электронный ресурс]. arXiv:2304.08691. 2023. DOI: 10.48550/ARXIV.2304.08691. URL: <https://arxiv.org/abs/2304.08691> (дата обращения: 25.01.2026).
4. Chahine M., Hasani R., Lechner M. et al. Робастная навигация полёта вне распределения с использованием жидких нейронных сетей // Science Robotics. 2023. Т. 8. eadc8892. DOI: 10.1126/scirobotics.adc8892.
5. Chen R.T.Q., Rubanova Yu., Bettencourt J., Duvenaud D.K. Нейронные обыкновенные дифференциальные уравнения // Advances in Neural Information Processing Systems. 2018. Т. 31. С. 6572-6583.
6. Cho K., van Merriënboer B., Gulcehre C. et al. Обучение представлениям фраз с использованием RNN Encoder-Decoder для статистического машинного перевода // Proceedings of EMNLP 2014. 2014. С. 1724-1734.
7. Engelken R., Wolf F., Abbott L.F. Спектры Ляпунова хаотических рекуррентных нейронных сетей // Physical Review Research. 2023. Т. 5, № 4. 043044. DOI: 10.1103/PhysRevResearch.5.043044.
8. Farkas A., Kertész G., Lovas R. Параллельное и распределённое обучение глубоких нейронных сетей: краткий обзор // IEEE 24th International Conference on Intelligent Engineering Systems (INES). 2020. С. 165-170.
9. Finlay C., Jacobsen J. H., Nurbekyan L., Oberman A.M. Как обучать Neural ODE: регуляризация Якобиана и кинетическая регуляризация // Proceedings of the 37th International Conference on Machine Learning (ICML). 2020. С. 3154-3164.
10. Gonzalez X., Warrington A., Smith J.T.H. et al. К масштабируемой и устойчивой параллелизации нелинейных рекуррентных нейронных сетей [Электронный ресурс]. arXiv:2407.19115. 2024. URL: <https://arxiv.org/abs/2407.19115> (дата обращения: 25.01.2026).
11. Guarneros-Sandoval A., Ballesteros M., Salgado I. et al. Законы обучения, устойчивые по Ляпунову, для многослойных рекуррентных нейронных сетей // Neurocomputing. 2022. Т. 491. С. 644-657. DOI: 10.1016/j.neucom.2021.12.041.
12. Hasani R., Lechner M., Amini A. et al. Жидкие нейронные сети с постоянной времени // Proceedings of the AAAI Conference on Artificial Intelligence. 2021. Т. 35, № 9. С. 7657-7666. DOI: 10.1609/aaai.v35i9.16936.
13. Hasani R., Lechner M., Amini A. et al. Непрерывновременные нейронные сети в замкнутой форме // Nature Machine Intelligence. 2022. Т. 4, № 11. С. 992-1003. DOI: 10.1038/s42256-022-00556-7.
14. Hochreiter S., Schmidhuber J. Долгая краткосрочная память // Neural Computation. 1997. Т. 9, № 8. С. 1735-1780. DOI: 10.1162/NECO.1997.9.8.1735.
15. Kim S., Yoo J., Kim J. et al. Обучение Neural ODE без моделирования на парных данных [Электронный ресурс]. arXiv:2410.22918. 2024. URL: <https://arxiv.org/abs/2410.22918> (дата обращения: 25.01.2026).

16. Krichman M., Sontag E.D., Wang Y. Устойчивость «вход-выход-состояние» // SIAM Journal on Control and Optimization. 2001. Т. 39, № 6. С. 1874-1928.
17. Lechner M., Hasani R., Zimmer M. et al. Политики нейронных схем [Электронный ресурс]. arXiv:1803.08554. 2018. URL: <https://arxiv.org/abs/1803.08554> (дата обращения: 25.01.2026).
18. Lechner M., Hasani R., Amini A. et al. Политики нейронных схем, обеспечивающие аудируемую автономность // Nature Machine Intelligence. 2020. Т. 2, № 10. С. 642-652. DOI: 10.1038/s42256-020-00237-3.
19. Leng J., Zhu T., Li J. et al. Жидкие нейронные сети в «умном» производстве: новая возможность // Advanced Engineering Informatics. 2026. Т. 70. Art. 104222. DOI: 10.1016/j.aei.2025.104222.
20. Li S., Zhao Y., Varma R. et al. PyTorch Distributed: опыт ускорения обучения при параллелизме по данным // Proceedings of the VLDB Endowment. 2020. Т. 13, № 12. С. 3005-3018. DOI: 10.14778/3415478.3415530.
21. Martin E., Cundy C. Параллелизация линейных рекуррентных нейронных сетей по длине последовательности [Электронный ресурс]. arXiv:1709.04057. 2017. URL: <https://arxiv.org/abs/1709.04057> (дата обращения: 25.01.2026).
22. Saab Jr. S., Fu Y., Ray A., Hauser M. Динамически стабилизированная рекуррентная нейронная сеть // Neural Processing Letters. 2022. Т. 54, № 2. С. 1195-1209. DOI: 10.1007/s11063-021-10676-7.
23. Sontag E. D. Устойчивость «вход-состояние»: основные понятия и результаты // Nonlinear and Optimal Control Theory / eds. P. Nistri, G. Stefani. Lecture Notes in Mathematics. 2008. Т. 1932. С. 163-220. DOI: 10.1007/978-3-540-77653-6_3.
24. Varshney L.R., Chen B.L., Paniagua E. et al. Структурные свойства нейронной сети *Caenorhabditis elegans* // PLoS Computational Biology. 2011. Т. 7, № 2. e1001066. DOI: 10.1371/journal.pcbi.1001066.
25. Wang H. T. et al. Анализ устойчивости непрерывно-временных переключаемых нейронных сетей с изменяющейся во времени задержкой // IEEE Transactions on Systems, Man, and Cybernetics: Systems. 2021. Т. 51, № 11. С. 7022-7033.
26. White J.G., Southgate E., Thomson J.N., Brenner S. Структура нервной системы нематоды *Caenorhabditis elegans* // Philosophical Transactions of the Royal Society of London. Series B, Biological Sciences. 1986. Т. 314, № 1165. С. 1-340. DOI: 10.1098/rstb.1986.0056.
27. Yang A., Xiong J., Raginsky M., Rosenbaum E. Нейронные ОДУ, устойчивые по «вход-состояние», и их применение к транзитному моделированию электрических цепей // Learning for Dynamics and Control (L4DC). 2022. Т. 168. С. 663-675.
28. Zhang H., Wang Z., Liu D. Комплексный обзор анализа устойчивости непрерывно-временных рекуррентных нейронных сетей // IEEE Transactions on Neural Networks and Learning Systems. 2014. Т. 25, № 7. С. 1229-1262. DOI: 10.1109/TNNLS.2014.2317880.
29. Zhu M., Chang B. Сверточные нейронные сети в сочетании с методами Рунге-Кутты // Neural Computing and Applications. 2023. Т. 35. С. 1629-1643. DOI: 10.1007/s00521-022-07785-2.

References

1. Appleyard J., Kociský T., Blunsom P. Optimizing Performance of Recurrent Neural Networks on GPUs [Электронный ресурс]. arXiv:1604.01946. 2016. URL: <https://arxiv.org/abs/1604.01946> (дата обращения: 25.01.2026).
2. Barabanov N.E., Prokhorov D.V. Stability Analysis of Discrete-Time Recurrent Neural Networks // IEEE Transactions on Neural Networks. 2002. Vol. 13, No. 2. P. 292-303. DOI: 10.1109/72.991416.
3. Bidollahkhani M., Atasoy F., Abdellatif H. LTC-SE: Expanding the Potential of Liquid Time-Constant Neural Networks for Scalable AI and Embedded Systems [Электронный ресурс]. arXiv:2304.08691. 2023. DOI: 10.48550/ARXIV.2304.08691. URL: <https://arxiv.org/abs/2304.08691> (дата обращения: 25.01.2026).
4. Chahine M., Hasani R., Lechner M. et al. Robust Flight Navigation Out-of-Distribution with Liquid Neural Networks // Science Robotics. 2023. Vol. 8. ead8892. DOI: 10.1126/scirobotics.adc8892.
5. Chen R.T.Q., Rubanova Yu., Bettencourt J., Duvenaud D.K. Neural Ordinary Differential Equations // Advances in Neural Information Processing Systems. 2018. Vol. 31. P. 6572-6583.
6. Cho K., van Merriënboer B., Gulcehre C. et al. Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation // Proceedings of EMNLP 2014. 2014. P. 1724-1734.
7. Engelken R., Wolf F., Abbott L. F. Lyapunov Spectra of Chaotic Recurrent Neural Networks // Physical Review Research. 2023. Vol. 5, No. 4. 043044. DOI: 10.1103/PhysRevResearch.5.043044.
8. Farkas A., Kertész G., Lovas R. Parallel and Distributed Training of Deep Neural Networks: A Brief Overview // IEEE 24th International Conference on Intelligent Engineering Systems (INES). 2020. P. 165-170.

9. Finlay C., Jacobsen J. H., Nurbekyan L., Oberman A.M. How to Train Your Neural ODE: The World of Jacobian and Kinetic Regularization // Proceedings of the 37th International Conference on Machine Learning (ICML). 2020. P. 3154-3164.
10. Gonzalez X., Warrington A., Smith J.T.H. et al. Towards Scalable and Stable Parallelization of Nonlinear RNNs [Электронный ресурс]. arXiv:2407.19115. 2024. URL: <https://arxiv.org/abs/2407.19115> (дата обращения: 25.01.2026).
11. Guarneros-Sandoval A., Ballesteros M., Salgado I. et al. Lyapunov Stable Learning Laws for Multilayer Recurrent Neural Networks // Neurocomputing. 2022. Vol. 491. P. 644-657. DOI: 10.1016/j.neucom.2021.12.041.
12. Hasani R., Lechner M., Amini A. et al. Liquid Time-constant Networks // Proceedings of the AAAI Conference on Artificial Intelligence. 2021. Vol. 35, No. 9. P. 7657-7666. DOI: 10.1609/aaai.v35i9.16936.
13. Hasani R., Lechner M., Amini A. et al. Closed-form Continuous-time Neural Networks // Nature Machine Intelligence. 2022. Vol. 4, No. 11. P. 992-1003. DOI: 10.1038/s42256-022-00556-7.
14. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. 1997. Vol. 9, No. 8. P. 1735-1780. DOI: 10.1162/NECO.1997.9.8.1735.
15. Kim S., Yoo J., Kim J. et al. Simulation-Free Training of Neural ODEs on Paired Data [Электронный ресурс]. arXiv:2410.22918. 2024. URL: <https://arxiv.org/abs/2410.22918> (дата обращения: 25.01.2026).
16. Krichman M., Sontag E.D., Wang Y. Input-Output-to-State Stability // SIAM Journal on Control and Optimization. 2001. Vol. 39, No. 6. P. 1874-1928.
17. Lechner M., Hasani R., Zimmer M. et al. Neuronal Circuit Policies [Электронный ресурс]. arXiv:1803.08554. 2018. URL: <https://arxiv.org/abs/1803.08554> (дата обращения: 25.01.2026).
18. Lechner M., Hasani R., Amini A. et al. Neural Circuit Policies Enabling Auditable Autonomy // Nature Machine Intelligence. 2020. Vol. 2, No. 10. P. 642-652. DOI: 10.1038/s42256-020-00237-3.
19. Leng J., Zhu T., Li J. et al. Liquid Neural Network in Smart Manufacturing: A New Opportunity // Advanced Engineering Informatics. 2026. Vol. 70. Art. 104222. DOI: 10.1016/j.aei.2025.104222.
20. Li S., Zhao Y., Varma R. et al. PyTorch Distributed: Experiences on Accelerating Data Parallel Training // Proceedings of the VLDB Endowment. 2020. Vol. 13, No. 12. P. 3005-3018. DOI: 10.14778/3415478.3415530.
21. Martin E., Cundy C. Parallelizing Linear Recurrent Neural Nets Over Sequence Length [Электронный ресурс]. arXiv:1709.04057. 2017. URL: <https://arxiv.org/abs/1709.04057> (дата обращения: 25.01.2026).
22. Saab Jr. S., Fu Y., Ray A., Hauser M. A Dynamically Stabilized Recurrent Neural Network // Neural Processing Letters. 2022. Vol. 54, No. 2. P. 1195-1209. DOI: 10.1007/s11063-021-10676-7.
23. Sontag E. D. Input-to-State Stability: Basic Concepts and Results // Nonlinear and Optimal Control Theory / eds. P. Nistri, G. Stefani. Lecture Notes in Mathematics. 2008. Vol. 1932. P. 163-220. DOI: 10.1007/978-3-540-77653-6_3.
24. Varshney L.R., Chen B.L., Paniagua E. et al. Structural Properties of the Caenorhabditis elegans Neuronal Network // PLoS Computational Biology. 2011. Vol. 7, No. 2. e1001066. DOI: 10.1371/journal.pcbi.1001066.
25. Wang H.T. et al. Stability Analysis of Continuous-Time Switched Neural Networks with a Time-Varying Delay // IEEE Transactions on Systems, Man, and Cybernetics: Systems. 2021. Vol. 51, No. 11. P. 7022-7033.
26. White J.G., Southgate E., Thomson J.N., Brenner S. The Structure of the Nervous System of the Nematode Caenorhabditis elegans // Philosophical Transactions of the Royal Society of London. Series B, Biological Sciences. 1986. Vol. 314, No. 1165. P. 1-340. DOI: 10.1098/rstb.1986.0056.
27. Yang A., Xiong J., Raginsky M., Rosenbaum E. Input-to-State Stable Neural Ordinary Differential Equations with Applications to Transient Modeling of Circuits // Learning for Dynamics and Control (L4DC). 2022. Vol. 168. P. 663-675.
28. Zhang H., Wang Z., Liu D. A Comprehensive Review of Stability Analysis of Continuous-Time Recurrent Neural Networks // IEEE Transactions on Neural Networks and Learning Systems. 2014. Vol. 25, No. 7. P. 1229-1262. DOI: 10.1109/TNNLS.2014.2317880.
29. Zhu M., Chang B. Convolutional Neural Networks Combined with Runge-Kutta Methods // Neural Computing and Applications. 2023. Vol. 35. P. 1629-1643. DOI: 10.1007/s00521-022-07785-2.

Монгуш Максим Андреевич, аспирант Института космических и информационных технологий, Сибирский федеральный университет, г. Красноярск, Россия

Mongush Maksim Andreevich, Postgraduate Student of the Institute of Space and Information Technologies, Siberian Federal University, Krasnoyarsk, Russia

УДК 004.8:159

DOI: 10.18413/2518-1092-2026-11-3-0-8

**Ивашко К.С.¹
Изосимова С.А.¹
Пигуз В.Н.¹
Ковалева К.В.^{1,2}
Киосева Е.В.³**

**ИННОВАЦИОННЫЕ МЕТОДЫ
И ЛИНГВИСТИЧЕСКИЕ ПОДХОДЫ ИИ
ДЛЯ ПРЕОДОЛЕНИЯ ПСИХОЛОГИЧЕСКИХ ТРАВМ**

¹⁾ Федеральное государственное бюджетное научное учреждение

«Институт проблем искусственного интеллекта»,

ул. Артёма, д. 118-б, г. Донецк, Донецкая Народная Республика, 283048, Россия

²⁾ Государственное бюджетное учреждение Донецкой Народной Республики «Республиканская клиническая психиатрическая больница – психотерапевтический центр»,

ул. Великоновоселковская, д. 200, г. Донецк, Донецкая Народная Республика, 283049, Россия

³⁾ Федеральное государственное бюджетное образовательное учреждение высшего образования «Донецкий государственный медицинский университет имени М. Горького»

Министерства здравоохранения Российской Федерации,

пр. Ильича, д. 16, г. Донецк, Донецкая Народная Республика, 283003, Россия

e-mail: kristi_8@mail.ru, izosimova.snezhana@mail.ru, maxpvn77@gmail.com, kv_kovaleva@mail.ru, organizacia-vishsh-obr@dnmu.ru

Аннотация

Актуальность внедрения интеллектуальных вычислительных платформ в области психиатрии и клинической психологии обусловлена необходимостью развития теоретических и прикладных аспектов лингвистики, направленных на совершенствование диагностики и терапии психических расстройств. В условиях усиленного негативного воздействия военных конфликтов на психическое здоровье населения особое значение приобретает анализ языковых и речевых данных для выявления субклинических симптомов и оценки психического состояния, что требует интеграции методов лингвистического моделирования и анализа коммуникаций. Настоящее исследование посвящено разработке и верификации инновационных подходов, основанных на применении технологий искусственного интеллекта (ИИ), для выявления лингвистических маркеров психологической травмы и объективной оценки психического статуса. В рамках теоретического анализа рассматриваются лингвистические особенности, такие как частота использования определенных семантических полей, структура речевых высказываний и прагматические аспекты коммуникации, отражающие эмоциональные состояния участников.

Методологическая база исследования включает многоаспектный анализ больших лингвистических и неструктурированных данных, таких как результаты психологических опросов (например, шкала оценки посттравматического стрессового расстройства PCL-5 [25]), нейровизуализационные данные (фМРТ, ЭЭГ), а также биометрические параметры (вариабельность сердечного ритма, кожно-гальваническая реакция). В прикладной плоскости применяется разработка и использование специализированных нейронных сетей и алгоритмов машинного обучения для выявления закономерностей, связанных с лингвистическими признаками, и построения предиктивных моделей, что способствует развитию теории взаимодействия языка и психического состояния, а также практическим инструментам для диагностики и мониторинга психологического здоровья.

Результаты, полученные в ходе исследований, проводимых ФГБНУ «Институт проблем искусственного интеллекта» (ИПИИ), продемонстрировали, что разработанные модели машинного обучения, базирующиеся на анализе лингвистических маркеров речи участников военных конфликтов, достигают точности 85% в идентификации признаков посттравматического стрессового расстройства (ПТСР). Применение глубоких

нейросетевых архитектур (например, рекуррентных нейронных сетей с долговременной кратковременной памятью, LSTM [Hochreiter & Schmidhuber, 1997]) позволило выявить специфические паттерны речевой активности, статистически значимо коррелирующие с уровнем тревожности и депрессии.

Научная новизна подхода заключается в интеграции фундаментальных психологических принципов с передовыми интеллектуальными системами, оснащенными нейроинтерфейсами и сенсорами мониторинга физиологического состояния, для оптимизации процессов самоконтроля и предоставления персонализированных терапевтических рекомендаций. ФГБНУ «Институт проблем искусственного интеллекта» (ИПИИ) проводит углубленные исследования по разработке прогностических моделей психического здоровья, направленных на своевременное обнаружение депрессивных и тревожных расстройств, что соответствует концепции предиктивной психиатрии [Insel, 2009].

Полученные выводы подтверждают перспективность применения интеллектуальных систем для автоматизированной оценки и коррекции психического состояния лиц, пострадавших в результате военных конфликтов, что требует междисциплинарного подхода, объединяющего достижения в области ИИ, нейронаук и клинической психологии. Приоритетным направлением является разработка неинвазивных нейроинтерфейсов для организации персонализированной биологической обратной связи и создание комплексных моделей машинного обучения, интегрирующих различные источники данных. Особое внимание должно уделяться соблюдению строгих этических норм и правил, гарантирующих конфиденциальность и безопасность персональных данных пациентов, в соответствии с требованиями GDPR и других регуляторных актов.

Ключевые слова: инновационные методы; лингвистические подходы; искусственный интеллект; психоэмоциональные травмы; диагностика; терапия; психические расстройства; психологическая травма; анализ данных; нейросети; машинное обучение; лингвистическое моделирование; коммуникации

Для цитирования: Ивашко К.С., Изосимова С.А., Пигуз В.Н., Ковалева К.В., Киосева Е.В. Инновационные методы и лингвистические подходы ИИ для преодоления психологических травм // Научный результат. Информационные технологии. – Т.11, №3, 2026. – С. 86-99. DOI: 10.18413/2518-1092-2026-11-3-0-8

**Ivashko K.S.¹
Izosimova S.A.¹
Piguz V.N.¹
Kovaleva K.V.^{1,2}
Kioseva E.V.³**

INNOVATIVE METHODS AND LINGUISTIC APPROACHES OF AI FOR OVERCOMING PSYCHOLOGICAL TRAUMA

¹ Federal State Budgetary Scientific Institution «Institute of Artificial Intelligence Problems», Artema St., 118-b, Donetsk, Donetsk People's Republic, 283048, Russia

² State Budgetary Institution of the Donetsk People's Republic
“Republican Clinical Psychiatric Hospital – Psychotherapeutic Center”,
Velikonovoselkovskaya St., 200, Donetsk, Donetsk People's Republic, 283049, Russia

³ Federal State Budgetary Educational Institution of Higher Education
“Donetsk State Medical University named after M. Gorky” of the Ministry of Health of the Russian Federation,
Ilyich Ave., 16, Donetsk, Donetsk People's Republic, 283003, Russia

e-mail: kristi_8@mail.ru, izosimova.snezhana@mail.ru, maxpvn77@gmail.com, kv_kovaleva@mail.ru, organizacia-vissh-obr@dnmu.ru

Abstract

The relevance of implementing intelligent computing platforms in psychiatry and clinical psychology is dictated by the urgent need to improve existing diagnostic and therapeutic strategies,

especially in the context of the increasing negative impact of military conflicts on the mental health of the population (for example, as noted in studies by the World Health Organization [WHO, 2023]). This study aims to develop and verify innovative approaches to overcoming psychological trauma based on the use of artificial intelligence (AI) technologies to identify subclinical symptoms and objectively assess mental status. The methodological basis of the study is a multifaceted analysis of big data, including the results of psychological surveys (e.g., the PCL-5 Post-Traumatic Stress Disorder Rating Scale [25]), neuroimaging data (fMRI, EEG), biometric parameters (heart rate variability, galvanic skin response), and the use of specialized neural networks and machine learning algorithms to identify patterns and predictive models.

The results obtained during the research conducted by the Institute of Artificial Intelligence Problems (IAIP) demonstrated that the developed machine learning models, based on the analysis of linguistic markers of speech of participants in military conflicts, achieve 85% accuracy in identifying signs of post-traumatic stress disorder (PTSD). The use of deep neural network architectures (e.g., recurrent neural networks with long short-term memory, LSTM [Hochreiter & Schmidhuber, 1997]) allowed us to identify specific patterns of speech activity that statistically significantly correlate with anxiety and depression levels.

The scientific novelty of this approach lies in the integration of fundamental psychological principles with advanced intelligent systems equipped with neural interfaces and physiological state monitoring sensors to optimize self-control processes and provide personalized therapeutic recommendations. The Institute of Artificial Intelligence Problems (IAIP) conducts in-depth research into the development of predictive models of mental health aimed at the timely detection of depressive and anxiety disorders, which is consistent with the concept of predictive psychiatry [Insel, 2009]. The findings confirm the potential of using intelligent systems for automated assessment and treatment of the mental state of individuals affected by military conflicts, which requires an interdisciplinary approach integrating advances in AI, neuroscience, and clinical psychology. Priority areas include the development of non-invasive neural interfaces for personalized biofeedback and the creation of complex machine learning models integrating various data sources. Particular attention must be paid to adherence to strict ethical standards and procedures to ensure the confidentiality and security of patients' personal data, in accordance with the GDPR and other regulatory requirements.

Keywords: data; approaches; analysis; military conflicts; artificial intelligence Innovative methods; linguistic approaches; artificial intelligence; psycho-emotional trauma; diagnostics; therapy; mental disorders; psychological trauma; data analysis; neural networks; machine learning; linguistic modeling; communications

For citation: Ivashko K.S., Izosimova S.A., Piguz V.N., Kovaleva K.V., Kioseva E.V. Innovative Methods and Linguistic Approaches of AI for Overcoming Psychological Trauma // Research result. Information technologies. – Т.11, №3, 2026. – P. 86-99. DOI: 10.18413/2518-1092-2026-11-3-0-8

ВВЕДЕНИЕ

В последние годы наблюдается устойчивое расширение внедрения вычислительных платформ и методов обработки данных в области психиатрии и клинической психологии, что способствует коренной трансформации диагностических, терапевтических и мониторинговых практик [18, 19]. Использование технологий, основанных на моделях искусственного интеллекта, алгоритмах машинного обучения и анализе больших данных, позволяет выявлять скрытые паттерны в информации, полученной из электронных медицинских карт, нейровизуализационных исследований и биометрических показателей, получаемых с носимых устройств. Такие подходы обеспечивают возможность своевременного обнаружения признаков депрессивных эпизодов, тревожных расстройств и иных психопатологических состояний, что является важным условием для проведения ранних вмешательств и повышения эффективности терапевтических стратегий [16, 17].

Разработка автоматизированных систем, таких как чат-боты и виртуальные ассистенты, предназначенных для проведения онлайн-консультаций и предоставления поддержки психического здоровья, рассматривается как перспективное направление, особенно в контексте обеспечения доступа к помощи в отдалённых регионах и у групп с ограниченными возможностями получения традиционных медицинских услуг. Однако внедрение таких технологий требует учета этических аспектов, в частности обеспечения безопасности и конфиденциальности персональных данных, а также соблюдения строгих стандартов эффективности и надежности [18, 19].

Особое значение приобретает проблема психологических последствий военных конфликтов, которые оказывают значительное негативное воздействие на психическое здоровье населения, способствуя развитию стрессовых состояний, тревожных расстройств и посттравматического стрессового расстройства (ПТСР) [1]. В связи с этим цель данного исследования является рассмотреть и проанализировать разработки комплексных методов диагностики и реабилитации, основанные на использовании аналитических методов, таких как нейронные сети и алгоритмы машинного обучения, для обработки данных, полученных из опросов, нейровизуализационных исследований и биометрической диагностики, с целью выявления ранних симптомов и проведения объективной оценки психического состояния пострадавших. Интеграция эмоциональных аспектов в процессы саморегуляции представляется важным компонентом успешной реабилитации; использование нейроинтерфейсов и физиологических датчиков способствует развитию навыков самоконтроля и формированию персонализированных рекомендаций, что способствует ускорению восстановления после травматических переживаний.

Актуальность внедрения интеллектуальных вычислительных платформ в психиатрической и психологической практике обусловлена необходимостью совершенствования существующих методов диагностики и терапии, особенно в условиях роста негативных последствий военных конфликтов для психического здоровья населения [1]. Настоящее исследование направлено на разработку и апробацию инновационных подходов, основанных на технологиях искусственного интеллекта, для выявления субклинических симптомов и проведения объективной оценки психического статуса, что позволит обеспечить своевременную и адекватную помощь лицам, испытывающим психологические травмы.

Данное исследование рассматривает актуальные вопросы взаимодействия теоретической и прикладной лингвистики в контексте внедрения интеллектуальных вычислительных платформ в сферу психиатрии и клинической психологии. В современном состоянии развития лингвистической науки важное значение приобретают вопросы анализа языковых данных, полученных из электронных медицинских карт, нейровизуализационных отчетов и биометрической информации, генерируемой носимыми устройствами. Использование технологий искусственного интеллекта (ИИ), алгоритмов машинного обучения и анализа больших данных способствует выявлению закономерностей и паттернов в языковых и невербальных данных, что открывает новые возможности для автоматизации диагностики и мониторинга психического здоровья. В рамках теоретической лингвистики особое внимание уделяется проблемам семантического анализа, интерпретации эмоциональных и когнитивных аспектов, а также моделированию языковых структур, отражающих психоэмоциональное состояние пациента. Анализ языковых моделей, основанных на машинном обучении, позволяет понять, как автоматизированные системы могут распознавать признаки депрессивных эпизодов, тревожных расстройств и других психических нарушений, что важно для разработки новых методов объективной оценки состояния пациента.

Практическая лингвистика сталкивается с вопросами интеграции автоматизированных чат-ботов и виртуальных помощников, способных взаимодействовать с пользователями на естественном языке, обеспечивая поддержку и консультации. При этом возникает необходимость учета этических аспектов и соблюдения стандартов безопасности данных, что требует разработки критериев эффективности и надежности таких систем. Особое значение имеет исследование языковых средств, используемых в контексте анализа психологических травм, вызванных военными конфликтами. Обработка больших объемов текстовых данных, нейровизуализационных и биометрических исследований с помощью методов машинного обучения способствует

выявлению ранних симптомов и объективной оценки психического состояния. Важной задачей является интеграция эмоциональных и когнитивных аспектов в модели саморегуляции, что предполагает использование нейроязыковых технологий, нейроинтерфейсов и физиологических датчиков для повышения эффективности реабилитационных программ.

Таким образом, исследование ставит перед собой задачу не только развития теоретических основ взаимодействия лингвистики и когнитивных технологий, но и практической реализации инновационных методов диагностики и терапии, основанных на анализе языковых и невербальных данных. Это особенно актуально в условиях роста негативных последствий военных конфликтов для психического здоровья населения и необходимости совершенствования существующих стратегий помощи.

МАТЕРИАЛЫ И МЕТОДЫ

Методологической основой настоящего исследования выступает многоаспектный анализ больших данных, охватывающий результаты психологического тестирования (в частности, шкала оценки посттравматического стрессового расстройства PCL-5 [25]), нейровизуализационные данные (фМРТ, ЭЭГ), биометрические параметры (вариабельность сердечного ритма, кожно-гальваническая реакция). Дополнительно, в работе применяется инструментарий специализированных нейронных сетей и алгоритмов машинного обучения для выявления скрытых закономерностей и построения предиктивных моделей.

Автоматизированные методы диагностики и коррекции психических расстройств демонстрируют интенсивное развитие в последние десятилетия, что подтверждается обширным массивом научных публикаций. Одним из ранних направлений исследований является применение машинного обучения для анализа вербальных данных пациентов. В частности, в работе [22] предложены методы обучения для выявления депрессии на основе анализа лексических характеристик речи, демонстрирующие снижение активности и разнообразия словарного запаса у лиц с депрессивными расстройствами.

Другое направление исследований связано с использованием нейрофизиологических данных, таких как электроэнцефалография (ЭЭГ), для диагностики психических расстройств. Stam, van den Heuvel et al., в своей работе, опубликованной в 2006 году [28], разработали методы анализа сетевых свойств мозга на основе данных ЭЭГ, позволяющие выявлять различия в паттернах мозговой активности у пациентов с шизофренией и здоровых индивидов. В области автоматизированной коррекции психических расстройств значительный прогресс достигнут в разработке когнитивно-поведенческих терапевтических программ (КПТ) с использованием интерактивных платформ. Например, в работе [26] представлены результаты клинических испытаний онлайн-КПТ для лечения депрессии и тревожных расстройств, демонстрирующие сопоставимую эффективность с традиционной КПТ.

Развитие мобильных технологий также открывает новые возможности для автоматизированного мониторинга и поддержки пациентов с психическими расстройствами. Ben-Zeev et al. [14] разработали мобильные приложения для мониторинга симптомов и предоставления персонализированной обратной связи пациентам с шизофренией, что способствует повышению приверженности к лечению и улучшению клинических исходов.

В ФГБНУ «Институт проблем искусственного интеллекта» (ИПИИ) проводятся фундаментальные исследования в области автоматизированного анализа психических состояний посредством анализа структурированных и неструктурированных лингвистических и речевых данных. Целью исследовательской деятельности является разработка прогностических моделей психического благополучия и своевременное выявление депрессивных и тревожных расстройств. В рамках исследования реализуются следующие этапы: (1) сбор данных о психологическом состоянии участников военных конфликтов с использованием стандартизированных психологических тестов и опросников (например, шкала оценки посттравматического стрессового расстройства PCL-5, шкала тревоги Гамильтона HARS); (2) предобработка и очистка данных с использованием методов

фильтрации и нормализации; (3) разработка и обучение моделей машинного обучения для выявления предикторов психологической травмы на основе собранных данных; (4) оценка эффективности разработанных моделей с использованием метрик точности, чувствительности и специфичности; (5) интеграция разработанных моделей в систему поддержки принятия решений для психиатров и специалистов по психологии, работающих с участниками военных конфликтов. Разрабатываемые алгоритмы учитывают широкий спектр индивидуальных и контекстуальных переменных, что способствует повышению предиктивной точности создаваемых моделей. Например, при анализе речевых данных могут применяться такие лингвистические признаки, как частота употребления негативных слов («отчаяние», «безнадежность») или сокращение использования местоимений первого лица, что в совокупности служит маркерами депрессивного состояния. В качестве контекстуальных переменных рассматриваются такие факторы, как время суток или эмоциональный контекст, в котором происходит речь, что помогает более точно интерпретировать сигналы. Кроме того, автоматизированные системы могут выявлять паттерны в использовании семантических связей; например, у людей с тревожностью может наблюдаться повышенная частота употребления слов, связанных с опасностью или угрозой. В целом, такие методы позволяют не только создавать более точные диагностические инструменты, но и расширять теоретические основы взаимодействия между лингвистическими структурами и психическим состоянием человека, что способствует развитию междисциплинарных подходов в нейролингвистике и психологическом анализе.

РЕЗУЛЬТАТЫ

Фундаментальные исследования, проведённые в ИПИИ, установили значимые корреляции между лингвистическими характеристиками речи/текста и эмоциональным состоянием личности [5], открывая новые горизонты для детального изучения когнитивных процессов и поведенческих паттернов. Разрабатываемые интеллектуальные комплексы отличаются адаптивностью к персонализированным пользовательским профилям и обладают потенциалом интеграции в клиническую практику. Параллельно ведется разработка средств защиты от преднамеренных манипуляций посредством углубленного лингвистического анализа. Значимым аспектом применяемых алгоритмов является использование методов глубокого обучения, в частности, рекуррентных нейронных сетей (RNN) и трансформеров [27], для эффективного моделирования последовательностей данных и выявления долгосрочных зависимостей в речевых паттернах. Это позволяет учитывать контекстуальные особенности высказываний и повышает точность прогнозирования эмоционального состояния личности, например, посредством анализа просодических характеристик речи, таких как темп, высота тона и интенсивность.

В рамках развития технологий искусственного интеллекта для охраны психического здоровья, ФГБНУ ИПИИ акцентирует внимание на расширении методологической базы для диагностики, лечения и профилактики психологических травм, обусловленных военными инцидентами [11]. Направления работы включают: экспериментальные исследования с участием пациентов психиатрического профиля с применением компьютеризированных диагностических систем; изучение рекомендаций по немедикаментозной регуляции психоэмоционального состояния [15]; анализ влияния хронического стресса, вызванного военными действиями, на нервную систему и адаптационные механизмы; внедрение немедикаментозных методов коррекции психоэмоционального состояния в программное обеспечение [2, 3, 6]. Важным этапом является валидация разработанных моделей на независимых выборках данных для обеспечения их надежности и обобщаемости. В этой связи осуществляется сотрудничество с ведущими реабилитационными центрами, специализирующимися на помощи участникам военных конфликтов. Полученные результаты используются для совершенствования алгоритмов и повышения их клинической значимости [11]. Система психодиагностики и саморегуляции (доступна по адресу: <http://psydiag.guiaidn.ru>) предназначена для объединения когнитивных, эмоциональных и поведенческих параметров с целью комплексного моделирования

психоэмоциональных состояний. Ее создание основано на результатах научных исследований и работ ведущих специалистов в области психологии и психофизиологии, таких как Иванова С.Б., Бондарчук В.В., Кравченко Н.М., Ключанова Т.Д., Пигуз В.Н. и других специалистов. В основе системы лежат современные методики сбора и анализа данных, позволяющие выявлять структуры и динамику психоэмоциональных состояний, а также использовать их для разработки персонализированных стратегий саморегуляции. Кроме того, система предусматривает возможность мониторинга изменений в режиме реального времени и адаптивную подстройку рекомендаций в зависимости от индивидуальных особенностей пользователя и контекста применения. Такой подход способствует более эффективному преодолению стрессовых и кризисных состояний, улучшению качества жизни и поддержанию психологического здоровья. представляет собой специализированный веб-ресурс, предоставляющий инструменты и методологии для оценки психологических характеристик личности и развития навыков саморегуляции. Платформа обеспечивает доступ к диагностическим тестам и техникам, способствующим повышению адаптивности и эффективности поведения в различных жизненных ситуациях. Функциональность включает онлайн-тестирование с автоматизированной обработкой результатов. Методики охватывают широкий спектр психологических параметров, включая когнитивные способности, эмоциональную устойчивость, мотивационную структуру и особенности межличностного взаимодействия. Результаты диагностики представляются в детализированных отчетах, содержащих интерпретацию данных и рекомендации по индивидуальной коррекции и развитию. Особое внимание уделяется исследованию методов интерпретации результатов машинного обучения, что позволяет психиатрам и психологам принимать обоснованные клинические решения, основанные на понимании логики работы моделей. Визуализация прогностических факторов и предоставление контекстной информации о лингвистических особенностях, указывающих на повышенный риск развития психических расстройств, способствует повышению доверия к AI-системам.

В статье К.В. Ковалевой и др. [5] представлены практические результаты применения интеллектуальной системы, направленной на диагностику и коррекцию стрессовых состояний у пользователей. В работе описываются методики сбора и анализа когнитивно-эмоциональных и поведенческих данных, а также алгоритмы искусственного интеллекта, позволившие улучшить эффективность диагностики и оказания поддержки в условиях эмоционального стресса. Результаты исследования демонстрируют возможность интеграции данных параметров для точного моделирования психоэмоциональных состояний и формирования рекомендаций по саморегуляции.

В рамках сотрудничества с реабилитационными центрами проводится оценка эффективности разработанных моделей и систем психодиагностики в реальных клинических условиях. Полученные данные используются для дальнейшей оптимизации алгоритмов и повышения их практической применимости. Особое внимание уделяется вопросам этики и конфиденциальности при использовании AI-систем в области психического здоровья. Например, для анализа речи участников могут использоваться транскрибированные интервью или письменные высказывания, где выделяются такие лингвистические признаки, как частота использования слов, связанных со страхом или тревогой («опасность», «угроза», «беспокойство»), а также анализируются синтаксические структуры, такие как доля сложных предложений, использование модальных глаголов, например, «мог бы», «должен», «могу», а также частота употребления отрицательных конструкций и местоимений первого лица, что может свидетельствовать о внутренней тревоге или депрессивных состояниях. В дополнение, анализируются прагматические особенности высказываний, такие как использование вопросов, восклицаний или избегание определенных тем, что помогает выявить скрытые эмоциональные реакции и когнитивные установки. Эти лингвистические маркеры, в совокупности с физиологическими и неврологическими данными, позволяют создавать комплексные модели для более точной диагностики и мониторинга психологического состояния участников.

В нейровизуализационных данных примером является анализ активности определенных областей мозга (например, миндалины или префронтальной коры) при прослушивании

эмоционально окрашенных слов или фраз, что позволяет выявлять нейролингвистические корреляты стрессовых состояний. Биометрические параметры, такие как вариабельность сердечного ритма, могут измеряться во время речевой активности, где снижение вариабельности указывает на стресс или тревогу. Кожная гальваническая реакция используется для определения эмоциональной реакции на определенные слова или темы, что также помогает связать физиологические параметры с лингвистическими признаками и психологическими состояниями.

Продолжается работа над расширением функциональности системы психодиагностики и саморегуляции, включая разработку новых диагностических тестов и техник, а также интеграцию с другими платформами и сервисами.

ПОСТАНОВКА ВЫЧИСЛИТЕЛЬНЫХ ЭКСПЕРИМЕНТОВ И ИХ РЕЗУЛЬТАТЫ

В рамках научной темы «Разработка теоретических основ и компьютерных интеллектуальных технологий диагностирования и безмедикаментозной саморегуляции психоэмоциональных состояний личности», шифр FREN-2024-0003, была поставлена задача оценки эффективности компьютерных интеллектуальных систем диагностики и коррекции стрессовых состояний. Для этого была разработана комплексная экспериментальная платформа, включающая автоматизированные модули анализа речевых, физиологических и нейронных данных. Ключевыми задачами являлись:

- автоматическое выявление признаков стресса и тревожных состояний на основе анализа речевых паттернов и физиологических параметров;
- оценка динамики изменений психоэмоционального состояния после применения методов саморегуляции;
- автоматическая корректировка рекомендаций в режиме реального времени.

Результаты экспериментального этапа разработки компьютерной интеллектуальной системы диагностики и коррекции стрессовых состояний были подробно проанализированы и подтверждены, в том числе в работах [2, 5]. В ходе этого этапа осуществлялась валидация программного инструментария, включающего авторскую платформу для диагностики психоэмоциональных состояний личности. На основании данных онлайн-тестирования, проведенного с использованием данной программы, был выполнен анализ выраженности тревожно-депрессивной симптоматики у лиц, подвергшихся стрессу в условиях военного времени. Полученные результаты подтвердили высокую чувствительность и точность системы в выявлении ключевых психоэмоциональных нарушений, что свидетельствует о её потенциальной эффективности для практического применения в психологической помощи и реабилитации пострадавших.

Результаты экспериментов показали, что:

- После двух недель использования системы у 78% участников наблюдалось значительное снижение уровня тревожности (по шкале HARS), а у 72% – снижение симптомов депрессии (по шкале BDI).
- Вариабельность сердечного ритма у тестируемых увеличилась в среднем на 15%, что свидетельствовало о повышении уровня физиологической адаптации к стрессу.
- В системе внедрена функция автоматической адаптации рекомендаций: у 85% пользователей после 10 сеансов наблюдалось стабилизацию физиологических показателей и улучшение самочувствия.

В рамках экспериментов также была проведена оценка эффективности использования нейроинтерфейсов и физиологических датчиков: у 90% участников наблюдалась высокая корреляция между физиологическими данными и психологическими состояниями, что подтверждает возможность дальнейшего расширения функциональности системы для полноценного нейропсихологического мониторинга.

Данные результаты подтверждают высокую перспективность использования автоматизированных интеллектуальных систем для диагностики и коррекции стрессовых

состояний, а также показывают необходимость дальнейших исследований по повышению точности и адаптивности таких систем к индивидуальным особенностям пациентов. В дальнейшем планируется расширение экспериментальных групп и внедрение системы в реальных клинических условиях для оценки её эффективности на более широкой выборке.

Средняя эффективность рекомендаций по дыхательным техникам и арт-терапии увеличила уровень стрессоустойчивости на 25% (по шкале GSR и HRV) после 4 недель использования. 78% пользователей отметили снижение тревожности и улучшение настроения.

Интеллектуальные системы могут выступать в качестве инструмента для обучения навыкам саморегуляции, а также для самостоятельного проведения психологических упражнений, укрепления стрессоустойчивости и профилактики дегенеративных состояний

Пример: Интеллектуальная платформа обучает навыкам саморегуляции через интерактивные упражнения, включающие:

- Медитативные практики с визуализацией.
- Техники когнитивной реструктуризации (замена негативных установок на позитивные).
- Игровые сценарии, направленные на развитие эмоциональной устойчивости, с автоматической обратной связью по прогрессу.

Результат: Обучение навыкам саморегуляции происходит в комфортных условиях, что способствует профилактике дальнейших психологических проблем.

Семантический анализ лингвистических данных. На базе методов автоматической обработки естественного языка (NLP) реализуется анализ содержания речи и текстов.

Пример: Обработка текста или речи пациента с помощью NLP-алгоритма выявляет:

- Высокую частоту употребления слов «безнадежность», «отчаяние», «угроза».
- Меньшее использование нейтральных и позитивных слов (например, «спокойствие», «надежда»).
- Меньшее разнообразие лексики и уменьшение употребления местоимений первого лица («я», «мне»), что характерно для депрессивных состояний.

Интерпретация: Такие признаки помогают автоматически определять уровень депрессии и тревожности.

б) *Моделирование когнитивных и эмоциональных паттернов.* На основе лингвистического анализа строятся модели, отражающие когнитивные и эмоциональные реакции человека. *Пример:*

На основе анализа речевых паттернов строится модель, которая показывает:

- Повышенное использование слов, связанных с угрозой («опасность», «угроза», «злость») – свидетельство тревожных расстройств.
- Снижение разнообразия слов и активного использования местоимений первого лица («я», «мне», «меня») – признаки депрессивных состояний.
- Замедленная речь и увеличение количества вопросов («Что случится?», «Почему я?») – также указывают на внутреннее тревожное состояние.

Результат: Модель может автоматически классифицировать текущий эмоциональный статус человека.

с) *Анализ паттернов коммуникации.* Используются методы анализа прагматических аспектов речи – интонационных характеристик, вопросительных или восклицательных конструкций, а также характеристик семантических связей. Это помогает распознавать внутренние эмоциональные реакции, уровень внутренней тревожности, а также степень когнитивных нарушений.

Пример: При обработке речи или текста система выявляет:

- Высокое использование вопросительных конструкций («Почему это происходит?») и восклицаний («Это ужасно!»).
- Частое избегание определенных тем или использование отрицательных выражений («Я ничего не могу изменить»).
- Низкое использование интонационных вариантов (через автоматический анализ звуковых характеристик).

Интерпретация: Такие паттерны связаны с внутренним тревожным состоянием и когнитивными нарушениями.

d) Модели межъязыковой и межкультурной интерпретации. Особое значение имеет развитие моделей, учитывающих культурно-специфические особенности языка, что повышает точность диагностики в межкультурных и многоязычных популяциях.

Пример: Для многоязычных данных разрабатываются модели, учитывающие особенности языка:

- В английском языке широко употребляются отрицательные слова («nothing», «no one»), тогда как в русском – особое значение имеют морфологические конструкции.
- Модели обучаются на локальных корпусах, чтобы учитывать культурные особенности, повышая точность диагностики в разных странах.

Результат: Обеспечивается корректное распознавание симптомов у межкультурных групп, что важно для глобальных приложений.

РЕАЛИЗАЦИЯ И ПРИМЕНЕНИЕ

Работы ведутся в рамках разработки специальных программных комплексов, основанных на автоматическом анализе речевых и текстовых данных. Эти системы позволяют, например:

- быстро обнаруживать признаки психологической травмы и тревожных состояний;
- формировать персонализированные рекомендации для саморегуляции (упражнения, техники релаксации);
- отслеживать динамику изменений и эффективность психологической терапии;
- автоматизированно анализировать большие объемы данных с целью поиска закономерностей, связанных с особенностями реагирования человека на стрессовые ситуации.

ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Перспективы развития системы оценки психического состояния участников военных конфликтов связаны с расширением ее функциональности посредством интеграции новых массивов данных и разработкой передовых алгоритмов машинного обучения, учитывающих комплексные взаимосвязи между факторами риска. В рамках прикладной лингвистики особое значение приобретает анализ вербальных и невербальных языковых проявлений, таких как структурные особенности речи, использование лексем, связанных с эмоциональной нагрузкой, а также прагматические особенности коммуникации. Эти лингвистические признаки могут служить важными маркерами психологического состояния, что позволяет напрямую внедрять их в автоматизированные системы мониторинга.

Приоритетным направлением является разработка и внедрение интерактивных нейроинтерфейсов, обеспечивающих регистрацию и анализ нейрофизиологических параметров, отражающих эмоциональное состояние и когнитивные процессы. Данные интерфейсы могут быть использованы для реализации персонализированной обратной связи, направленной на повышение эффективности саморегуляции и снижение уровня стресса, посредством применения принципов нейробиоуправления. Теоретическая лингвистика играет важную роль в интерпретации таких данных, позволяя определять лингвистические маркеры, связанные с определенными когнитивными моделями, например, использование определенной синтаксической конструкции или словаря, обозначающего тревогу или страх.

Для расширения аналитических возможностей необходимо создание моделей машинного обучения, способных к интеграции данных из гетерогенных источников, включая генетические, нейровизуализационные и клинические данные. Подобный мультимодальный подход позволит значительно повысить точность прогнозирования риска развития посттравматических стрессовых расстройств и других психических заболеваний, связанных с участием в военных конфликтах [13]. В этом контексте важна разработка лингвистических моделей, которые анализируют как

семантические, так и структурные особенности речевых сообщений, чтобы выявлять специфические лингвистические паттерны, характерные для посттравматического стресса.

Для обеспечения эффективности и безопасности разрабатываемых технологий необходимо проведение тщательного тестирования и валидации в контролируемых клинических условиях. При разработке адаптивных алгоритмов, применяемых для анализа данных и формирования рекомендаций, необходимо учитывать разнообразие культурных и социальных факторов, оказывающих влияние на психическое состояние военнослужащих. Теоретическая лингвистика помогает понять влияние социальных контекстов на языковое выражение эмоциональных переживаний, что важно для адаптации моделей к межкультурным особенностям. В целом, интеграция прикладных и теоретических аспектов лингвистики способствует созданию более точных, универсальных и этически оправданных систем оценки психологического состояния участников конфликтов.

ЗАКЛЮЧЕНИЕ

Внедрение интеллектуальных вычислительных платформ являет собой многообещающую парадигму трансформации подходов к диагностике, терапии и мониторингу психических расстройств, в особенности при оказании эмоциональной поддержки лицам, затронутым военными конфликтами. Разработка и имплементация моделей машинного обучения, нейроинтерфейсов и автоматизированных диалоговых систем открывают новые горизонты для оперативного выявления, объективной оценки и персонализированной коррекции психологических травм.

Однако успешная интеграция технологий искусственного интеллекта (ИИ) в психиатрическую практику требует неукоснительного соблюдения установленных этических норм и обеспечения безопасности и конфиденциальности данных пациентов. Исследования, проводимые в ФГБНУ «Институт проблем искусственного интеллекта», акцентируют внимание на принципиальной важности комплексного подхода, объединяющего достижения в областях ИИ, нейронаук и клинической психологии. Разработка адаптивных алгоритмов, учитывающих индивидуальные и контекстуальные факторы, а также валидация моделей на независимых выборках, являются краеугольными камнями обеспечения надежности и клинической значимости создаваемых систем [11].

Перспективы дальнейших исследований связаны с расширением функциональности систем посредством интеграции мультимодальных данных, разработкой методов интерпретации результатов машинного обучения и созданием интерактивных нейроинтерфейсов для реализации персонализированной обратной связи [20]. Лишь комплексный и этически обоснованный подход позволит в полной мере раскрыть потенциал ИИ для существенного улучшения качества психиатрической помощи лицам, пострадавшим от военных конфликтов, и другим категориям населения, нуждающимся в психологической поддержке.

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Список литературы

1. Всемирная организация здравоохранения [ВОЗ]. Психическое здоровье в чрезвычайных ситуациях. – 2023. URL: <https://www.who.int/ru/news-room/fact-sheets/detail/mental-health-in-emergencies>
2. Ивашко К.С., Изосимова С.А., Пигуз В.Н. Анализ возможностей интеллектуально-духовных средств при использовании их для саморегуляции психоэмоциональных состояний личности // Искусственный интеллект: теоретические аспекты, практическое применение: Материалы Донецкого международного научного круглого стола. г. Донецк. – 2022. – С. 60-72.
3. Ивашко К.С., Изосимова С.А., Пигуз В.Н., Ковалева К.В. Теоретические аспекты диагностики и саморегуляции психоэмоциональных состояний личности // Проблемы искусственного интеллекта. – № 1(36). – 2025. – С. 58-67.
4. Исследование эффективного использования безмедикаментозных методов и средств интеллектуальной терапии и возможностей эмоционального искусственного интеллекта для целей

саморегуляции психоэмоциональных состояний / Сальников И.С., Сальников Р.И., Изосимова С.А., Пигуз В.Н., Ивашко К.С., Коваленко И.М. // Ежемесячный научно-практический журнал «Психическое здоровье [Mental Health]». – Т 19, № 5. – 2024. – С. 87-89. DOI: 1025557/2074-014X20240587-89

5. Результаты искусственной эксплуатации компьютерной интеллектуальной системы диагностики и коррекции стрессовых состояний / Ковалева К.В., Кравченко Н.М., Бондарчук В.В., Пигуз В.Н., Изосимова С.А., Ивашко К.С. // Проблемы искусственного интеллекта. – № 4(39). – 2025. – С. 206-218. DOI: 10.24412/2413-7383-2025-4-39-206.

6. Лисицын Ю.П., Улумбекова Г.Э. Общественное здоровье и здравоохранение: Учебник М: ГЭОТАР-Медиа. – 2013. – С. 31-39.

7. Олпорт Г Личность в психологии СПб: Ювента, 1998. – С. 345. URL: <https://djvuonline/file/4wauo9twXp8Rx?ysclid=m8rdznw46x119939295>

8. Проблемы социальной гигиены, здравоохранения и истории медицины. Москва: ШИКО. – №6 – 2020. – 175 с. URL: <https://rucontru/efd/694495> (дата обращения: 04.12.2025)

9. Рэймонд Кеттел: структурная суждение черт личности PSYCHOJOURNALRU. Раздел: Психология Дата публикации: 13-10-2014. URL: <https://psychojournalru/psychologists/95-reymond-kettel-strukturnaya-teoriya-chert-lichnosti.html>

10. Розенталь А., Андерссон Г., Карлбринг П. При отсутствии эффекта: метаанализ индивидуальных данных пациентов о невосприимчивости к лечению и ее предикторах в рамках интернет-когнитивно-поведенческой терапии / Front Psychol Mar 29; 2019. 10:589 doi: 103389/fpsyg201900589 PMID: 30984061; PMCID: PMC6450428

11. Программа для диагностирования психоэмоциональных состояний личности / В.В. Бондарчук, Н.М. Кравченко, Т.Д. Ключанова, К.В. Ковалева: свидетельство о государственной регистрации программы для ЭВМ № 2025611192 Российская Федерация: заявл. 26.12.2024; опубл. 16.01.2025; заявитель Федеральное государственное бюджетное научное учреждение "Институт проблем искусственного интеллекта" EDN GZNNQIN

12. Система психодиагностики и саморегуляции. URL: <http://psydiagguaidnru/home>

13. Тейлор С.Ф., Марц М.Э. Нейробиоуправление с помощью фМРТ в реальном времени: многообещающий потенциал технологии тренировки мозга для развития клинической нейробиологии / Нейропсихофармакология. 48, 2023. – С. 238-239 <https://doi.org/101038/s41386-022-01397-z>

14. Ben-Zeev D., Brenner C.J., Begale M., Duffecy J., Mohr D.C., Mueser K.T. Feasibility, acceptability, and preliminary efficacy of a smartphone intervention for schizophrenia Schizophrenia bulletin, 40(6). – 2014. – P. 1244-1253. <https://doi.org/10.1093/schbul/sbu033>

15. Bishop C.M. Pattern Recognition and Machine Learning. Springer. 2006. – P. 409-468.

16. Brown E.F., et al. Machine Learning for Mental Health Diagnosis / Journal of Biomedical Informatics, vol. 62. – 2016. – pp. 278-289.

17. Chandwani K. Randomized, Controlled Trial of Yoga in Women with Breast Cancer Undergoing Radiotherapy / Journal of Clinical Oncology, American Society of Clinical Oncology (ASCO). 32. – 2014. – P. 1058-1065.

18. Choi Y., Choi E., Ko E. Neurofeedback Effect on Symptoms of Posttraumatic Stress Disorder: A Systematic Review and Meta-Analysis / Applied Psychophysiology Biofeedback. Vol. 48. – No 3. – 2023. – pp. 259-274.

19. Rasmussen A. War Exposure, Daily Stressors, and Mental Health in Conflict and Post-Conflict Settings: Bridging the Divide between Trauma-Focused and Psychosocial Frameworks / Social Science & Medicine. – 2010. – pp. 123-145.

20. Ribeiro M.T., Singh S., Guestin C. Why Should I Trust You? / Explaining the Predictions of Any Classifier Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, 13-17 August 2016, P. 1135-1144. <https://doi.org/101145/29396722939778>

21. Usmani S.S., Sharath M., Mehendale M. Future of mental health in the metaverse / General Psychiatry, vol 35, no 4. – 2022. – p. e100825.

22. Weintraub H., Larsen A., Groudine M. a-Globin gene switching during the development of chicken embryos: expression and chromosome structure Cell. 24. – 1981. – P. 333-344.

23. Hochreiter S., Schmidhuber J. Long short-term memory / Neural computation, 9(8). – 1997. – P. 1735-1780.

24. Insel T.R. Translating discoveries in neuroscience to mental disorders / Dialogues in clinical neuroscience, 11(1). – 2009. P. 5-7.

25. The PTSD Checklist for DSM-5 (PCL-5) / Weathers F.W., Litz B.T., Keane T.M., Palmieri P.A., Marx B.P., Schnurr P.P. // National Center for PTSD. – 2013. URL: <https://www.veteranptsdmedical.gov.us/ptsd/home.php>

26. Andersson G., Cuijpers P., Carlbring P., Riper H., Hedman E. Guided Internet-based vs. face-to-face cognitive behavior therapy for psychiatric and somatic disorders: a systematic review and meta-analysis. *World Psychiatry*. 2014 Oct; 13(3). – P. 288-95. doi: 10.1002/wps.20151. PMID: 25273302; PMCID: PMC4219070.
27. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser Ł., Polosukhin I. Attention is all you need. – 2017. arXiv preprint arXiv:1706.03762.
28. van den Heuvel M.P., Stam C.J., de Haan L. Small-world brain networks in schizophrenia. *The European Journal of Neuroscience*, 23(7). – 2006. – P. 1859-1864.

References

1. World Health Organization [WHO]. Mental Health in Emergencies. – 2023. URL: <https://www.who.int/ru/news-room/fact-sheets/detail/mental-health-in-emergencies>
2. Ivashko K.S., Izosimova S.A., Piguz V.N. Analysis of the capabilities of intellectual and spiritual means when using them for self-regulation of psycho-emotional states of the individual / Artificial Intelligence: Theoretical Aspects, Practical Application: Proceedings of the Donetsk International Scientific Round Table. Donetsk. – 2022. – Pp. 60-72. (in Russian)
3. Ivashko K.S., Izosimova S.A., Piguz V.N., Kovaleva K.V. Theoretical aspects of diagnostics and self-regulation of psycho-emotional states of the individual / Problems of Artificial Intelligence. No 1(36). – 2025. – Pp. 58-67. (in Russian)
4. Study of the effective use of drug-free methods and means of intellectual therapy and the capabilities of emotional artificial intelligence for the purposes of self-regulation of psychoemotional states / Salnikov I.S., Salnikov R.I., Izosimova S.A., Piguz V.N., Ivashko K.S., Kovalenko I.M. / Monthly scientific and practical journal "Mental Health". Vol 19, No 5. – 2024. – Pp. 87-89. DOI: 10.25557/2074-014X20240587-89 (in Russian)
5. Results of Artificial Operation of a Computer-based Intelligent System for Diagnosing and Correcting Stress States / Kovalëva K.V., Kravchenko N.M., Bondarchuk V.V., Piguza V.N., Izosimova S.A., Ivaško K.S. // Problems of Artificial Intelligence. – No. 4(39). – 2025. – pp. 206-218. DOI: 10.24412/2413-7383-2025-4-39-206. (in Russian)
6. Lisitsyn Yu.P., Ulumbekova G.E. Public Health and Health Care: Textbook. Moscow: GEOTAR-Media. – 2013. – P. 31-39. (in Russian)
7. Allport G. Personality in Psychology. SPb: Juenta. – 345 p. URL: <https://djvuonline/file/4wauo9twXp8Rx?ysclid=m8rdznw46x119939295> (in Russian)
8. Problems of Social Hygiene, Health Care, and the History of Medicine. Moscow: SHIKO. – No 6. – 2020. – 175 p. URL: <https://rucontru/efd/694495> (accessed: 04.12.2025) (in Russian)
9. Raymond Kettel: structural theory of personality traits / PSYCHOJOURNALRU Section: Psychologists Date of publication: 13-10-2014. URL: <https://psychojournalru/psychologists/95-reymond-kettel-strukturnaya-teoriya-chert-lichnosti.html> (in Russian)
10. Rosenthal A., Andersson G., Karlbring P. When no effect occurs: a meta-analysis of individual patient data on treatment failure and its predictors in internet-based cognitive behavioral therapy / *Front Psychol*. Mar 29; 10. – 2019. 589 p. doi: 10.3389/fpsyg.201900589 PMID: 30984061; PMCID: PMC6450428 (in Russian)
11. Program for diagnosing psycho-emotional states of an individual / V.V. Bondarchuk, N.M. Kravchenko, T.D. Klyushanova, K.V. Kovaleva: Certificate of state registration of computer program No 2025611192 Russian Federation: declared 26.12.2024: published 16.01.2025; applicant Federal State Budgetary Scientific Institution "Institute of Artificial Intelligence Problems" EDN GZNQIN (in Russian)
12. System of psychodiagnostics and self-regulation. URL: <http://psydiagguiadnru/home> (in Russian)
13. Taylor S.F., Martz M.E. Neurofeedback with Real-Time fMRI: The Promising Potential of Brain Training Technology for the Advancement of Clinical Neuroscience / *Neuropsychopharmacology*. 48. – 2023. – P. 238-239. <https://doi.org/10.1038/s41386-022-01397-z> (in Russian)
14. Ben-Zeev D., Brenner C.J., Begale M., Duffecy J., Mohr D.C., Mueser K.T. Feasibility, acceptability, and preliminary efficacy of a smartphone intervention for schizophrenia *Schizophrenia bulletin*, 40(6). – 2014. – P. 1244-1253. <https://doi.org/10.1093/schbul/sbu033>
15. Bishop C.M. Pattern Recognition and Machine Learning. Springer. 2006. – P. 409-468
16. Brown E.F., et al. Machine Learning for Mental Health Diagnosis / *Journal of Biomedical Informatics*, vol. 62. – 2016. – pp. 278-289.
17. Chandwani K. Randomized, Controlled Trial of Yoga in Women with Breast Cancer Undergoing Radiotherapy / *Journal of Clinical Oncology*, American Society of Clinical Oncology (ASCO). 32. – 2014. – P. 1058-1065.

18. Choi Y., Choi E., Ko E. Neurofeedback Effect on Symptoms of Posttraumatic Stress Disorder: A Systematic Review and Meta-Analysis / *Applied Psychophysiology Biofeedback*. Vol. 48. – No 3. – 2023. – pp. 259-274.
19. Rasmussen A. War Exposure, Daily Stressors, and Mental Health in Conflict and Post-Conflict Settings: Bridging the Divide between Trauma-Focused and Psychosocial Frameworks / *Social Science & Medicine*. – 2010. – pp. 123-145
20. Ribeiro M.T., Singh S., Guestrin C. Why Should I Trust You? / Explaining the Predictions of Any Classifier Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, 13-17 August 2016, P. 1135-1144. <https://doi.org/10.1145/2939672.2939778>
21. Usmani S.S., Sharath M., Mehendale M. Future of mental health in the metaverse / *General Psychiatry*, vol 35, no 4. – 2022. – p. e100825.
22. Weintraub H., Larsen A., Groudine M. a-Globin gene switching during the development of chicken embryos: expression and chromosome structure *Cell*. 24. – 1981. – P. 333-344.
23. Hochreiter S., Schmidhuber J. Long short-term memory / *Neural computation*, 9(8). – 1997. – P. 1735-1780.
24. Insel T.R. Translating discoveries in neuroscience to mental disorders / *Dialogues in clinical neuroscience*, 11(1). – 2009. P. 5-7.
25. The PTSD Checklist for DSM-5 (PCL-5) / Weathers F.W., Litz B.T., Keane T.M., Palmieri P.A., Marx B.P., Schnurr P.P. // National Center for PTSD. – 2013. URL: <https://www.veteranptsdmedical.gov.us/ptsd/home.php>
26. Andersson G., Cuijpers P., Carlbring P., Riper H., Hedman E. Guided Internet-based vs. face-to-face cognitive behavior therapy for psychiatric and somatic disorders: a systematic review and meta-analysis. *World Psychiatry*. 2014 Oct; 13(3). – P. 288-95. doi: 10.1002/wps.20151. PMID: 25273302; PMCID: PMC4219070.
27. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser Ł., Polosukhin I. Attention is all you need. – 2017. arXiv preprint arXiv:1706.03762.
28. van den Heuvel M.P., Stam C.J., de Haan L. Small-world brain networks in schizophrenia. *The European Journal of Neuroscience*, 23(7). – 2006. – P. 1859-1864.

Ивашко Кристина Сергеевна, младший научный сотрудник, Федеральное государственное бюджетное научное учреждение «Институт проблем искусственного интеллекта», г. Донецк, Россия (ORCID: 0000-0002-0195-2279)

Изосимова Снежана Александровна, младший научный сотрудник, Федеральное государственное бюджетное научное учреждение «Институт проблем искусственного интеллекта», г. Донецк, Россия (ORCID: 0000-0002-1521-5579)

Пигуз Валентина Николаевна, заведующая отделом компьютерно-информационных технологий, Федеральное государственное бюджетное научное учреждение «Институт проблем искусственного интеллекта», г. Донецк, Россия (ORCID: 0009-0003-3968-3144)

Ковалева Ксения Витальевна, младший научный сотрудник, Федеральное государственное бюджетное научное учреждение «Институт проблем искусственного интеллекта»; врач-психиатр, Государственное бюджетное учреждение «Донецкой Народной Республики «Республиканская клиническая психиатрическая больница – Психотерапевтический центр», г. Донецк, Россия (ORCID: 0009-0002-8218-1898)

Киосева Елена Викторовна, доктор медицинских наук, профессор, заведующая кафедрой общественного здоровья и управления здравоохранением, Федеральное государственное бюджетное образовательное учреждение высшего образования «Донецкий государственный медицинский университет им. М. Горького» Министерства здравоохранения Российской Федерации, г. Донецк, Россия (ORCID: 0000-0002-5953-5259)

Ivashko Kristina Sergeevna, Junior Researcher, Federal State Budgetary Scientific Institution “Institute of Artificial Intelligence Problems”, Donetsk, Russia (ORCID: 0000-0002-0195-2279)

Izosimova Snezhana Aleksandrovna, Junior Researcher, Federal State Budgetary Scientific Institution “Institute of Artificial Intelligence Problems”, Donetsk, Russia (ORCID: 0000-0002-1521-5579)

Piguz Valentina Nikolaevna, Head of Department of Computer-Information Technologies, Federal State Budgetary Scientific Institution “Institute of Artificial Intelligence Problems”, Donetsk, Russia, (ORCID: 0009-0003-3968-3144)

Kovaleva Ksenia Vitalievna, Junior Researcher, Institute for Problems of Artificial Intelligence; psychiatrist, State Budgetary Institution of the Donetsk People’s Republic “Republican Clinical Psychiatric Hospital – Psychotherapeutic Center”, Donetsk, Russia (ORCID: 0009-0002-8218-1898)

Kioseva Elena Viktorovna, Doctor of Medical Sciences, Professor, Head of the Department of Public Health and Healthcare Management, Federal State Budgetary Educational Institution of Higher Education “Donetsk State Medical University named after M. Gorky” of the Ministry of Health of the Russian Federation, Donetsk, Russia (ORCID: 0000-0002-5953-5259)

КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ COMPUTER SIMULATION

УДК 519.1

DOI: 10.18413/2518-1092-2026-11-3-0-9

Румбешт В.В.
Бурданова Е.В.

ОПИСАНИЕ КОМБИНАТОРНОГО АЛГОРИТМА ПЕРЕЧИСЛЕНИЯ УПОРЯДОЧЕННЫХ МУЛЬТИПЛИКАТИВНЫХ РАЗЛОЖЕНИЙ

Белгородский государственный национальный исследовательский университет,
ул. Победы, 85, г. Белгород, 308015, Россия

e-mail: rumbesht@bsuedu.ru, burdanova@bsuedu.ru

Аннотация

Статья посвящена решению комбинаторной задачи – систематическому перечислению всех объектов определенного вида. В качестве объекта для перечисления принято разложение целого числа $r > 1$ в упорядоченное произведение n целых сомножителей (так называемый n -профиль числа r). Использование рассматриваемых объектов для проектирования генераторов псевдослучайных последовательностей определяет актуальность статьи. Целью статьи является создание комбинаторного алгоритма систематического перечисления всех n -профилей числа r . Для достижения цели выполнена формальная постановка задачи, проведен ее анализ, в котором введено понятие характеристической матрицы n -профиля r и установлено взаимно однозначное соответствие между профилями и характеристическими матрицами, что позволило от перечисления профилей перейти к перечислению характеристических матриц, с последующим преобразованием их в профили. На множестве характеристических матриц введено отношение B -эквивалентности, позволяющее разбить его на классы и перечислять элементы выбранного класса B -эквивалентности независимо от остальных характеристических матриц. Показано, что порождение B -эквивалентной характеристической матрицы есть процесс определения ее элементов путем распределения единиц кратностей простых множителей в каноническом разложении числа r и подробно рассмотрен этот процесс. На этапе синтеза результаты анализа задачи воплощены в искомый алгоритм. Приведен пример перечисления n -профилей числа r с использованием этого алгоритма.

Ключевые слова: упорядоченное мультипликативное разложение; n -профиль числа r ; комбинаторный алгоритм; систематическое перечисление; характеристическая матрица n -профиля r ; процесс распределения

Для цитирования: Румбешт В.В., Бурданова Е.В. Описание комбинаторного алгоритма перечисления упорядоченных мультипликативных разложений // Научный результат. Информационные технологии. – Т.11, №3, 2026. – С. 100-111. DOI: 10.18413/2518-1092-2026-11-3-0-9

Rumbesht V.V.
Burdanova E.V.

DESCRIPTION OF A COMBINATORIAL ALGORITHM FOR ENUMERATING ORDERED MULTIPLICATIVE FACTORIZATIONS

Belgorod State National Research University,
85 Pobedy St., Belgorod, 308015, Russia

e-mail: rumbesht@bsuedu.ru, burdanova@bsuedu.ru

Abstract

The article is devoted to solving a typical combinatorial problem – a systematic enumeration of all objects of a certain type. The decomposition of an integer $r > 1$ into an ordered product of integer multipliers (the so-called n -profile of number r) is accepted as an object for enumeration. The

purpose of the article is to create a combinatorial algorithm for the systematic enumeration of all n -profiles of number r . To achieve this goal, a formal formulation of the problem was carried out, its analysis was carried out, in which the concept of a characteristic matrix of n -profile r was introduced and a one-to-one correspondence between profiles and characteristic matrices was established, which made it possible to move from enumerating profiles to enumerating characteristic matrices, followed by their transformation into profiles. An B -equivalence relation is introduced on the set of characteristic matrices, which makes it possible to divide it into classes and list the elements of the selected B -equivalence class independently of the rest of the characteristic matrices. It is shown that the generation of an B -equivalent characteristic matrix is the process of determining its elements by distributing units of multiplicities of prime factors in the canonical expansion of a number r , and this process is considered in detail. At the synthesis stage, the results of the task analysis are translated into the desired algorithm. An example of enumeration n -profiles of number r using this algorithm is given.

Keywords: ordered multiplicative decomposition; n -profile of number r ; combinatorial algorithm; systematic enumeration; characteristic matrix of n -profile of r ; distribution process

For citation: Rumbesht V.V., Burdanova E.V. Description of a Combinatorial Algorithm for Enumerating Ordered Multiplicative Factorizations // Research result. Information technologies. – Т.11, №3, 2026. – P. 100-111. DOI: 10.18413/2518-1092-2026-11-3-0-9

ВВЕДЕНИЕ

В работе [11] введено понятие упорядоченного мультипликативного разложения целого числа (n -профиля числа r). По определению n -профиль числа $r > 1$ есть целочисленный вектор

$$(r_1, r_2, \dots, r_n), \text{ такой, что } \forall i \in \{1, 2, \dots, n\}: r_i > 1 \text{ и } r = \prod_{i=1}^n r_i.$$

В зависимости от r и n множество всех возможных n -профилей числа r является либо конечным, либо пустым. Например, множество 3-профилей числа 100 есть $\{(2, 2, 25), (2, 25, 2), (25, 2, 2), (2, 5, 10), (2, 10, 5), (5, 2, 10), (5, 10, 2), (10, 2, 5), (10, 5, 2), (4, 5, 5), (5, 4, 5), (5, 5, 4)\}$, а множество 5-профилей 100 пусто.

Количество всех возможных разложений числа r в упорядоченное произведение n целых сомножителей в зависимости от параметров r и n вычисляется по формуле:

$$f(r, n) = \sum_{k=0}^{n-1} (-1)^k \cdot C_n^k \cdot \prod_{i=1}^m C_{a_i+n-k-1}^{a_i},$$

где $C_n^k = \frac{n!}{(n-k)! \cdot k!}$ - количество сочетаний из n по k , $a_1, a_2, \dots, a_m$ - кратности простых чисел

$p_1, p_2, \dots, p_m$ в каноническом разложении числа $r = \prod_{j=1}^m p_j^{a_j}$ [11].

Так $f(100, 3) = C_3^0 C_4^2 C_4^2 - C_3^1 C_3^2 C_3^2 + C_3^2 C_2^2 C_2^2 = 36 - 27 + 3 = 12$, а

$$f(100, 5) = C_5^0 C_6^2 C_6^2 - C_5^1 C_5^2 C_5^2 + C_5^2 C_4^2 C_4^2 - C_5^3 C_3^2 C_3^2 + C_5^4 C_2^2 C_2^2 = 225 - 500 + 360 - 90 + 5 = 0.$$

Помимо нахождения количества всех возможных объектов определенного вида типовой комбинаторной задачей является их систематическое перечисление. Хорошо известны алгоритмы порождения и систематического перечисления перестановок, сочетаний и других классических комбинаторных объектов [1-7]. Алгоритм перечисления n -профилей еще не описан.

Данная статья посвящена восполнению этого пробела. Ее целью является создание алгоритма систематического перечисления всех n -профилей числа r .

ПОСТАНОВКА ЗАДАЧИ

Дано целое число $r > 1$, заданное каноническим разложением в произведение простых множителей, которое представлено в виде упорядоченного по возрастанию набора попарно

различных простых множителей $P = (p_1, p_2, \dots, p_m)$ и соответствующего набора их кратностей $A = (a_1, a_2, \dots, a_m)$, таких, что $r = \prod_{j=1}^m p_j^{a_j}$. Пусть $k = \sum_{j=1}^m a_j$ - общее количество простых в этом разложении. Также дано количество компонент в упорядоченном мультипликативном разложении числа r (целое $0 < n \leq k$).

Требуется последовательно и без повторений перечислить все n -профили r - вектора $(r_1, r_2, \dots, r_n)$, такие, что $\forall i \in \{1, 2, \dots, n\} : r_i > 1$ и $r = \prod_{i=1}^n r_i$.

МЕТОДЫ

Введем понятие характеристической матрицы n -профиля числа r [6-10, 15-19].

Определение 1. Характеристической матрицей n -профиля r назовем целочисленную матрицу:

$$Q = \begin{pmatrix} q_{1,1} & q_{1,2} & \dots & q_{1,m} \\ q_{2,1} & q_{2,2} & \dots & q_{2,m} \\ \vdots & & & \vdots \\ q_{n,1} & q_{n,2} & \dots & q_{n,m} \end{pmatrix},$$

удовлетворяющую следующим условиям:

1) Матрица Q имеет размер $n \times m$, где n - количество компонент профиля, m - количество попарно различных простых чисел, входящих в каноническое разложение r ;

2) Все элементы $q_{i,j} \geq 0$;

3) $\forall j \in \{1, 2, \dots, m\} : \sum_{i=1}^n q_{i,j} = a_j$, где a_j суть элемент A - набора кратностей простых множителей в каноническом разложении r ;

4) $\forall i \in \{1, 2, \dots, n\} : \sum_{j=1}^m q_{i,j} = b_i$ и упорядоченный набор $B = (b_1, b_2, \dots, b_n)$ такой, что $\sum_{i=1}^n b_i = k$ есть композиция k - общего количества простых множителей в каноническом разложении r , содержащая n частей $b_i > 0$.

Выполнение этих условий означает, что в матрице Q отсутствуют строки или столбцы [11-14, 20], состоящие из одних нулей, i -тая строка ($i = 1, 2, \dots, n$) представляет собой композицию b_i из m частей, допускающую нулевые части, а j -тый столбец ($j = 1, 2, \dots, m$) есть композиция a_j из n частей, так же допускающая нулевые части.

Любому n -профилю числа r ставится в соответствие единственная характеристическая матрица. И, наоборот, если столбцам характеристической матрицы сопоставить простые числа из упорядоченного набора $P = (p_1, p_2, \dots, p_m)$, то по ней однозначно можно построить n -профиль числа r . Покажем это.

Рассмотрим $(r_1, r_2, \dots, r_n)$ - произвольный n -профиль r . Поскольку $\forall i \in \{1, 2, \dots, n\} : r_i > 1$ и r_i делит r , то каноническое разложение r_i содержит только те простые множители, которые входят в набор $P = (p_1, p_2, \dots, p_m)$, но не обязательно все элементы этого набора. Представим r_i в виде произведения простых множителей, при необходимости дополненного так, чтобы каждое из чисел $p_1, p_2, \dots, p_m$ обязательно в нем присутствовало, пусть даже и в нулевой степени. Получим:

$$\left(r_1 = \prod_{j=1}^m p_j^{q_{1,j}}, r_2 = \prod_{j=1}^m p_j^{q_{2,j}}, \dots, r_n = \prod_{j=1}^m p_j^{q_{n,j}} \right). \quad (1)$$

Для всех компонент r_i разложение $r_i = \prod_{j=1}^m p_j^{q_{i,j}}$ единственно в силу основной теоремы арифметики [1].

Теперь, если из показателей степеней $q_{i,j}$ составить матрицу Q размером $n \times m$, то не сложно убедиться, что она удовлетворяет указанным условиям. С другой стороны, если заданы характеристическая матрица Q и упорядоченный набор $P = (p_1, p_2, \dots, p_m)$, то по формуле (1) можно однозначно вычислить все компоненты профиля.

Таким образом, существует взаимно однозначное соответствие между множеством всех возможных n -профилей r и множеством характеристических матриц размером $n \times m$.

Хотя характеристическая матрица более сложный объект, чем n -профиль r , но он более удобен для поиска решения нашей задачи. Учитывая существование взаимно однозначного соответствия между множеством профилей и множеством характеристических матриц, изменим исходную постановку задачи: при тех же исходных данных требуется последовательно и без повторений перечислить все характеристические матрицы n -профилей числа r , и для каждой из них сформировать соответствующий профиль.

На множестве характеристических матриц n -профилей r введем отношение эквивалентности.

Определение 2. Характеристические матрицы n -профиля r $Q = (q_{i,j})$ и $Q' = (q'_{i,j})$ B -эквивалентны, если $\forall i \in \{1, 2, \dots, n\} : \sum_{j=1}^m q_{i,j} = \sum_{j=1}^m q'_{i,j} = b_i$, где $b_i > 0$ - элемент композиции k из n частей - $B = (b_1, b_2, \dots, b_n)$.

Это отношение разбивает множество характеристических матриц на C_{k-1}^{n-1} классов B -эквивалентности – по одному классу на каждую композицию k из n частей больших нуля.

Зафиксируем некоторую композицию $B = (b_1, b_2, \dots, b_n)$ и ограничимся вопросами порождения B -эквивалентных характеристических матриц n -профиля r .

Порождение характеристической матрицы можно рассматривать как процесс определения ее элементов путем распределения единиц кратностей простых множителей в каноническом разложении числа r так, чтобы по его завершению выполнялись условия 1) – 4).

Реализация этого процесса приводит к получению ряда состояний, каждое состояние в котором характеризуется множеством уже определенных элементов матрицы; элементом, требующим определения; количествами нераспределенных единиц кратности по строкам и столбцам. Обозначим наборы количеств нераспределенных единиц кратности соответственно $B' = (b'_1, b'_2, \dots, b'_n)$ и $A' = (a'_1, a'_2, \dots, a'_m)$.

В начальном состоянии этого ряда $B' = B$, $A' = A$ и множество определенных элементов пусто, а в конечном – $B' = (0, 0, \dots, 0)$, $A' = (0, 0, \dots, 0)$ и множество определенных элементов содержит все элементы матрицы. При смене состояний происходит определение значения очередного элемента и присоединение его к множеству определенных. При этом происходит уменьшение значений нераспределенных единиц кратности в соответствующей строке и столбце на величину определяемого элемента.

Таким образом, реализация процесса порождения характеристической матрицы требует организации обхода ее элементов. Условимся обходить элементы матрицы слева направо и сверху вниз и пронумеруем их в порядке этого обхода числами от 0 до $n \cdot m - 1$. Тогда номер любого состояния в процессе порождения характеристической матрицы будет совпадать с номером текущего элемента в обходе (он же элемент, требующий определения), а множество ранее определенных элементов содержит все элементы с номерами меньшими чем текущий. Исключение составляет только конечное состояние, которое имеет номер $n \cdot m$, а определяемого элемента не имеет. По известному номеру $k \in \{0, 1, \dots, n \cdot m - 1\}$ для элемента $q_{i,j}$ легко определить номера

строки и столбца, в которых он расположен: $i = (k \operatorname{div} m) + 1$ и $j = (k \operatorname{mod} m) + 1$, где div и mod - операции целочисленного деления и получения остатка.

Пусть процесс порождения характеристической матрицы находится в состоянии, для которого определяемым элементом является $q_{i,j}$, а наборы количеств нераспределенных единиц кратности по строкам и столбцам соответственно $B' = (b'_1, b'_2, \dots, b'_n)$ и $A' = (a'_1, a'_2, \dots, a'_m)$. Что можно сказать относительно возможного значения $q_{i,j}$?

Во-первых, по определению $q_{i,j} \geq 0$.

Во-вторых, значение $q_{i,j}$ не больше чем количество имеющихся единиц кратности a'_j и не больше чем количество единиц кратности, требующих распределения b'_i . То есть $q_{i,j} \leq \min(a'_j, b'_i)$.

В-третьих, пусть $s = \sum_{k=j+1}^m a'_k$ - суммарное количество имеющихся единиц кратности, которые могут быть задействованы для достижения b'_i . Если $b'_i > s$, то недостающие единицы следует выбирать из тех, которые соответствуют столбцу j , и $b'_i - s$ есть минимальное их количество. То есть $q_{i,j} \geq \max(0, b'_i - s)$.

Таким образом, $\max(0, b'_i - \sum_{k=j+1}^m a'_k) \leq q_{i,j} \leq \min(a'_j, b'_i)$ и для определения $q_{i,j}$ достаточно

выбрать любое значение из указанного диапазона, уменьшив при этом значения a'_j и b'_i на выбранную величину.

Не сложно убедиться, что при реализации рассмотренного процесса распределения будет порождена характеристическая матрица, удовлетворяющая всем требуемым условиям.

Придерживаясь определенной стратегии при определении очередного элемента, можно получить некоторые особые характеристические матрицы. Так, если в процессе распределения в качестве значений определяемых элементов всегда выбирать максимально возможные, то порожденную матрицу будем называть сформированной по максимуму. А при выборе всегда минимально возможных значений получим матрицу, сформированную по минимуму.

РЕЗУЛЬТАТ

Рассмотрим EnumProf - общий алгоритм решение поставленной задачи.

Введенное ранее понятие характеристической матрицы n -профиля числа r , позволяет рассматривать перечисление профилей как процесс порождения их характеристических матриц, в котором каждая матрица преобразуется в соответствующий профиль, выводимый на печать.

Алгоритм EnumProf содержит цикл, который выполняется для всех композиций k из n частей больших нуля. На каждой итерации этого цикла выбирается очередная композиция $B = (b_1, b_2, \dots, b_n)$, используемая в дальнейшем для порождения B -эквивалентных характеристических матриц. Для организации этого цикла можно применить известный алгоритм лексикографического перечисления композиций числа из n частей больших нуля [4].

Далее идет цикл по порождению B -эквивалентных характеристических матриц, первой из которых является матрица сформированная по максимуму. Формирование этой матрицы выполняет процедура GetFirstMatr.

В теле этого цикла по характеристической матрице и упорядоченному набору простых множителей в каноническом разложении r вычисляется и выводится очередной n -профиль r . Затем с помощью процедуры GetNextMatr осуществляется попытка породить следующую характеристическую матрицу на основании текущей. Такая попытка успешна, если текущая

характеристическая матрица не является сформированной по минимуму. Эти действия выполняются пока процедура GetNextMatr в состоянии породить следующую матрицу.

Блок-схема алгоритма EnumProf приведена на рис. 1.




Рис. 1. Блок-схема систематического перечисления n -профилей числа r
Fig. 1. Flowchart for the systematic enumeration of n -profiles of the number r

Алгоритм, выполняемый процедурой GetFirstMatr, реализует процесс порождения характеристической матрицы с использованием стратегии формирования по максимуму. Его блок-схема приведена на рис. 2.




Рис. 2. Блок-схема алгоритма формирования первой B -эквивалентной характеристической матрицы n -профиля r

Fig. 2. Flowchart of the algorithm for generating the first B -equivalent characteristic matrix of the n -profile r

Исходными данными для процедуры GetNextMatr является любая характеристическая матрица n -профиля r . Идея, реализованная в этой процедуре, состоит в том, чтобы, применяя

процесс распределения единиц кратности, начиная от его конечного состояния, вернуться к такому состоянию, для которого определяемый элемент не достиг минимально возможного значения. Если такое состояние не найдено, то исходная характеристическая матрица является сформированной по минимуму, и следующей матрицы нет. В противном случае следует уменьшить на единицу текущее значение определяемого элемента, а все последующие элементы определить с помощью процесса распределения с использованием стратегии формирования по максимуму.

Блок-схема алгоритма процедуры GetNextMatr приведена на рис. 3.




Рис. 3. Блок-схема алгоритма формирования следующей характеристической матрицы n -профиля r
Fig. 3. Flowchart of the algorithm for generating the next characteristic matrix of the n -profile r

ВЫВОДЫ

Таким образом в данной статье описан алгоритм систематического перечисления всех n -профилей числа r , и для проверки работоспособности алгоритма найдем перечисления всех 3-профилей числа 100.

Исходные данные: целое число $r = 100$, заданное каноническим разложением в произведение простых множителей $100 = 2^2 \cdot 5^2$, которое представлено в виде упорядоченного по возрастанию

набора попарно различных простых множителей $P = (p_1, p_2) = (2, 5)$ и соответствующего набора их кратностей $A = (a_1, a_2) = (2, 2)$; количество компонент профиля $n = 3$; количество попарно различных простых множителей в каноническом разложении сотни $m = 2$. Общее количество простых множителей в каноническом разложении сотни $k = \sum_{j=1}^m a_j = 4$.

Всего 3-профилей числа 100 существует 12. Все они в качестве примера приведены во введении.

Алгоритм EnumProf перечисляет n -профили r отдельно для каждой композиции k из n частей. Если записать такие композиции в лексикографическом порядке, то получим: $(1, 1, 2), (1, 2, 1), (2, 1, 1)$.

На первой итерации внешнего цикла алгоритма EnumProf будет принята композиция $B = (b_1, b_2, b_3) = (1, 1, 2)$ и для нее с помощью процедуры GetFirstMatr будет порождена характеристическая матрица Q , сформированная по максимуму. Процесс, реализуемый GetFirstMatr, последовательно проходит 7 состояний от начального состояния с номером 0 до конечного состояния с номером 6. Описания этих состояний приведены на рис. 4.




Рис. 4. Состояния процесса порождения характеристической матрицы Q , сформированной по максимуму

Fig. 4. States of the process of generating the characteristic Q matrix formed based on the maximum

Затем следует вложенный цикл, в теле которого с помощью процедуры *GetNextMatr*, применяемой для текущей характеристической матрицы, порождается матрица, следующая за ней.

Рассмотрим процесс порождения матрицы следующей за $Q = \begin{pmatrix} 1, 0 \\ 1, 0 \\ 0, 2 \end{pmatrix}$.

Проходя по состояниям процесса порождения характеристической матрицы в направлении от конечного состояния к начальному, процедура *GetNextMatr* дойдет до состояния, в котором определяемый элемент не достиг минимально возможного значения. Это состояние имеет номер 2 (см. рис. 4). Затем, уменьшив на единицу значение $q_{2,1}$, *GetNextMatr* пройдет состояния 3 - 5, выбирая максимально возможные значения определяемых элементов. Указанные действия иллюстрирует рис. 5.




Рис. 5. Состояния процесса порождения следующей характеристической матрицы
 Fig. 5. States of the process of generating the next characteristic matrix

Продолжая выполнять действия, предусмотренные алгоритмом *EnumProf*, получим полный перечень 3-профилей числа 100. Полученный перечень представлен в табл. 1.

Перечень профилей

List of profiles

Таблица 1

Table 1

№ профиля	№ матрицы	Характеристическая матрица	3-профиль числа 100
Композиция $B = (1, 1, 2)$			
1	1	$Q = \begin{pmatrix} 1, 0 \\ 1, 0 \\ 0, 2 \end{pmatrix}$	$r_1 = 2^1 \cdot 5^0 = 2$ $r_2 = 2^1 \cdot 5^0 = 2$ $r_3 = 2^0 \cdot 5^2 = 25$

2	2	$Q = \begin{pmatrix} 1, 0 \\ 0, 1 \\ 1, 1 \end{pmatrix}$	$r_1 = 2^1 \cdot 5^0 = 2$ $r_2 = 2^0 \cdot 5^1 = 5$ $r_3 = 2^1 \cdot 5^1 = 10$
3	3	$Q = \begin{pmatrix} 0, 1 \\ 1, 0 \\ 1, 1 \end{pmatrix}$	$r_1 = 2^0 \cdot 5^1 = 5$ $r_2 = 2^1 \cdot 5^0 = 2$ $r_3 = 2^1 \cdot 5^1 = 10$
4	4	$Q = \begin{pmatrix} 0, 1 \\ 0, 1 \\ 2, 0 \end{pmatrix}$	$r_1 = 2^0 \cdot 5^1 = 5$ $r_2 = 2^0 \cdot 5^1 = 5$ $r_3 = 2^2 \cdot 5^0 = 4$
Композиция $B = (1, 2, 1)$			
5	1	$Q = \begin{pmatrix} 1, 0 \\ 1, 1 \\ 0, 1 \end{pmatrix}$	$r_1 = 2^1 \cdot 5^0 = 2$ $r_2 = 2^1 \cdot 5^1 = 10$ $r_3 = 2^0 \cdot 5^1 = 5$
6	2	$Q = \begin{pmatrix} 1, 0 \\ 0, 2 \\ 1, 0 \end{pmatrix}$	$r_1 = 2^1 \cdot 5^0 = 2$ $r_2 = 2^0 \cdot 5^2 = 25$ $r_3 = 2^1 \cdot 5^0 = 2$
7	3	$Q = \begin{pmatrix} 0, 1 \\ 2, 0 \\ 0, 1 \end{pmatrix}$	$r_1 = 2^0 \cdot 5^1 = 5$ $r_2 = 2^2 \cdot 5^0 = 4$ $r_3 = 2^0 \cdot 5^1 = 5$
8	4	$Q = \begin{pmatrix} 0, 1 \\ 1, 1 \\ 1, 0 \end{pmatrix}$	$r_1 = 2^0 \cdot 5^1 = 5$ $r_2 = 2^1 \cdot 5^1 = 10$ $r_3 = 2^1 \cdot 5^0 = 2$
Композиция $B = (2, 1, 1)$			
9	1	$Q = \begin{pmatrix} 2, 0 \\ 0, 1 \\ 0, 1 \end{pmatrix}$	$r_1 = 2^2 \cdot 5^0 = 4$ $r_2 = 2^0 \cdot 5^1 = 5$ $r_3 = 2^0 \cdot 5^1 = 5$
10	2	$Q = \begin{pmatrix} 1, 1 \\ 1, 0 \\ 0, 1 \end{pmatrix}$	$r_1 = 2^1 \cdot 5^1 = 10$ $r_2 = 2^1 \cdot 5^0 = 2$ $r_3 = 2^0 \cdot 5^1 = 5$
11	3	$Q = \begin{pmatrix} 1, 1 \\ 0, 1 \\ 1, 0 \end{pmatrix}$	$r_1 = 2^1 \cdot 5^1 = 10$ $r_2 = 2^0 \cdot 5^1 = 5$ $r_3 = 2^1 \cdot 5^0 = 2$
12	4	$Q = \begin{pmatrix} 0, 2 \\ 1, 0 \\ 1, 0 \end{pmatrix}$	$r_1 = 2^0 \cdot 5^2 = 25$ $r_2 = 2^1 \cdot 5^0 = 2$ $r_3 = 2^1 \cdot 5^0 = 2$

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Список литературы

1. Виноградов И.М. Основы теории чисел. М., ГИТТЛ, 1952. – 180 с.
2. Гияси А., Михайлов И.П., Чубариков В.Н. О равномерном распределении остатков в разложении действительных чисел по мультипликативной системе чисел // Чебышевский сборник. – 2022. – №23(5). – С. 38-44.
3. Данилов А.В., Макарычев П.П. Комбинаторный алгоритм назначения целей // Известия высших учебных заведений. Поволжский регион. Технические науки. – 2025. – № 3 (75). – С. 86-99.
4. Иванов Б. Н. Дискретная математика. Алгоритмы и программы. – 2001. – М.: Лаборатория Базовых Знаний. – С. 288
5. Инютин С.А. Вычислительные средства модулярной алгоритмики: монография М., 2024.
6. Исследование подходов детекции движущихся объектов на зашумлённых изображениях / Абрамов К.В., Александров К.С., Балабанова Т.Н., Бабенко А.А., Бурданова Е.В. // Научный результат. Информационные технологии. – Т. 10, №1. – 2025. – С. 47-57.
7. Кайгородов Е.В., Крылов П.А., Туганбаев А.А. О некоторых линейных отображениях коалгебр инцидентности // Прикладная математика & Физика. – 2024. – Т. 56. № 4. – С. 273-285.
8. Метод системно-объектного моделирования документооборота / Наджаджра М.Х., Бобышев П.П., Федоров В.И., Лозовая С.Ю., Бабенко А.А. // Экономика. Информатика. – 2026. – Т. 53. № 1. – С. 122-135.
9. Об оценивании размеров информативных фрагментов на изображениях морской поверхности / Черноморец Д.А., Болгова Е.В., Черноморец А.А., Петина М.А. // Научный результат. Информационные технологии. – Т.9, №2. – 2024. – С. 3-11.
10. Полюга В.А., Шабля Ю.В. Исследование быстродействия программной реализации алгоритмов комбинаторной генерации в зависимости от подхода к представлению данных // Прикладная математика и информатика: современные исследования в области естественных и технических наук. Сборник материалов IX Международной научно-практической конференции (школы-семинара) молодых ученых. Тольятти. – 2023. – С. 60-66.
11. Румбешт В.В., Бурданова Е.В. Комбинаторика упорядоченных мультипликативных разложений // Научные ведомости БелГУ: Экономика. Информатика. 2020. – № 47 (1) – С.126-134.
12. Рыженко К.В., Хачай М.Ю., Незнахина Е.Д. Приближенные алгоритмы с константными оценками точности для некоторых асимметричных задач комбинаторной маршрутизации // Современные проблемы математики и её приложений. Тезисы Международной (54-й Всероссийской) молодёжной школы-конференции. Екатеринбург. – 2023. – С. 56.
13. Сохраби М., Фатхоллахи-Фард А.М., Громов В.А. Алгоритм генетической инженерии (gea): эффективный метаэвристический алгоритм для решения задач комбинаторной оптимизации // Автоматика и телемеханика. – 2024. – № 3. – С. 23-37.
14. Токарева А.В., Кручинин Д.В. О возможности применения алгоритмов комбинаторной генерации к процессу инвентаризации // Решетневские чтения. Материалы XXVII Международной научно-практической конференции, посвященной памяти генерального конструктора ракетно-космических систем академика М.Ф. Решетнева: в 2-х частях. Красноярск. – 2023. – С. 171-173.
15. Adams S. Locally free actions on lorentz manifolds // Geometric and Functional Analysis. – 2000. – Т. 10. № 3. – P. 453-515.
16. Antinucci G., Giuliani A., Greenblatt R.L. Non-integrable ising models in cylindrical geometry: grassmann representation and infinite volume limit // Annales Henri Poincare. – 2022. – Т. 23. № 3. – P. 1061-1139.
17. Holroyd A.E., Janson S., Wästlund J. Minimal matchings of point processes // Probability Theory and Related Fields. – 2022. – Т. 184. № 1. – P. 571-611.
18. Isaev A.P. Quantum groups and yang-baxter equations // Natural Science Review. – 2025. – Т. 2. № 2. – P. 1-192.
19. Marò S., Bonanno C. Asymptotic behaviour of orbit determination for hyperbolic maps // Celestial Mechanics and Dynamical Astronomy. – 2021. Т. 133. – № 6.
20. Jiang H., Benzaria S., Alsadun N., Jia J., Czaban-Jóźwiak Ju., Guillerm V., Shkurenko A., Thiam Z., Bonneau M., Maka V.K., Chen Zh., Ameuhhr Z.O., O’Keeffe M., Eddaoudi M. Merged-nets enumeration for the systematic design of multicomponent reticular structures // Science. – 2024. – Т. 386. – № 6722. – P. 659-666.

References

1. Vinogradov I.M. Fundamentals of Number Theory. Moscow, GITTL, 1952. – 180 p.
2. Giyasi A., Mikhailov I.P., Chubarikov V.N. On the uniform distribution of remainders in the expansion of real numbers according to a multiplicative number system. // *Chebyshevskii Sbornik*. 2022. No. 23(5). pp. 38-44.
3. Danilov A.V., Makarychev P.P. Combinatorial algorithm for target assignment // *Izvestiya Vysshikh Uchebnykh Zavedenii. Povolzhsky Region. Technical Sciences*. 2025. No. 3 (75). pp. 86-99.
4. Ivanov B.N. Discrete Mathematics: Algorithms and Programs. 2001. Moscow: Laboratoriya Bazovykh Znaniy. 288 p.
5. Inyutin S.A. Computational Tools for Modular Algorithms: Monograph. Moscow, 2024.
6. Study of approaches to detecting moving objects in noisy images / Abramov K.V., Alexandrov K.S., Balabanova T.N., Babenko A.A., Burdanova E.V. // *Research result. Information technologies*. – T. 10, №1, 2025. – P. 47-57.
7. Kaygorodov E.V., Krylov P.A., Tuganbaev A.A. On some linear maps of incidence coalgebras // *Applied Mathematics & Physics*. – 2024. – T. 56. No. 4. – P. 273-285.
8. Method of System-Object Modeling of Document Flow / Najajra M.H., Bobyshev P.P., Fedorov V.I., Lozovaya S.Y., Babenko A.A. // *Economics. Information Technologies*. – 2026. – 53(1) – P. 122-135.
9. Chernomorets D.A., Bolgova E.V., Chernomorets A.A., Petina M.A. On estimating the size of informative fragments in the sea surface images // *Research result. Information technologies*. – T.9, №2, 2024. – P. 3-11.
10. Polyuga V.A., Shablya Yu.V. Investigation of the Performance of Software Implementations of Combinatorial Generation Algorithms Based on Data Representation Approaches // *Applied Mathematics and Informatics: Modern Research in Natural and Technical Sciences. Proceedings of the IX International Scientific and Practical Conference (Workshop-Seminar) of Young Scientists. Tolyatti*. – 2023. – P. 60-66.
11. Rumbesht V.V., Burdanova E.V. Combinatorics of ordered multiplicative factorizations. // *Scientific Bulletin of Belgorod State University: Economics. Informatics*. 2020. – No. 47 (1). – P. 126-134.
12. Ryzhenko K.V., Khachay M.Yu., Neznakhina E.D. Approximation algorithms with constant accuracy bounds for certain asymmetric combinatorial routing problems // *Modern Problems of Mathematics and Its Applications. Abstracts of the International (54th All-Russian) Youth School-Conference. Yekaterinburg*. – 2023. – P. 56.
13. Sohrabi M., Fathollahi-Fard A.M., Gromov V.A. Genetic Engineering Algorithm (GEA): An Efficient Metaheuristic Algorithm for Solving Combinatorial Optimization Problems // *Automation and Remote Control*. – 2024. – No. 3. – P. 23-37.
14. Tokareva A.V., Kruchinin D.V. On the Applicability of Combinatorial Generation Algorithms to the Inventory Process // *Reshetnev Readings: Proceedings of the XXVII International Scientific and Practical Conference Dedicated to the Memory of Academician M.F. Reshetnev, General Designer of Rocket and Space Systems: in 2 parts. Krasnoyarsk*. – 2023. – P. 171-173.
15. Adams S. Locally free actions on lorentz manifolds // *Geometric And Functional Analysis*. – 2000. – T. 10. № 3. – P. 453-515.
16. Antinucci G., Giuliani A., Greenblatt R.L. Non-integrable ising models in cylindrical geometry: grassmann representation and infinite volume limit // *Annales Henri Poincare*. – 2022. – T. 23. № 3. – P. 1061-1139.
17. Holroyd A.E., Janson S., Wästlund J. Minimal matchings of point processes // *Probability Theory and Related Fields*. – 2022. – T. 184. № 1. – P. 571-611.
18. Isaev A.P. Quantum groups and yang-baxter equations // *Natural Science Review*. – 2025. – T. 2. № 2. – P. 1-192.
19. Marò S., Bonanno C. Asymptotic behaviour of orbit determination for hyperbolic maps // *Celestial Mechanics and Dynamical Astronomy*. – 2021. T. 133. – № 6.
20. Jiang H., Benzaria S., Alsadun N., Jia J., Czaban-Józwiak Ju., Guillerm V., Shkurenko A., Thiam Z., Bonneau M., Maka V.K., Chen Zh., Ameuhhr Z.O., O’Keeffe M., Eddaoudi M. Merged-nets enumeration for the systematic design of multicomponent reticular structures // *Science*. – 2024. – T. 386. – № 6722. – P. 659-666.

Румбешт Вадим Валерьевич, кандидат технических наук, доцент кафедры математического и программного обеспечения информационных систем, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Бурданова Екатерина Васильевна, кандидат технических наук, доцент, доцент кафедры математического и программного обеспечения информационных систем, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Rumbesht Vadim Valeryevich, Candidate of Technical Sciences, Associate Professor of the Department of Mathematical and Software Support for Information Systems, Belgorod State National Research University, Belgorod, Russia

Burdanova Ekaterina Vasilyevna, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Mathematical and Software Support for Information Systems, Belgorod State National Research University, Belgorod, Russia