

МИНОБРНАУКИ РОССИИ

Известия

**Юго-Западного
государственного университета**

**Серия: Управление, вычислительная
техника, информатика. Медицинское
приборостроение**

Научный журнал

Том 16 № 1 / 2026

Proceedings

**of the Southwest
State University**

**Series: Control, Computer Engineering,
Information Science. Medical
Instruments Engineering**

Scientific Journal

Vol. 16 № 1 / 2026



**Известия Юго-Западного
государственного университета.
Серия: Управление, вычислительная
техника, информатика. Медицинское приборостроение
(Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta.
Seriya: Upravlenie, vychislitel'naya tekhnika, informatika.
Meditinskoe priborostroenie)
Научный рецензируемый журнал
Основан в 2011 г.**

Цель издания – публичное представление научно-технической общественности научных результатов фундаментальных, проблемно-ориентированных научных исследований в таких областях, как информационные и интеллектуальные системы, мехатроника и робототехника, распознавание и обработка изображений, системный анализ и принятие решений, моделирование в медицинских и технических системах, приборы и методы контроля природной среды.

В журнале публикуются оригинальные работы, обзорные статьи, рецензии и обсуждения, соответствующие тематике издания.

Публикация статей в журнале для авторов бесплатна.

Целевая аудитория: научные работники, профессорско-преподавательский состав образовательных учреждений, экспертное сообщество, молодые ученые, аспиранты, заинтересованные представители широкой общественности.

Журнал придерживается политики открытого доступа. Полнотекстовые версии статей доступны на сайте журнала, научной электронной библиотеки eLIBRARY.RU.

Журнал включен в перечень ведущих научных журналов и изданий ВАК Минобрнауки России, в которых должны быть опубликованы основные научные результаты диссертаций на соискание ученых степеней доктора наук, кандидата наук по следующим научным специальностям:

2.2.4. Приборы и методы измерения (по видам измерений) (технические науки).

2.2.8. Методы и приборы контроля и диагностики материалов, изделий, веществ и природной среды (технические науки).

2.2.12. Приборы, системы и изделия медицинского назначения (технические науки).

2.2.15. Системы, сети и устройства телекоммуникаций (технические науки).

2.3.1. Системный анализ, управление и обработка информации (по отраслям) (технические науки).

2.3.8. Информатика и информационные процессы (технические науки).

3.3.9. Медицинская информатика (медицинские науки).

ГЛАВНЫЙ РЕДАКТОР

Емельянов Сергей Геннадьевич, д-р техн. наук, профессор, Лауреат премии Правительства РФ в области науки и техники, ректор, Юго-Западный государственный университет (г. Курск, Россия)

ЗАМЕСТИТЕЛЬ ГЛАВНОГО РЕДАКТОРА

Томакова Римма Александровна, д-р техн. наук, профессор,
Юго-Западный государственный университет (г. Курск, Россия)

РЕДАКЦИОННАЯ КОЛЛЕГИЯ

Агарков Николай Михайлович, д-р мед. наук, профессор, Юго-Западный государственный университет (г. Курск, Россия)

Будневский Андрей Валериевич, д-р мед. наук, профессор, Воронежский государственный медицинский университет им. Н. Н. Бурденко Минздрава России (г. Воронеж, Россия)

Гонтарев Сергей Николаевич, д-р мед. наук, профессор, Белгородский государственный национальный исследовательский университет (г. Белгород, Россия)

Зайченко Кирилл Владимирович, д-р техн. наук, профессор, Институт аналитического приборостроения Российской академии наук (г. Санкт-Петербург, Россия)

Зо Зо Тун, канд. техн. наук, профессор, Военный институт сестринских и парамедицинских наук (г. Янгон, Мьянма)

Истомина Татьяна Викторовна, д-р техн. наук, профессор, Московский государственный гуманитарно-экономический университет (г. Москва, Россия)

Кореневский Николай Алексеевич, д-р техн. наук, профессор, Юго-Западный государственный университет (г. Курск, Россия)

Коровин Евгений Николаевич, д-р техн. наук, доцент, Воронежский государственный технический университет (г. Воронеж, Россия)

Маслак Анатолий Андреевич, д-р техн. наук, профессор, Кубанский государственный университет (г. Краснодар, Россия)

Подмастерьев Константин Валентинович, д-р техн. наук, профессор, Орловский государственный университет им. И. С. Тургенева (г. Орел, Россия)

Разинкин Константин Александрович, д-р техн. наук, профессор, Воронежский государственный технический университет (г. Воронеж, Россия)

Риад Таха Аль-Касасбех, д-р техн. наук, профессор, Университет Аль-Балка (г. Амман, Иордания)

Серегин Станислав Петрович, д-р мед. наук, профессор, Юго-Западный государственный университет (г. Курск, Россия)

Таныгин Максим Олегович, д-р техн. наук, доцент, Юго-Западный государственный университет (г. Курск, Россия)

Тарасов Сергей Павлович, д-р техн. наук, профессор, Южный Федеральный университет (г. Ростов-на-Дону, Россия)

Филист Сергей Алексеевич, д-р техн. наук, профессор, Юго-Западный государственный университет (г. Курск, Россия)

Филонович Александр Владимирович, д-р техн. наук, профессор, Юго-Западный государственный университет (г. Курск, Россия)

Чернов Николай Николаевич, д-р техн. наук, профессор, Южный Федеральный университет (г. Ростов-на-Дону, Россия)

Чопоров Олег Николаевич, д-р техн. наук, профессор, Воронежский государственный технический университет (г. Воронеж, Россия)

Шаталова Ольга Владимировна, д-р техн. наук, доцент, Юго-Западный государственный университет (г. Курск, Россия)

Якунченко Татьяна Игоревна, д-р мед. наук, профессор, Белгородский государственный национальный исследовательский университет (г. Белгород, Россия)

Учредитель и издатель:

ФГБОУ ВО «Юго-Западный государственный университет»

Адрес учредителя, издателя и редакции:

305040, г. Курск, ул. 50 лет Октября, 94

Телефон: +7(4712) 22-25-26,

Факс: +7(4712) 50-48-00.

E-mail: rio_kursk@mail.ru

Наименование органа, зарегистрировавшего издание:

Журнал зарегистрирован Федеральной службой по надзору в сфере связи, информационных технологий и массовых коммуникаций (ПИ №ФС77-82285 от 23.11.2021).

ISSN 2223-1536 (Print)

Префикс DOI: 10.21869

Сайт журнала: <https://swsu.ru/izvestiya/seriesivt/>

© Юго-Западный государственный университет, 2025



Материалы журнала доступны под лицензией Creative Commons Attribution 4.0 License

Типография:

Полиграфический центр
Юго-Западного государственного
университета, 305040, г. Курск,
ул. 50 лет Октября, 94

Подписка и распространение:

журнал распространяется
по подписке.
Подписной индекс журнала 44288
в объединенном каталоге
«Пресса России».

Периодичность: четыре раза в год

Свободная цена.

Оригинал-макет подготовлен А. Е. Джиоевой

Подписано в печать 31.03.2026. Формат 60×84/8.

Дата выхода в свет 14.04.2026.

Бумага офсетная. Усл. печ. л. 28,1.

Тираж 1000 экз. Заказ 11.

16+



**Proceedings of the Southwest State University.
Series: Control, Computer Engineering,
Information Science. Medical Instruments Engineering**

Peer-reviewed scientific journal

Published since 2011

These Proceedings present the results of scientific fundamental and applied research in such areas as information and intelligent systems; mechatronics, robotics; image recognition and processing; system analysis and decision making; simulation in medical and technical systems; devices and methods for monitoring the natural environment.

The journal publishes scientific articles, critical reviews, reports and discussions in the above mentioned areas.

All papers are published free of charge.

Target readers are scientists, university professors and teachers, experts, young scholars, graduate and post-graduate students, stakeholders and interested public.

The Editorial Board of the journal pursues open access policy. Complete articles are available at the journal web-site and at eLIBRARY.RU .

The journal is included into the Register of the Top Scientific Journals of the Higher Attestation Commission of the Russian Federation as a journal recommended for the publication of the findings made by the scientists working on a doctoral or candidate thesis in the following areas:

2.2.4. Devices and methods of measurement (by type of measurement) (technical Sciences).

2.2.8. Methods and devices for monitoring and diagnosing materials, products, substances and the natural environment (technical Sciences).

2.2.12. Devices, systems and medical devices (technical Sciences).

2.2.15. Telecommunication systems, networks and devices (technical Sciences).

2.3.1. System analysis, management and information processing (by industry) (technical Sciences).

2.3.8. Informatics and information processes (technical sciences).

3.3.9. Medical informatics (medical sciences).

EDITOR-IN-CHIEF

Sergei G. Emelianov, Dr. of Sci. (Engineering), Correspondent Member of the Russian Academy of Architecture and Construction Sciences, a Holder of the Russian Government Prize in the Field of Science and Engineering, Rector of the Southwest State University (Kursk, Russia)

DEPUTY EDITOR-IN-CHIEF

Rimma A. V. Tomakova, Dr. of Sci. (Engineering), Professor, Southwest State University (Kursk, Russia)

EDITORIAL BOARD

Nikolai M. Agarkov, Dr. of Sci. (Medical), Professor, Southwest State University (Kursk, Russia)

Andrey V. Budnevsky, Dr. of Sci. (Medical), Professor, Voronezh State Medical University named after N. N. Burdenko (Voronezh, Russia)

Nikolay N. Chernov, Dr. of Sci. (Engineering), Professor, Southern Federal University (Rostov-on-Don, Russia)

Oleg N. Choporov, Dr. of Sci. (Engineering), Professor, Voronezh State Technical University (Voronezh, Russia)

Sergey A. Filist, Dr. of Sci. (Engineering), Professor, Southwest State University (Kursk, Russia)

Alexander V. Filonovich, Dr. of Sci. (Engineering), Professor, Southwest State University (Kursk, Russia)

Sergei N. Gontarev, Dr. of Sci. (Medical), Professor,
Belgorod State National Research University
(Belgorod, Russia)

Tatiana V. Istomina, Dr. of Sci. (Engineering),
Professor, Moscow State University of Humanities
and Economics (Moscow, Russia)

Nikolay A. Korenevsky, Dr. of Sci. (Engineering),
Professor, Southwest State University (Kursk, Russia)

Evgeny N. Korovin, Dr. of Sci. (Engineering), Associate
Professor, Voronezh State Technical University
(Voronezh, Russia)

Anatoly A. Maslak, Dr. of Sci. (Engineering), Professor,
Kuban State University (Krasnodar, Russia)

Konstantin V. Podmasteryev, Dr. of Sci. (Engineering),
Professor, Orel State University named after I. S. Turgenev
(Orel, Russia)

Konstantin A. Razinkin, Dr. of Sci. (Engineering),
Professor, Voronezh State Technical University
(Voronezh, Russia)

Stanislav P. Seregin, Dr. of Sci. (Medical), Professor,
Southwest State University (Kursk, Russia)

Maxim O. Tanygin, Dr. of Sci. (Engineering),
Associate Professor, Southwest State University
(Kursk, Russia)

Riad Taha Al-Kasasbeh, Dr. of Sci. (Engineering),
Professor, Al-Balqa University (Amman, Jordan)

Olga V. Shatalova, Dr. of Sci. (Engineering),
Associate Professor, Southwest State University
(Kursk, Russia)

Sergey P. Tarasov, Dr. of Sci. (Engineering),
Professor, Southern Federal University
(Rostov-on-Don, Russia)

Tatiana I. Yakunchenko, Dr. of Sci. (Medical),
Professor, Belgorod State National Research University
(Belgorod, Russia)

Kirill V. Zaichenko, Dr. of Sci. (Engineering),
Professor, Institute for Analytical Instrumentation
Russian Academy of Sciences (St. Petersburg, Russia)

Zhanybai T. Zhusubaliyev, Dr. of Sci. (Engineering),
Professor, Southwest State University (Kursk, Russia)

Zo Zo Tun, Cand. of Sci. (Engineering), Professor,
Military Institute of Nursing and Paramedical Sciences
(Yangon, Myanmar)

Founder and Publisher:
“Southwest State University”

Official address of the Founder, Publisher and Editorial Office:

50 Let Oktyabrya str. 94, Kursk 305040, Russian Federation

Phone: (+74712) 22-25-26,

Fax: (+74712) 50-48-00.

E-mail: rio_kursk@mail.ru

The Journal is officially registered by:

The Federal Supervising Authority in the Field of Communication,
Information Technology and Mass media

(PI №FS77-82285 of 23.11.2021).

ISSN 2223-1536 (Print)

DOI Prefix: 10.21869

Web-site: <https://swsu.ru/izvestiya/seriesivt/>

Printing office:

Printing Center

of the Southwest State University,

50 Let Oktyabrya str., 94,

Kursk 305040, Russian Federation

Subscription and distribution:

the journal is distributed by subscription.

Subscription index 44288

in the General Catalogue “Pressa Rossii”

Frequency: Quarterly

Free price

Original lay-out design: A. E. Djioeva

© Southwest State University, 2025



Publications are available in accordance with
the Creative Commons Attribution 4.0 License

Signed for printing 31.03.2026. Format 60×84/8.

Release date 14.04.2026.

Offset paper. Printer's sheets: 28,1.

Circulation 1000 copies. Order 11.

16+

СОДЕРЖАНИЕ

ИНФОРМАЦИОННЫЕ И ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ.....	8
Искусственный интеллект в высшем образовании: признание рисков	8
<i>Томакова Р. А., Томаков В. И.</i>	
Прогнозирование восстановления пациентов после черепно-мозговой травмы	38
<i>Азарков Н. М., Лысенко А. С.</i>	
Интеллектуальная система оптимизации производственной деятельности на среднем и крупном предприятии на основе автоматизированных информационных систем.....	50
<i>Каракчиев Д. А., Шевченко К. Н., Томакова Р. А.</i>	
РАСПОЗНАВАНИЕ И ОБРАБОТКА ИЗОБРАЖЕНИЙ.....	64
Методика автоматической сегментации зрачка в офтальмологических изображениях с аномалиями	64
<i>Комкова С. В.</i>	
Пространственная локализация костных сарком на рентгенограммах с использованием одноэтапной нейросетевой модели	77
<i>Киселев А. В., Кулешова Е. А., Горелов В. Д., Конаныхина Т. Н., Чьямова З. К.</i>	
Анализ методов обработки и исследования речевого сигнала для установления психоэмоционального состояния человека	93
<i>Кравчук Д. А., Котенко А. С.</i>	
СИСТЕМНЫЙ АНАЛИЗ И ПРИНЯТИЕ РЕШЕНИЙ.....	107
Биотехническая система реабилитации пациентов с нарушением двигательных функций нижних конечностей с адаптивными режимами управления экзоскелетом.....	107
<i>Петрунина Е. В.</i>	
Разработка многоуровневой системы для прогнозирования стоимости акций компаний в условиях высоковолатильного рынка России.....	132
<i>Положенцев А. А., Малышев А. В., Брежнев А. В.</i>	
МОДЕЛИРОВАНИЕ В МЕДИЦИНСКИХ И ТЕХНИЧЕСКИХ СИСТЕМАХ.....	148
Диагностика подагры на основе градиентного анализа.....	148
<i>Бобырь М. В., Супрунова О. Г.</i>	
Анализ и разработка вязкоупругой модели биотканей для оценки их нелинейных свойств	164
<i>Лагута М. В., Кравчук Д. А.</i>	
Система поддержки принятия врачебных решений по выбору конструкции дентального имплантата с использованием машинного обучения.....	174
<i>Кийко А. А., Николаенко А. Н., Постников М. А., Попов Н. В., Лысов А. Д., Пономарев А. Е., Заров Е. В.</i>	
Влияние геометрических параметров насосов аппарата вспомогательного кровообращения на их напорно-расходные характеристики.....	189
<i>Кротов К. В., Боярский Г. Г., Хаустов А. И.</i>	
Нечеткие модели прогнозирования неврозов у преподавателей и студентов высшей школы.....	206
<i>Родионова С. Н., Корневский Н. А., Трусевич А. А., Малыгина Е. Д.</i>	
Гибридные технологии искусственного интеллекта и биоимпедансной спектроскопии для классификации функционального состояния органов и систем человека.....	221
<i>Корсунский Н. А.</i>	
К СВЕДЕНИЮ АВТОРОВ.....	242

CONTENT

INFORMATION AND INTELLIGENT SYSTEMS.....	8
Artificial intelligence in higher education: awareness of risks	8
<i>Rimma A. Tomakova, Vladimir I. Tomakov</i>	
Predicting recovery of patients after traumatic brain injury.....	38
<i>Nikolay M. Agarkov, Anastasia S. Lysenko</i>	
Intelligent system for optimization of production activities at a medium and large enterprise based on ais.....	50
<i>Daniil A. Karakchiev, Klim N. Shevchenko, Rimma A. Tomakova</i>	
IMAGE RECOGNITION AND PROCESSING.....	64
Method for automatic pupil segmentation in ophthalmological images with anomalies.....	64
<i>Svetlana V. Komkova</i>	
Spatial localization of bone sarcomas on radiographs using a one-stage neural network model.....	77
<i>Alexey V. Kiselev, Elena A. Kuleshova, Vladislav D. Gorelov, Tatyana N. Konanykhina, Zoya K. Chyamova</i>	
Analysis of speech signal processing and research methods for establishing the psycho-emotional state of a person.....	93
<i>Denis A. Kravchuk, Alexander S. Kotenko</i>	
SYSTEM ANALYSIS AND DECISION-MAKING	107
A biotechnical system for the rehabilitation of patients with lower limb motor impairments using adaptive exoskeleton control modes	107
<i>Elena V. Petrunina</i>	
Development of a multi-level system for forecasting stock prices of companies in the conditions of the highly volatile russian market	132
<i>Alexey A. Polozhentsev, Alexander V. Malyshev, Alexey V. Brezhnev</i>	
MODELING IN MEDICAL AND TECHNICAL SYSTEMS.....	148
Gout diagnosis based on gradient analysis.....	148
<i>Maxim V. Bobyr, Olga G. Suprunova</i>	
Analysis and development of a viscoelastic model of biological tissues to assess their nonlinear properties	164
<i>Margarita V. Laguta, Denis A. Kravchuk</i>	
Clinical decision-making support system for dental implant design using machine learning.....	174
<i>Anastasia A. Kijko, Andrey N. Nikolaenko, Mikhail A. Postnikov, Nikolay V. Popov, Alexander D. Lysov, Artem E. Ponomarev, Evgeniy V. Zarov</i>	
The influence of the assisted blood circulation pumps geometry on their head-flow characteristics	189
<i>Kirill V. Krotov, Gleb G. Boyarsky, Alexander I. Khaustov</i>	
Fuzzy models for predicting neuroses in higher education teachers and students	206
<i>Sofya N. Rodionova, Nikolay A. Korenevsky, Alena A. Trusevich, Ekaterina D. Malykhina</i>	
Hybrid artificial intelligence and bioimpedance spectroscopy technologies for classifying the functional state of human organs and systems.....	221
<i>Nikita A. Korsunsky</i>	
INFORMATION FOR AUTHORS	242

Искусственный интеллект в высшем образовании: признание рисков

Р. А. Томакова¹, В. И. Томаков¹ ✉

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: tomakov52@mail.ru

Резюме

Цель исследования – выявить и классифицировать риски, сопряжённые с внедрением искусственного интеллекта в сфере образования.

Методы. Применялись общенаучные методы исследования: анализ и синтез, индукция, дедукция, конкретизация, классификация. Для выявления причинно-следственных связей были задействованы сравнительный и системный подходы. Классификация рисков выстроена с учетом принципов единства основания, взаимоисключения, системной полноты, релевантности и адаптивности.

Результаты. Потенциальные риски применения технологий искусственного интеллекта в образовательной сфере многообразны и охватывают разные уровни взаимодействия учащихся, педагогов и системы образования в целом. Выявлены и охарактеризованы потенциальные риски: технологические, этические, психологические, когнитивные, социальные, педагогические, правовые и регуляторные. Признание рисков позволит использовать потенциал искусственного интеллекта для повышения качества образования, не забывая о фундаментальных принципах обучения и развитии личности учащихся. Классификация потенциальных рисков позволит учитывать баланс между использованием искусственного интеллекта и сохранением человеческого фактора в образовании, разрабатывать стратегии минимизации негативных последствий в образовательном процессе.

Заключение. Для минимизации негативных последствий применения искусственного интеллекта в образовании необходимы комплексные меры, включающие разработку соответствующих нормативных актов, совершенствование образовательных программ, разработку новых методик и педагогических технологий, переподготовку преподавателей и обеспечение современной технической инфраструктуры. Наилучшие результаты от внедрения искусственного интеллекта будут достигнуты при условии формирования такой образовательной среды, которая сохранит ценность традиционного преподавания под руководством педагога, но при этом будет активно использовать и интегрировать возможности искусственного интеллекта.

Ключевые слова: образование; высшее образование; искусственный интеллект; мышление; преподаватель; студент; учащийся; риск.

Конфликт интересов: Автор декларирует отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Томакова Р. А., Томаков В. И. Искусственный интеллект в высшем образовании: признание рисков // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2025. Т. 16, № 1. С. 8–37. <https://doi.org/10.21869/2223-1536-2026-16-1-8-37>

Поступила в редакцию 15.01.2026

Подписана в печать 12.02.2026

Опубликована 31.03.2026

Artificial intelligence in higher education: awareness of risks

Rimma A. Tomakova¹, Vladimir I. Tomakov¹ ✉

¹ Southwest State University

50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: tomakov52@mail.ru

Abstract

The purpose of the research is to identify and classify the risks associated with the introduction of artificial intelligence in the field of education.

Methods. General scientific research methods were used: analysis and synthesis, induction, deduction, concretization, classification. Comparative and systematic approaches were used to identify cause-and-effect relationships. The classification of risks is based on the principles of unity of foundation, mutual exclusion, systemic completeness, relevance and adaptability.

Results. The potential risks of using artificial intelligence technologies in the educational sphere are diverse and cover different levels of interaction between students, teachers and the education system as a whole. Potential risks are identified and characterized: technological, ethical, psychological, cognitive, social, pedagogical, legal and regulatory. Recognizing the risks will make it possible to use the potential of artificial intelligence to improve the quality of education, without forgetting the fundamental principles of learning and personal development of students. The classification of potential risks will allow taking into account the balance between the use of artificial intelligence and the preservation of the human factor in education, and developing strategies to minimize negative consequences in the educational process.

Conclusion. To minimize the negative consequences of the use of artificial intelligence in education, comprehensive measures are needed, including the development of appropriate regulations, the improvement of educational programs, the development of new methods and pedagogical technologies, the retraining of teachers and the provision of modern technical infrastructure. The best results from the introduction of artificial intelligence will be achieved if an educational environment is formed that preserves the value of traditional teaching under the guidance of a teacher, but at the same time actively uses and integrates the capabilities of artificial intelligence.

Keywords: education; higher education; artificial intelligence; critical thinking; teacher; student; risk.

Conflict of interest: The Authors declares the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Tomakova R.A., Tomakov V.I. Artificial intelligence in higher education: awareness of risks. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie* = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering. 2026;16(1):8–37. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-8-37>

Received 15.01.2026

Accepted 12.02.2026

Published 31.03.2026

Введение

Национальная стратегия развития искусственного интеллекта на период до 2030 года¹, утвержденная Указом Президента РФ В. В. Путина, определяет цели и задачи развития искусственного интеллекта в России, а также меры по его использованию для обеспечения национальных интересов. Документ предусматривает создание благоприятных условий для повсеместного и масштабного внедрения ИИ-технологий в деятельность образовательных учреждений. Стратегия определяет искусственный интеллект (далее – ИИ) как важнейший инструмент повышения качества и эффективности образовательной системы. Использование ИИ открывает возможности для глубокого анализа учебной информации, оптимизации образовательных программ и методов преподавания, внедрения персонализированного подхода к обучению каждого студента. Особое внимание уделяется развитию компетенций по применению технологий ИИ среди студентов вузов.

В ходе заседания Совета по развитию гражданского общества и правам человека 9 декабря 2025 г. Президент РФ В. В. Путин особо подчеркнул важ-

ность сохранения человеческого потенциала в условиях стремительного развития цифровизации. Он подчеркнул опасность ситуации, при которой молодые граждане утратят способность самостоятельно анализировать информацию и принимать решения, заменяя собственные размышления цифровыми подсказками². По словам Президента, государству предстоит найти баланс между развитием ИИ и сохранением человеческого потенциала.

На заседании Государственного совета РФ 25 декабря 2025 г. Президент России В. В. Путин озвучил ряд важных тезисов в отношении искусственного интеллекта³. В частности, он подчеркнул необходимость адаптации системы образования к новым технологическим реалиям, сохраняя ценности отечественного образования.

Высшая школа стоит перед важной задачей – подготовить специалистов, способных к работе в новой реальности, где ИИ играет важную роль. Университеты ищут наилучшие способы внедрения ИИ в учебный процесс, и данный аспект активно обсуждается ректорами высших учебных заведений [1]. Однако, как отмечают ректоры вузов, ИИ

¹ О развитии искусственного интеллекта в Российской Федерации (вместе с «Национальной стратегией развития искусственного интеллекта на период до 2030 года»): Указ Президента Российской Федерации от 10 октября 2019 г. № 490 // Президент России. URL: <http://www.kremlin.ru/acts/bank/44731> (дата обращения: 23.12.2025).

² Заседание Совета по развитию гражданского общества и правам человека. // Президент России. URL: <http://www.kremlin.ru/events/president/transcripts/78691> (дата обращения: 27.12.2025).

³ Заседание Государственного Совета. // Президент России. URL: <http://www.kremlin.ru/events/president/transcripts/deliberations/78860> (дата обращения: 27.12.2025).

представляет собой инструмент с потенциальными рисками, с которыми уже сталкивается система образования и которые могут негативно повлиять на качество учебного процесса и развитие обучающихся. В этом процессе важно правильно оценивать баланс рисков и возможностей, которые дают технологии ИИ. Критически осмысленное внедрения ИИ в систему российского высшего образования позволит высшим учебным заведениям реализовать его потенциал для эффективного поддержания, динамичного продвижения и устойчивого развития образовательных процессов и научных исследований.

Цель исследования – выявить и классифицировать риски, сопряжённые с внедрением искусственного интеллекта в сфере образования.

Для достижения поставленной цели были сформулированы и следующие исследовательские задачи: выявление ключевых рисков, связанных с использованием ИИ в высшем образовании; классификация рисков по различным критериям (технологическим, этическим, социальным и др.) и видам потенциального вреда.

Актуальность обусловлена необходимостью обеспечения эффективной и безопасной интеграции ИИ в образовательный процесс, поскольку на сегодняшний день остается много нерешенных вопросов, связанных с ИИ. Несмотря на значительный объем проведенных исследований в области применения ИИ в образовательной сфере, до

сих пор не создана исчерпывающая классификация основных рисков, которая позволила бы выявить потенциальные угрозы и разработать эффективные меры по снижению возможных неблагоприятных эффектов. Недостаточная структурированность понимания существующих угроз ведет к неоптимальному распределению ресурсов, упущенным выгодам и недоверию к технологиям ИИ как надежному инструменту улучшения образовательного процесса. Классификация возможных рисков позволит учитывать баланс между использованием ИИ и сохранением человеческого фактора в образовании, разрабатывать стратегии минимизации негативных последствий в обучении студентов.

Материалы и методы

Исследование проводилось в соответствии с методологией и особенностями процедур аналитического обзора. Рассматривались научные труды российских ученых, входящих в перечень ВАК и представленных на информационно-аналитическом портале *elibrary.ru*.

Объектом исследования выступили процессы внедрения технологий ИИ в систему высшего образования, предметом анализа стали потенциальные риски и угрозы, возникающие в связи с данным процессом.

Применялись общенаучные методы исследования: анализ и синтез, индукция, дедукция, конкретизация, классификация. В дополнение к ним, для вы-

явления причинно-следственных связей были задействованы сравнительный и системный подходы.

Классификация рисков, связанных с внедрением ИИ, построена на фундаментальных принципах: единства основания – все риски вытекают из единой природы ИИ; взаимоисключения – категории рисков не пересекаются и образуют исчерпывающий набор потенциальных угроз; системной полноты – классификация охватывает все существенные аспекты риска, связанные с использованием ИИ; релевантности – выделенные категории рисков имеют прямую связь с практическим применением ИИ; адаптивности – классификация может быть модифицирована и дополнена по мере развития ИИ и появления новых угроз.

Классификация рисков применения ИИ в сфере образования преследует две основные задачи – выявление типов рисков и их качественный анализ в доступном и понятном виде.

Первая задача решается путем структурирования рисков в соответствии с определенными критериями: по типу риска (технологические, этические, правовые и др.) и сфере применения (обучение, оценка). Такая структура позволяет получить целостное представление о ландшафте рисков и выделить приоритетные для дальнейшего анализа.

Вторая задача – объединение информации о рисках по уровню потенциального вреда – подразумевает сбор,

анализ и документирование доступных данных о потенциальных проблемах, связанных с использованием ИИ в образовании.

Результаты и их обсуждение

Классификация рисков служит основой для систематического анализа и управления рисками, связанными с внедрением ИИ. Она позволяет выявить не только отдельные угрозы, но и их потенциальные комбинации, расставить приоритеты, сосредоточившись на наиболее опасных или вероятных рисках, что позволит разработать стратегии управления рисками, рационально использовать ресурсы и усилия на минимизацию наиболее значимых угроз, обеспечить прозрачность и подотчетность при внедрении ИИ в образовании. Такая процедура является неотъемлемой частью ответственного и безопасного внедрения ИИ в образование. Она способствует более эффективному и рациональному решению задач, связанных с минимизацией рисков, созданию благоприятных условий для использования технологий ИИ в интересах обучающихся, педагогов и всего общества.

Предлагаемая классификация рисков затрагивают несколько ключевых аспектов образовательного процесса, носит предварительный характер и не является исчерпывающей. Тем не менее она служит отправной точкой для дальнейших исследований, направленных на разработку эффективных методов минимизации рисков, связанных с при-

менением технологий искусственного интеллекта в образовательной сфере. Дальнейшие исследования в данном направлении позволят углубленно изучить возможные угрозы и разработать комплекс мер, обеспечивающих безопасность и эффективность внедрения ИИ в образовательный процесс.

Технологические риски возникают вследствие некорректной работы технологий ИИ, включают широкий спектр потенциальных проблем, вызванных сбоями, ошибками или недостаточной эффективностью алгоритмов, используемых в системах ИИ.

Ограничения в понимании естественного языка и контекста. Системы ИИ, предназначенные для оценки корректности текста или его перевода, испытывают затруднения в адекватном осмыслении многоуровневых синтаксических структур, тонкостей иронии и сарказма, а также выражений, глубоко укорененных в конкретной культуре и зависящих от контекста. Они могут расценивать правильно написанные тексты как содержащие грамматические ошибки или же, напротив, пропустить серьезные нарушения структуры речи, что может приводить к недопониманию и ошибкам в образовательном процессе, особенно при оценке письменных работ или в интерактивных обучающих системах.

Неэффективность обработки нестандартных ситуаций и творческих задач. Работа ИИ основана на выявленных статистических закономерностях, извлекаемых из крупных объемов тек-

стовых данных. Когда тематика недостаточно отражена в учебных наборах или по ней крайне ограничены сведения, качество генерируемых ответов существенно снижается. Это проявляется либо в предоставлении общих, поверхностных высказываний, не имеющих практической пользы, либо в появлении ошибок, вызванных добавлением недостоверных деталей, что негативно сказывается на точности и ценности текста. Таким образом, возникают характерные проблемы, такие как «галлюцинации» (создание неверной информации вследствие нехватки надежных источников) и «неглубокий анализ» (замена глубокого изучения материала пустыми обобщениями).

Ограничения в адаптации к индивидуальным особенностям учащихся. Несмотря на высокий потенциал к индивидуализации, современные системы ИИ сталкиваются с рядом ограничений, препятствующих полному учету уникальных характеристик каждого обучающегося. Эти ограничения включают трудности в точной оценке эмоционального состояния учащихся (эмоциональная неопределенность, скрытые эмоции, преходящие изменения настроения, индивидуальные реакции на стрессовые ситуации), недостаточное понимание специфики культурных особенностей и неспособность адаптироваться ко множеству разнообразных стилей обучения.

Ошибочные решения. Алгоритмы ИИ могут давать неверные рекоменда-

ции или оценки учащимся, если модели не были достаточно хорошо натренированы на репрезентативных данных. Например, недостаточное количество примеров для определенных типов заданий может привести к ошибкам в оценке, и она может выдавать неправильные или необъективные рекомендации. Современные алгоритмы глубокого обучения часто представляют собой «черные ящики», чьи внутренние механизмы принятия решений трудно интерпретировать, что усложняет процесс понимания, почему учащийся получил именно такую оценку или рекомендацию.

Ошибка идентификации. Использование биометрических систем распознавания лиц для контроля посещаемости студентов на занятиях представляет собой инновационный подход, обещая повысить эффективность и прозрачность учебного процесса. Ошибка идентификации системой ИИ может несправедливо отметить студента как отсутствующего на занятии, что негативно скажется на его академической успеваемости и репутации, что в результате может привести к снижению итоговых оценок, возникновению недоверия преподавателя, а также вызвать стресс и разочарование у самого студента.

Этические риски представляют потенциальные угрозы нарушения этических норм и принципов, возникающие вследствие внедрения технологий ИИ в образовательный процесс.

Проблемы конфиденциальности и защиты данных. Использование ИИ в

образовании связано с обработкой большого количества персональных данных учащихся. Существует риск несанкционированного доступа, утечки или неправомерного использования этой информации, что может нарушить право на приватность. Например, технологии распознавания лиц, основанные на алгоритмах ИИ, могут быть использованы для незаконного сбора и обработки персональных данных, что нарушает право на неприкосновенность частной жизни. Технологии рекомендательных систем, основанные на алгоритмах машинного обучения, собирают данные о привычках, интересах и поведении людей, что может быть использовано для манипулирования общественным мнением. Риски связаны с расширением спектра собираемой информации (включая IP-адреса, биометрию, поведенческие метрики) через цифровые дневники, платформы дистанционного обучения и системы прокторинга.

Предвзятость и дискриминация в алгоритмах ИИ. Предвзятость в ИИ – это не просто случайная ошибка, а систематические и повторяющиеся искажения в алгоритмах, которые приводят к несправедливым, перекошенным или дискриминационным результатам. Эти искажения могут проявляться в различных формах и иметь глубокие корни в данных, на которых обучается модель. Модели машинного обучения, являющиеся основой современных систем ИИ, функционируют путем анализа

огромных массивов данных. В процессе этого анализа они выявляют сложные закономерности, корреляции и тенденции, которые затем используют для генерации прогнозов, принятия решений или выполнения других задач. Однако качество, полнота и репрезентативность этих данных играют критически важную роль в обеспечении справедливости и точности работы модели.

Модели ИИ обучаются на наборах данных, которые могут содержать в себе существующие в обществе предрассудки и изначально несут в себе элемент дискриминации, что приводит к несправедливым решениям по отношению к отдельным людям, группам, организациям и т. п. В результате обученная модель, предназначенная для прогнозирования успеваемости учащихся, может демонстрировать преимущественное отношение к образовательным учреждениям с высоким уровнем финансирования по сравнению с учреждениями с ограниченными ресурсами. В образовании это может привести к несправедливой оценке или дискриминации отдельных групп учащихся.

Несправедливость автоматизированной оценки и принятия решений поднимает важные этические вопросы: насколько справедливо и этично полагаться на машину в вопросах, которые могут существенно повлиять на будущее учащегося. Например, алгоритм, обученный на данных об успехах студентов прошлых лет обучения, может систематически недооценивать потен-

циал учащихся, не входящих в эту категорию. Ещё пример: программа и онлайн-сервисы автоматической проверки текстов ставят лучшие оценки тем обучающимся, чьи работы написаны простым и понятным стилем, соответствующим большинству письменных образцов. Студенты с нестандартным стилем письма или иностранцы, испытывающие трудности с языком, будут получать худшие оценки, даже если содержание их работ вполне качественное.

В системах дистанционного обучения иногда возникают проблемы с обработкой мультимедийных файлов, с правильным пониманием содержания загружаемых документов или презентаций. Алгоритм мог неправильно распознать формулу или рисунок, предложенный студентом, что приводило к неправильной оценке работ или неполучению необходимых пояснений преподавателем.

Автоматизация оценки и принятия решений может ограничивать развитие критического мышления и самостоятельности у учащихся. Постоянная опора на машину для оценки своих работ может привести к пассивному усвоению информации и снижению мотивации к самосовершенствованию.

Проблемы прозрачности и объяснимости алгоритмов. Другой важный этический аспект связан с прозрачностью и объяснимостью алгоритмов ИИ. Часто механизмы работы таких алгоритмов являются «черными ящиками», что затрудняет понимание логики при-

нятых решений [2]. Если алгоритм выдаёт решение, которое кажется странным или несправедливым (например, неожиданная низкая оценка), отсутствие прозрачного обоснования усиливает сомнения и вызывает недовольство. Когда родители и педагоги не понимают, каким образом алгоритм принимает решения (например, почему именно эта оценка поставлена учащемуся или почему рекомендованы конкретные учебные задания), возникает ощущение непредсказуемости и случайности действий системы. Отсутствие прозрачности может привести к недоверию и ощущению несправедливости со стороны учащихся, родителей и педагогов.

Культурные барьеры и игнорирование культурных различий. Обучение, основанное исключительно на технологиях ИИ, может привести к стандартизации образовательного опыта и игнорированию культурных различий и специфики регионов. Кроме того, применение моделей ИИ в разных культурах без учета местных особенностей может привести к недоразумениям или неправильному толкованию контекста. Это особенно актуально для стран с богатым культурным наследием и многообразием национальных традиций, таких как Россия. Стандартизация образовательных процессов, ориентированных на универсальные алгоритмы и модели, способна нивелировать уникальность каждой культуры, обедняя тем самым общий образовательный ланд-

шафт. Важно учитывать, что культурные различия влияют не только на содержание учебных материалов, но и на методы преподавания, формы взаимодействия учащихся и преподавателей, а также на восприятие учебного материала учащимися разных этнических групп. Отсутствие персонализации содержания и методов обучения ведет к снижению эффективности усвоения материала студентами из разных регионов. Когда обучение проводится без учета местных обычаев и исторических корней, оно становится менее привлекательным и мотивирующим для обучающихся. Учащимся сложно ассоциировать себя с абстрактными и обезличенными образцами, предлагаемыми системами ИИ.

Доминирование искусственного интеллекта в творчестве. Вопрос о роли ИИ в творческих сферах вызывает оживлённые дебаты. ИИ способен генерировать впечатляющие изображения, музыку и тексты, имитируя стили известных мастеров. Однако утверждение о «продуктивном» творчестве ИИ требует тщательного осмысления и критического анализа.

Допущение использования ИИ для создания оригинальных и творческих текстов, что по своей сути выходит за рамки его возможностей, обусловленных обучением на существующих данных, может привести к неминуемой потере идентичности культуры. Это явление коснется не только способности людей к самостоятельной текстовой

продукции, но и их культурного кода в целом. Формирование последнего происходит исключительно на основе родного языка, включающего как устную, так и письменную речь. Язык служит мощным инструментом для постижения абстрактных концепций, овладения теоретическими и оценочными категориями, а также развития логического, критического и рефлексивного мышления [3]. Родной язык и устная / письменная речь являются фундаментом формирования культурного кода. Через язык усваиваются традиции, ценности, мировоззрение любого народа. ИИ, генерируя тексты на основе статистических закономерностей, не способен передать глубину и многогранность культурного наследия. Тексты, созданные ИИ, могут быть лишены эмоциональной окраски, нюансов, которые придают языку его неповторимую ценность.

В случае с изобразительным искусством ИИ может генерировать изображения, стилистически напоминающие работы известных художников. Созданный ИИ «креатив» будет лишь результатом переработки уже существующих работ, шаблонов и структур. Превалирование ИИ в творчестве может привести к девальвации человеческого творчества, создавая иллюзию доступности оригинальности без необходимости приложения собственных усилий. В результате люди могут утратить интерес к развитию собственных творческих способностей, что негативно скажется на культурном развитии общества.

Психологические риски представляют собой потенциальные угрозы психическому здоровью учащихся, возникающие вследствие взаимодействия с технологиями ИИ, способными оказывать влияние на разные аспекты психики, включая когнитивные процессы, эмоции и социальные отношения.

Утрата навыков самостоятельного принятия решений. Люди опираются на ИИ, потому что он предлагает быстрые, кажущиеся точными варианты. Это упрощает выбор, снижает нагрузку на мозг, особенно в условиях переизбытка информации. Постоянное следование оптимизированным алгоритмам, предлагаемым ИИ, способно вызвать ослабление волевой сферы, снижение уверенности в собственных возможностях и доверия к собственному суждению. В результате этого у пользователя может наблюдаться понижение уровня инициативы и самостоятельности в принятии решений. Обращение к ИИ, хотя и облегчает рабочий процесс, может привести к негативным последствиям. Человек, избегая этапов поиска, анализа и выбора, теряет возможность развивать важные навыки: критическое мышление, умение справляться с неопределенностью, находить решения в сложных ситуациях, развивается пассивность.

Искажённое восприятие реальности. ИИ может формировать идеи, не соответствующие классическим формам психоза. Например, пользователи

нейросетей могут верить, что открыли новый раздел физики или научились управлять временем. Некоторые пользователи иногда воспринимают подсказки и рекомендации ИИ как откровение или открытие новых истин, хотя это лишь продукт алгоритмов обработки текста и данных.

Причины искаженного восприятия кроются в алгоритмы рекомендательных систем – современные системы рекомендаций активно используют методы машинного обучения, чтобы предложить пользователям контент, соответствующий их интересам и предпочтениям. Это создает эффект «эхо-камер», когда человек постоянно сталкивается с информацией, подтверждающей его убеждения и гипотезы. Такое окружение может привести к укреплению ложных представлений и затруднить критическое осмысление альтернативных точек зрения. Срабатывает эффект когнитивного подкрепления – пользователи часто получают позитивное эмоциональное подкрепление, взаимодействуя с системой ИИ. Когда алгоритм генерирует выводы, подтверждающие личные теории пользователей, это усиливает чувство уверенности и значимости. Таким образом, даже самые абсурдные идеи могут казаться обоснованными благодаря положительной обратной связи от ИИ. Нейросети способны создавать убедительные нарративы, которые привлекают внимание аудитории и усиливают существующие предрассудки.

Иллюзия диалога с разумным существом. Люди приписывают ИИ намерение, доброту, понимание, которых у него нет. Иллюзия осмысленного взаимодействия возникает потому, что современные системы искусственного интеллекта способны создавать убедительные реплики и имитировать человеческое поведение. Такая коммуникация строится исключительно на алгоритмах обработки текста и распознавания закономерностей, заложенных разработчиками. У ИИ нет собственных мыслей, чувств или мотиваций, а любое впечатление понимания обусловлено лишь точностью подбора формулировки, основанной на огромном массиве проанализированных данных. Приписывание же качеств сознания, воли или эмоций ИИ является результатом психологического феномена антропоморфизма – склонности воспринимать неодушевленные объекты или процессы как обладающие личностными чертами. Это явление особенно ярко проявляется в условиях эмоционально насыщенного общения, например, когда собеседник остро нуждается в поддержке или внимании, ожидая услышать отклик, похожий на реакцию живого существа. Таким образом, хотя общение с искусственным интеллектом кажется живым и полноценным диалогом, оно остается игрой формальных моделей и методов машинного обучения, способствующих созданию впечатления глубокого взаимопонимания.

Информационная зависимость

возникает тогда, когда длительное и постоянное взаимодействие с определенными приложениями ИИ становится настолько привычным, что вызывает психологическую зависимость [4]. Пользователь испытывает навязчивую потребность регулярно обращаться к ИИ-сервисам для проверки фактов, советов или рекомендаций, даже если ситуация не требует немедленного вмешательства, даже если знания можно было бы восполнить самостоятельно.

Нейросети, несмотря на свою впечатляющую способность обрабатывать информацию, не обладают полным пониманием контекста и нюансов человеческого опыта. Они могут предоставлять достоверные факты, но не способны передать всю полноту эмоций, мнений, культурных ценностей, которые формируют наше мировоззрение. Постоянное общение с ИИ может привести к формированию одностороннего взгляда на мир, ограниченному рамками алгоритмов и обучающих данных. Человек теряет возможность критически оценивать информацию, сравнивать разные точки зрения, развивать собственную позицию.

Чрезмерная зависимость от подсказок ИИ приводит к ухудшению кратковременной памяти. Возникает порочный круг: ухудшение памяти вынуждает чаще обращаться к ИИ, что, в свою очередь, приводит к еще большему ослаблению памяти, делая человека полностью зависимым от этой техноло-

гии. Использование ИИ для решения сложных или рутинных задач может привести к быстрому развитию зависимости, поскольку мозг адаптируется к упрощению процессов. Продолжительность такого порочного круга зависит от частоты обращения к ИИ. Этот процесс может продолжаться годами, постепенно усиливаясь и приводя к серьезным последствиям для психического здоровья и качества жизни.

Информационное перенасыщение

при использовании ИИ возникает тогда, когда объем поступающей информации превышает способность человека её осмысленно воспринимать и обрабатывать. Это состояние характеризуется постоянным потоком больших объемов разнородных данных, многие из которых оказываются избыточными или малозначительными. Основные причины: постоянный доступ к большим массивам данных и информации; повышенная скорость распространения и доступности информации через алгоритмы рекомендаций платформ; неправильное использование инструментов искусственного интеллекта, генерирующих большие объемы текста или изображений.

Информационное перенасыщение вызывает усталость, стресс, рассеянность внимания, повышенную тревожность, депрессию, фрустрацию, когнитивные искажения и социальное отчуждение, негативно влияя на психическое и социальное благополучие пользователя.

Неадекватная поддержка.

Нейросеть может случайно поддержи-

вать деструктивные мысли или поведение, непродуманно реагируя на запросы пользователей. Это явление обусловлено природой обучения нейросетей. Они обучаются на огромных массивах данных, которые могут содержать как полезную, так и вредную информацию. В процессе обучения нейросеть выявляет закономерности в данных и учится генерировать текст, соответствующий им. Однако, если в обучающих данных присутствуют образцы деструктивного поведения или мыслей, нейросеть может перенять эти образцы и использовать их в своих ответах. В силу своей природы ИИ не может различать контекст и подтекст запроса пользователя. Последствия неадекватной поддержки могут быть весьма серьезными. Это может привести к тому, что она случайно поддержит деструктивные мысли или поведение, выдавая непродуманные ответы. Например, пользователь, страдающий депрессией, может обратиться к нейросети за поддержкой. Вместо того, чтобы предложить помощь и содействие, нейросеть может случайно сгенерировать ответ, усиливающий чувство безнадежности или предлагающий саморазрушительное поведение.

Сенсорная депривация – состояние, которое возникает в результате значительного ограничения сенсорных сигналов, поступающих от органов чувств (слух, зрение, осязание, вкус, обоняние). Частое использование технологий ИИ, особенно в виртуальных средах, может привести к этому нега-

тивному эффекту, так как значительная часть естественного чувственного опыта заменяется цифровыми сигналами, сокращающими разнообразие физических раздражителей. Дефицит реальной сенсорной активности негативно влияет на работу мозга, снижая эффективность когнитивной деятельности: ослабевает способность концентрироваться и поддерживать устойчивое внимание, замедляется процесс принятия решений, снижается качество пространственно-визуального анализа и страдает долговременная память. Это также ограничивает развитие способности мыслить творчески и абстрактно.

Фрустрация участников образовательного процесса. Системы ИИ, основанные на оценке успеваемости, могут вызывать повышенный стресс и тревожность у учащихся. Алгоритмы часто сравнивают достижения учащегося с результатами других студентов. Постоянное сравнение создает ощущение конкуренции, которое может негативно сказываться на психическом здоровье, приводя к чувству неполноценности или даже депрессии. Когда оценка становится автоматизированной и основана исключительно на показателях, установленных алгоритмом, студенты начинают бояться сделать ошибку. Страх автоматизированной оценки вызывает постоянное напряжение и тревогу, поскольку любое неправильное решение может повлиять на итоговую оценку. Получение низкой оценки от алгоритма воспринимается учащимися

гораздо острее, чем обратная связь от преподавателя. Автоматизированные оценки кажутся объективнее и неумолимо точными, что усиливает чувство разочарования и снижает уверенность в себе, оказывает негативное влияние на самооценку. Алгоритмам сложно учитывать индивидуальные особенности каждого студента, такие как эмоциональное состояние, мотивацию или личные обстоятельства. Из-за этого система оценки может казаться несправедливой и подавляющей. Отсутствие индивидуального подхода лишь усиливает стресс и тревожность.

Фрустрация педагогов и родителей проявляется в трудностях, возникающих при попытке адаптировать стандартные подходы к воспитанию и обучению к специфическим потребностям своей аудитории. Традиционные методы воспитания и обучения требуют определенной гибкости и индивидуального подхода, однако образовательные технологии ИИ оказываются недостаточно приспособленными для удовлетворения этих потребностей. Вместо того, чтобы служить инструментами повышения качества образования, они нередко превращаются в препятствия, усугубляя разрыв между ожиданиями преподавателей, родителей и возможностями учащихся. Этот факт создает дополнительную нагрузку на педагогов, вынужденных искать решения. Родители также испытывают чувство неуверенности и разочарования в выбранном вузе. Таким образом, фрустрация воз-

никает вследствие несовершенства существующих моделей взаимодействия между педагогами, родителями и учащимися, а также отсутствия эффективных механизмов адаптации образовательных технологий к индивидуальным особенностям каждой группы учеников.

Социальные риски следует определить как потенциальные негативные последствия, связанные с влиянием технологий ИИ, для отдельных индивидов, социальных групп и общества в целом.

Цифровое неравенство и доступ к образовательным ресурсам. Внедрение ИИ-технологий может усугубить существующее неравенство в доступе к качественному образованию. Учебные заведения и учащиеся с ограниченными ресурсами могут оказаться в невыгодном положении. Отсутствие равного доступа к образовательным ресурсам приводит к тому, что учащиеся из неблагополучных семей и регионов получают меньше возможностей для развития интеллектуальных способностей и приобретения профессиональных навыков. Это ведет к снижению уровня конкурентоспособности выпускников на рынке труда, уменьшает шансы социальной мобильности. Образование традиционно считается одним из главных путей повышения социального статуса и улучшения качества жизни. Однако разрыв в возможностях получать качественное образование через цифровые технологии ограничивает шансы молодых людей на успешную карьеру и

улучшение своего материального положения. Учащиеся, испытывающие дефицит ресурсов для дистанционного обучения, могут сталкиваться с психологическими проблемами, такими как чувство неполноценности, разочарования и стресса. Отсутствие равных условий способствует росту тревожности и снижает мотивацию к учебе.

Изменение требований к компетенциям на рынке труда. В условиях тотального применения ИИ концепция непрерывного обучения становится ключевой. Люди должны быть готовы постоянно обновлять свои знания и навыки на протяжении всей карьеры. Это значит, что система образования должна поддерживать возможность дополнительного профессионального развития даже после завершения основного курса обучения, чтобы выпускники получали знания и навыки, соответствующие современным требованиям рынка труда. Образовательные программы должны адаптироваться к новым реалиям. Изменения в образовательных программах могут потребовать значительных временных и материальных ресурсов, а также переобучения преподавательского состава, чтобы достичь гармонии между теоретическими знаниями и практическими навыками, которые необходимо предоставить студентам.

Девальвация подлинной ценности образования. Это процесс, при котором ценность образования, статус выпускников и дипломов снижаются. ИИ может привести к упрощению образова-

тельного процесса. Акцент на алгоритмах и оценке, основанной на данных, может превзойти гуманитарные аспекты обучения, такие как критическое мышление, креативность и эмоциональный интеллект. Студенты могут начать воспринимать образование как набор задач, которые необходимо выполнить для получения желаемого результата, а не как путь к личностному росту и освоению мира. Также избыточная зависимость от ИИ может привести к падению уровня самостоятельности и ответственности у учащихся. Легкий доступ к информации и автоматизированные решения могут обесценить усилия, необходимые для поиска знаний, анализа информации и выработки собственных выводов. Ценность дипломов и квалификаций, полученных с помощью технологий ИИ, может оказаться под вопросом, что, в свою очередь, снизит их ценность на рынке труда. Наличие диплома уже не будет гарантировать успех, а работодатели будут вправе предъявлять более высокие требования к кандидатам, от которых потребуются демонстрация дополнительных компетенций, выходящих за рамки возможностей ИИ и образовательных программ.

Обострение социальной напряженности. Образование, построенное исключительно на технологических решениях, рискует привести к утрате национальной идентичности и уникальной культуры отдельных народов. Стандартизированные учебные про-

граммы и подходы могут вытеснить традиционные знания и ценности, накопленные поколениями. ИИ, созданный без учета локальных особенностей, способен формировать стереотипы и предвзятые представления о представителях разных культур. Отсутствие персонализации содержания и методов обучения ведет к снижению эффективности усвоения материала студентами из разных регионов. Невнимание к культурным особенностям может вызвать недовольство среди представителей малых народностей и этнокультурных сообществ. Ощущение дискриминации и пренебрежения традициями способно спровоцировать рост социальных конфликтов и напряжения внутри многонациональных регионов.

Изменение моделей поведения.

Возможен риск формирования новых норм коммуникации и социального взаимодействия, зачастую вступающих в конфликт с традиционными ценностями. ИИ оказывает влияние на человеческие действия и мыслительные процессы: сокращается разнообразие возможных выборов, усиливается зависимость от рекомендаций алгоритмов, поведение становится менее спонтанным и более контролируемым, причем этот процесс нередко протекает бессознательно. Автоматизированные ответы, рекомендательные системы, речевое общение с устройствами, социальные сети и мессенджеры – новые формы коммуникации, подвергающие риску некоторые традиционные ценности. Так, ИИ спо-

собствует увеличению виртуального общения, заменяя личные встречи онлайн-взаимодействием. Традиционные формы личного контакта, доверия и близости ослабляются, уступая место дистанционному общению через устройства. Зависимость от рекомендаций и подсказок ИИ ограничивает свободу принятия самостоятельных решений. Алгоритмы предоставляют готовые варианты действий, снижая мотивацию к размышлению и критическому осмыслению ситуации. Под воздействием технологий ИИ некоторые устоявшиеся социальные нормы могут утратить свою значимость или существенно трансформироваться, например непосредственное общение «лицом к лицу». Человек воспринимает только тот контент, который соответствует его предпочтениям и взглядам. Это ограничивает доступ к различным точкам зрения и ведет к утрате способности самостоятельно формировать собственные убеждения. Цифровые сервисы способствуют стандартизации выражения эмоций, что проявляется в повсеместном использовании эмодзи и шаблонных сообщений. Постепенно утрачивается важность глубокого понимания чужих переживаний и проявления сочувствия в повседневной жизни.

Когнитивные риски возникают из-за внедрения цифровых технологий в познавательный процесс обучающихся. Они тесно связаны с трансформацией процессов познания под влиянием цифровых посредников, таких как техноло-

гии искусственного интеллекта, электронные учебные материалы, онлайн-лекции, обучающие видеоролики и игры. Чрезмерная зависимость от ИИ может нарушать когнитивные процессы, связанные с памятью, вниманием, критическим мышлением и принятием решений, что связано с «когнитивной разгрузкой» – привычкой позволять ИИ решать мыслительные задачи вместо того, чтобы самостоятельно решать проблемы.

Девальвация возможностей памяти (эффект «цифровой амнезии»). Известен как «эффект Google», или «цифровая забывчивость», характеризуется утратой мозга способности эффективно сохранять, накапливать и воспроизводить информацию. Это когнитивный феномен, при котором способность запоминать и предъявлять информацию ослабевает из-за привычки полагаться на системы и технологии ИИ. Легкий доступ к огромным объемам данных создает иллюзию того, что информация всегда будет под рукой, что приводит к снижению потребности в запоминании, поскольку люди полагаются на внешние хранилища памяти, т. е. не тренируется память. В результате мозг, не получающий должной нагрузки, начинает атрофироваться, что сказывается на качестве когнитивных функций, в т. ч. и памяти. Этот феномен может проявляться в разных формах: забывчивость, размышление воспоминаний, сложности в подборе слов.

Снижение уровня интеллекта.

Чрезмерная зависимость от ИИ может привести к снижению умственных способностей (интеллекта), таких как способность к обучению, пониманию, логическому мышлению, креативности и решению проблем, умению адаптироваться к окружающей среде, решать сложные задачи, анализировать информацию и делать обоснованные выводы. Понижается способность к пониманию и управлению своими и чужими эмоциями. Уменьшение живого общения минимизирует естественные коммуникации, приводит к неумению правильно формулировать мысли и высказываться.

Иллюзия компетентности, или эффект гипертрофированной уверенности (эффект сверхуверенности), – когнитивное искажение, при котором уверенность человека в правильности своих действий и решений значительно больше, чем объективные основания считать их правильными [5].

Согласно исследованиям, представленным в работе [6], существует несколько интерпретаций феномена сверхуверенности: сверхуверенность может проявляться в изначально завышенной положительной оценке собственных способностей. Данный тип суждений характеризуется абсолютной уверенностью в эффективности собственной деятельности; сверхуверенность может быть связана с относительными суждениями, т. е. оценкой своих способностей по сравнению с другими людьми. Для такого типа

сверхуверенности характерно преувеличение своих возможностей в знакомых областях и недооценка в сложных или незнакомых.

Пользователи ИИ, получавшие готовые решения, переоценивают свои знания в предметной области, при этом реальное понимание темы остается поверхностным, т. к. система ИИ создаёт ощущение осведомлённости, но не позволяет развить внутреннее понимание, необходимое для настоящего профессионализма. ИИ может давать правдоподобный, но неверный ответ, и человек может поверить в него. Специалисты объясняют этот феномен «когнитивной разгрузкой»: человек передаёт часть мышления машине, снижает уровень критического анализа из-за отсутствия навыка критической оценки и самостоятельного решения задачи. В результате снижается метакогнитивный контроль – способность осознавать и корректировать собственные рассуждения. Отсюда возникает ощущение полной уверенности без реального понимания точности ответа. Со временем это может обернуться падением качества критического мышления и принятием неверных решений.

Деформация познавательных процессов. Чрезмерная зависимость от ИИ и легкая доступность информации может привести к её пассивному восприятию и потреблению. Из когнитивной деятельности человека фактически убирается важный этап познания – предварительный сбор информации, её

анализ, осмысленная интерпретация и конкретизация, т. е. критическое мышление. По мнению В. Д. Емельяненко, замена сложных форм умственной деятельности готовыми результатами, полученными с помощью искусственного интеллекта, вероятно, приведёт к снижению познавательного потенциала человека. Это связано с тем, что использование ИИ в процессе познания не сопровождается параллельным развитием когнитивных способностей человека вследствие отсутствия регулярной тренировки [7].

Использование ИИ как сверхлёгкого способа получения информации приводит к тому, что человек стирает границы между своими собственными возможностями и возможностями электронных устройств, приписывая себе их сверхспособности, веря в то, что в этот момент происходит процесс обучения (иллюзия познания) [8].

Исключение из процесса познания сложных форм умственной деятельности, замена знания готовыми результатами, сгенерированными ИИ, может привести к снижению познавательного потенциала человека, к развитию «интеллектуальной лени» [9].

Искаженный выбор решений – алгоритмы могут предлагать заключения, основанные на приоритетах, скрытых от пользователя. Эта ситуация связана с восприятием и интерпретацией информации человеком. Человек принимает решение, основываясь на выводах алгоритма, полагая, что это наилучший ва-

риант. Это упрощает выбор, который снижает нагрузку на мозг, особенно в условиях переизбытка информации. Однако это суждение основано на искаженной информации, что ведет к неправильному выбору. Алгоритмы ИИ часто формируют выводы исходя из определенных предпочтений или целей, заложенных разработчиками или условиями системы ИИ. Эти предпочтения могут быть незаметны пользователям, создавая иллюзию объективности. Пользователи склонны воспринимать рекомендации ИИ как объективные и правильные, даже если они основаны на ограниченном или предвзятом подходе.

Потеря самостоятельности при принятии решений – избыточная зависимость от ИИ снижает способность к самостоятельному принятию решений. Эта ситуация затрагивает ряд аспектов человеческого мышления и поведения:

- отсутствие критического мышления – люди склонны полагаться на алгоритмы и рекомендации ИИ без глубокого анализа ситуации;

- перевод ответственности – использование автоматизированных систем часто сопровождается переносом ответственности за выбор на систему;

- формирование паттернов поведения – частое обращение к помощи ИИ формирует устоявшуюся привычку постоянно искать готовые решения вне собственного опыта и интуиции;

- зависимость от внешних мнений и регулирования приводит к уменьшению автономности. Такая ситуация

обусловлена экстернальным типом локуса контроля, когда человек склонен приписывать свои успехи и неудачи внешним факторам.

Правовые и регуляторные риски – это потенциальные угрозы и проблемы, которые обусловлены и возникают из-за новизны и несформировавшейся правовой практики, связанных с применением ИИ в различных сферах. Эти риски включают нарушения прав субъектов образовательных отношений (учащихся, педагогов, родителей), недостаточную защиту персональных данных учащихся, этические дилеммы, связанные с использованием технологий ИИ, неопределенность ответственности разработчиков и поставщиков решений, риск предвзятости алгоритмов и дискриминации отдельных групп учащихся, отсутствие ясных правовых рамок для внедрения инновационных цифровых инструментов в образовательный процесс.

Законодательное регулирование использования технологий ИИ. Существующее законодательство не успевает за развитием ИИ-технологий, создавая правовой вакуум в правилах применения ИИ в различных аспектах обучения: от индивидуализации образовательных программ, технологий дистанционного обучения, контроля за процессом тестирований и сдачи экзаменов до методов оценки знаний учащихся [10]. Сходные вопросы возникают и при использовании ИИ для контроля проведения дистанционных

испытаний. Системы ИИ могут анализировать видеопоток, отслеживая поведение студента во время экзамена и выявляя потенциальные случаи мошенничества. Однако вопросы о достоверности такой оценки, о допустимости методов сбора данных и о защите личных данных учащихся остаются открытыми. В области оценки знаний учащихся ИИ может использоваться для автоматической проверки работ, анализа текстов и выдачи оценок. Но как обеспечить объективность подобной оценки? Как избежать возможных алгоритмических ошибок и предвзятости? Без чёткого законодательства, определяющего критерии оценки и стандарты работы ИИ-систем, высок риск получить непредсказуемые и несправедливые результаты.

Неопределенность относительно ответственности сторон. Недостаточность законодательного регулирования применения систем ИИ в образовательной сфере, о чем говорится в научном исследовании Р. А. Абдусаламова [11], в конечном счете создает неопределенности относительно ответственности сторон. Проблема особенно актуальна в контексте индивидуализации образовательных программ – ИИ может эффективно анализировать данные о сильных и слабых сторонах каждого учащегося, подбирая индивидуальные траектории обучения. Однако без чёткого законодательного регулирования возникает вопрос: кто несет ответ-

ственность за качество подобранной программы: преподаватель, разработчик системы ИИ или образовательное учреждение?

Нарушения авторских прав при сборе и использовании данных для обучения ИИ. Данные, собранные с различных ресурсов, часто содержат материалы, защищённые авторским правом, и использование таких материалов для тренировки ИИ-моделей может нарушать права владельцев контента. В сфере ИИ наиболее актуальным и дискуссионным вопросом является правомерность использования чужих произведений, охраняемых авторским правом, для обучения нейронных сетей. Обучающие наборы данных часто включают в себя значительные объёмы текстов, изображений, музыкальных произведений и программного кода, полученных из открытых источников, включая те, которые формально защищены авторским правом. Суть проблемы заключается в следующем: не является ли использование таких произведений для анализа, статистического освоения и генерации новых данных нарушением авторских прав, если оно не направлено на непосредственное воспроизведение? В настоящее время в российском законодательстве отсутствует норма, однозначно регламентирующая подобные действия. Однако потенциально такие действия могут квалифицироваться как нарушение положений статьи 1270 ГК РФ, которая устанавливает исключительное право

на воспроизведение и переработку произведений¹.

Подотчетность и ответственность. Внедрение систем ИИ в сферу образования выявило сложные вопросы о распределении ответственности за принимаемые решения и их последствия. Определение четких границ ответственности является ключевым фактором для этичного использования ИИ в образовательном процессе. Проблема ответственности многогранна, затрагивая интересы различных участников: разработчиков систем ИИ, образовательных учреждений, педагогов и самих учащихся. Способность ИИ к независимому и несовершенному принятию решений усложняет вопрос о том, кто несет ответственность за эти решения. Кроме того, прогнозирование всех возможных результатов работы ИИ в динамичной среде образования является сложной задачей, что может привести к непредвиденным последствиям.

Педагогические риски, связанные с применением ИИ, представляют собой возможные угрозы, препятствующие эффективному развитию знаний, умений и навыков учащихся, а также выполнению воспитательных функций образовательного процесса. Эти риски проявляются в форме дегуманизации образовательной среды, уменьшению

воспитательных функций образовательного процесса, возникновения недоверия и сопротивления инновациям в области ИИ, утраты контроля над учебным процессом, необоснованных оценок учебных достижений, случаев академического мошенничества и др. нежелательных последствий.

Дегуманизация образования проявляется в вытеснении человекоцентричных аспектов обучения (эмпатии, творчества, критического мышления) в пользу алгоритмизированных, стандартизированных процессов [12]. Этот аспект означает тенденцию, направленную на вытеснение личности преподавателя из образовательного процесса и частичную передачу его функций различным техническим средствам обучения [13]. Роль педагога в современном учебном процессе трансформируется, приобретая характер «продвинутого оператора» цифровой образовательной среды. Его обязанности включают в себя обновление контента и мониторинг взаимодействия обучаемого с электронными ресурсами.

Обучение включает не только передачу знаний, но и создание эмоциональной связи между учителем и учеником. Преподаватель, будучи носителем знаний и опыта, способен передавать информацию, вдохновлять, мотивировать и направлять процесс обучения, помогать учащемуся развивать критический взгляд, а также аналитические способности и навыки самостоятельного поиска решений. Чрезмерная

¹ Гражданский кодекс Российской Федерации часть 4 (ГК РФ ч.4) // Консультант-Плюс. URL: https://www.consultant.ru/document/cons_doc_LAW_64629/ (дата обращения: 27.12.2025).

зависимость от систем ИИ приводит к утрате благоприятного психологического климата, уменьшению человеческого взаимодействия в учебном процессе между педагогом и учащимися, а также между самими учащимися, – технологии ИИ не могут заменить человеческое общение и эмпатию.

Ограниченное прямое взаимодействие молодых людей со сверстниками и педагогами ведет к дефициту опыта, необходимого для развития важных социальных навыков. Вследствие этого утрачиваются доверительные отношения, затрудняется процесс социализации, а молодые люди могут испытывать неуверенность в себе и замкнутость. Такие тенденции могут негативно повлиять на развитие «мягких» навыков, необходимых для успешной адаптации в обществе и профессиональной деятельности.

Стандартизированные подходы к обучению. Системы ИИ предлагают стандартизированные подходы к обучению, что может привести к тому, что преподаватели будут вынуждены следовать предписанным планам и структурам, что может ограничивать индивидуальность и креативность преподавателей. Вместо того, чтобы разрабатывать инновационные методы преподавания и искать новые способы вовлечения студентов, преподаватели могут начать полагаться на готовые решения, предлагаемые системами ИИ. Это может привести к стандартизации педагогического процесса, упрощению про-

фессиональной деятельности и потере преподавателем уникальности педагогического опыта. Когда система ИИ берет на себя функции планирования уроков, оценки знаний и предоставления обратной связи, преподаватели теряют возможность учиться на собственных ошибках, развивать свои навыки и совершенствовать методики обучения. В конечном итоге это может привести к утрате профессиональной идентичности преподавательской деятельности и снижению ее престижа.

Жесткая стандартизация и регламентация образовательного процесса могут привести к подавлению индивидуальных характеристик учащихся и ограничению их когнитивных способностей исключительно рамками абстрактных цифровых моделей обучения, что отдаляет их от практических реалий жизни [14].

Воспитательный дефицит. Традиционная российская педагогика всегда ставила во главу угла не просто передачу знаний, но и всестороннее духовное развитие и культурную интеграцию подрастающего поколения. Ведущие российские философы и педагоги единогласно подчеркивали неразрывную связь воспитания с образовательным процессом. Выдающийся русский мыслитель И. А. Ильин неустанно подчёркивал нераздельность процессов воспитания и образования, считая их взаимодополняющими элементами. Он считал, что образование без надлежащего воспитания не несёт никакой ре-

альной пользы ни для развивающейся личности, ни для российского общества в целом: «Образование без воспитания не формирует человека, а разнуздывает и портит его, ибо оно дает в его распоряжение жизненно-выгодные возможности, технические умения, которыми он, – бездуховный, бессовестный, безверный и бесхарактерный, – и начинает злоупотреблять» [15, с. 136].

Одна из очевидных и весьма серьезных проблем ИИ и электронной образовательной среды заключается в их неспособности в должной мере выполнять воспитательную функцию, которая, по российской классической педагогической традиции, предполагает не только простую передачу знаний, сколько всестороннее воспитание личности.

Необходимо также учитывать, что применение моделей ИИ может быть использовано институтами или группами, вовлеченными в разработку или финансирование исследований в области ИИ, с целью воздействия на мировоззрение и убеждения пользователей [16].

По мнению Ф. И. Шаркова с коллегами, педагог по-прежнему играет ключевую роль в образовательном процессе, обеспечивая высокое качество профессионального обучения, несмотря на внедрение инновационных цифровых технологий и ИИ в различные форматы образования [17].

Недоверие и сопротивление нововведениям в отношении технологий ИИ – риски, связанные с опасениями и

страхами, которые возникают при внедрении новых технологий (неизвестность, опасность ошибок, этические дилеммы, правовые аспекты). Недоверие и сопротивление нововведениям в сфере ИИ – это реальные риски, которые могут замедлить или даже помешать успешной интеграции этих технологий. Эти риски могут проявляться на разных уровнях – среди обучающихся, преподавателей, руководства, ответственности и родителей.

Студенты могут опасаться, что ИИ сделает их знания устаревшими, или что системы оценки, основанные на ИИ, будут несправедливыми. Они не будут чувствовать себя уверенно, если не понимают, как работают используемые технологии.

Преподаватели могут испытывать боязнь перед тем, что ИИ заменит их роль в образовательном процессе или что им придется осваивать сложные новые инструменты, на которые нет времени и ресурсов. Также могут возникать опасения по поводу потери индивидуального подхода к ученикам и утрате своего педагогического опыта. Постоянные ошибки и несправедливость, возникающие вследствие неправильного обучения на несбалансированном наборе данных, также снижают уровень доверия как преподавателей к используемым инструментам ИИ.

Родители могут беспокоиться о том, как ИИ повлияет на образование их детей, не приведет ли это к снижению качества обучения или к формиро-

ванию зависимости от систем ИИ, насколько безопасно использование таких технологий в личном аспекте из-за возможной утечки персональных данных учащихся, нарушения приватности, злоупотреблений. Например, неконтролируемое распространение технологий распознавания лиц и анализа данных может привести к нарушению конфиденциальности и злоупотреблениям со стороны государства или частных компаний или криминальных структур.

Руководители образовательных учреждений могут колебаться перед внедрением ИИ из-за высоких затрат, неопределенности в плане возврата инвестиций, а также опасений по поводу безопасности данных и потенциальных сбоев в работе систем.

Потеря контроля над процессом обучения. Например, создание индивидуальных учебных программ с помощью нейросети может привести к тому, что учащиеся будут получать только те материалы, которые соответствуют их личным интересам и уровню знаний. Учащиеся могут быть лишены возможности познакомиться с областями знаний, которые выходят за рамки их первоначальных интересов. Это может сузить кругозор и ограничить развитие критического мышления, которое часто формируется при столкновении с различными точками зрения и подходами.

Потеря контроля над процессом обучения порождает академическую нечестность, которая проявляется в различных формах: от списывания до пла-

гиата и подделки курсовых работ, использования запрещенных действий или материалов во время экзаменов (списывание, подсказки, попытки узнать решение у нейросети или найти ответ в Интернете). Например, значительная часть преподавателей (57%) не сталкивалась с подозрением о применении студентами ИИ при выполнении заданий, либо оно крайне возникало [18]. Студенты, прибегающие к нечестным методам обучения, лишают себя возможности получить глубокое знание предмета, развить навыки критического мышления и самостоятельной работы. Вместо того, чтобы усвоить материал, они механически копируют чужие идеи, что ведет к поверхностному пониманию и неспособности применять знания на практике.

Академическое мошенничество студентов – это использование ИИ для нечестного выполнения различного рода заданий или прохождения аттестации. Согласно исследованиям [19], интеграция ИИ в образовательную сферу сопряжена с потенциальными рисками деградации академических ценностей. Имеет негативные последствия для всех участников образовательного процесса: студенты упускают возможность учиться и развивать критические навыки, которые необходимы для их академического и профессионального роста; преподаватели затрудняются с объективной оценкой приобретенных знаний и навыков и прогресса студента, что приводит к искаженным результатам.

Утрата подлинной ценности академических работ. Например, утрата ценности курсового или дипломного проекта, когда их автором выступает не студент, а машинный алгоритм. Использование ИИ для написания академических работ ставит под угрозу принципы академической честности и ответственности, также возникают потенциальные юридические осложнения. Академическая нечестность подрывает авторитет и доверие образовательной организации и девальвирует ценность дипломов. Работодатели теряют уверенность в квалификации кандидатов, а сами студенты, получившие диплом нечестным путем, сталкиваются с проблемами при трудоустройстве и дальнейшем профессиональном росте.

Неравные условия и незаслуженная оценка. Применение искусственного интеллекта в образовательной сфере может привести к возникновению несправедливых преимуществ для некоторых студентов, что противоречит принципу равноправия и объективности оценки знаний, – таково мнение авторов исследования [20]. Если студентам будет позволено получать оценки за работы, созданные ИИ, это, несомненно, обесценит труд тех, кто честно выполняет свои задания самостоятельно.

Высоко оценивать работы, выполненные ИИ, подразумевает приписывание ему человеческих способностей к творчеству, критическому мышлению и пониманию. Это искажает саму сущность образования, которое призвано

развивать эти качества у студентов. Оценка работы ИИ как «человеческой» обесценивает усилия и достижения настоящих учащихся, подрывая ценность образования.

Такая практика противоречит принципу честности, лежащему в основе академической деятельности. Преподаватель, оценивающий работу ИИ как выполненную студентом самостоятельно (его собственную), совершает акт обмана. Это подрывает доверие к системе образования и ставит под сомнение объективность оценки знаний.

Выводы

Внедрение ИИ в сфере высшего образования приобретает статус фундаментального элемента образовательной и научной деятельности, имеет стратегическое значение для подготовки специалистов для работы в различных областях.

Понимание фундаментальных причин рисков, связанных с ИИ в сфере образования, предполагает комплексный междисциплинарный подход. Данные риски обусловлены не только внутренними ограничениями алгоритмов, но и особенностями педагогического процесса, социокультурного контекста их внедрения, а также этическими и правовыми проблемами взаимодействия человека и технологий.

Для эффективной минимизации рисков, связанных с ИИ в образовании, необходимо не только разрабатывать технические решения, но и активно ра-

ботать над изменением образовательных политик, повышением цифровой грамотности всех участников процесса, а также формированием этических норм и стандартов использования ИИ.

Первым шагом должна стать разработка четких правовых норм и стандартов, регулирующих использование ИИ в образовательном процессе, что включает разработку и принятие нормативно-правовых актов, определяющих права и обязанности участников образовательного процесса в условиях использования ИИ.

Следующим этапом должно стать создание инновационных подходов к обучению, учитывающих возможности ИИ. Необходимо разработать новые образовательные методики и педагогические технологии, позволяющие эффек-

тивно интегрировать технологии ИИ в учебный процесс.

Также для успешной интеграции ИИ необходима соответствующая квалификация профессорско-преподавательского состава. Важно организовать обучение педагогов новым технологиям и методикам работы с ними.

Наилучшие результаты от внедрения ИИ будут достигнуты при условии формирования такой образовательной среды, которая сохранит ценность традиционного преподавания под руководством педагога, но при этом будет активно использовать и интегрировать возможности ИИ. Только комплексный подход, учитывающий все эти аспекты, позволит нам раскрыть весь его потенциал, минимизируя при этом возможные риски.

Список литературы

1. ИИ грянул гром?... Искусственный интеллект для высшей школы: угрозы и возможности // Аккредитация в образовании. 2023. № 6(146). С. 4–17. EDN TUZAGC
2. Талапина Э. В. Прозрачность алгоритмов искусственного интеллекта // Право. Журнал Высшей школы экономики. 2025. Т. 18, № 3. С. 4–27. <https://doi.org/10.17323/2072-8166.2025.3.4.27>
3. Биричева Е. В. Преодоление рисков использования нейросетей для генерации текста: когнитивные, этические, педагогические аспекты // Философия образования. 2025. Т. 25, № 1. С. 57–75. <https://doi.org/10.15372/PHE20250104>
4. Корж Е. М., Громова А. В. Потенциал применения технологий искусственного интеллекта в психологии // Системная психология и социология. 2023. № 2 (46). С. 60–70. <https://doi.org/10.25688/2223-6872.2023.46.2.5>
5. Эффект сверхуверенности, или почему важно измерять результат. URL: <https://4brain.ru/blog/effekt-sverhuverennosti-ili-pochemu-vazhno-izmeryat-rezultat/> (дата обращения: 10.12.2025).

6. Волков Д. Н., Зиновьева Е. В. Проявление когнитивного бессознательного в феномене сверхуверенности // Вестник Санкт-Петербургского университета. Серия 12. Психология. Социология. Педагогика. 2011. № 1. С. 314–323.
7. Емельяненко В. Д. Влияние искусственного интеллекта на когнитивную сферу человека в контексте ценностно-мировоззренческого анализа // Манускрипт. 2025. Т. 18, № 2. С. 519–527. <https://doi.org/10.30853/mns20250074>
8. Авдеева Е. А., Корнилова О. А. Влияние цифровой электронной среды на когнитивные функции школьников и студентов // Кардиоваскулярная терапия и профилактика. 2022. Т. 21, № S3. С. 43–50. <https://doi.org/10.15829/1728-8800-2022-3331>. EDN SMCSJE
9. Шукова Г. В. Современные психологические исследования лени: лень есть или лени нет? // Общество: социология, психология, педагогика. 2021. № 6. С. 77–84. <https://doi.org/10.24158/spp.2021.6.12>
10. Давудова С. Я., Рагимханова К. Т. Правовое регулирование искусственного интеллекта в образовании // Закон и право. 2025. № 3. С. 57–62. <https://doi.org/10.24412/2073-3313-2025-3-57-62>
11. Абдусаламов Р. А. Основные направления правового регулирования использования искусственного интеллекта в сфере высшего образования // Юридический вестник Дагестанского государственного университета. 2024. Т. 52, № 4 (72). С. 135–143. <https://doi.org/10.21779/2224-0241-2024-52-4-135-143>
12. Берман Н. Д. Преодоление вызовов внедрения ИИ-агентов в образовательной среде: фокус на этические аспекты и риски // ЦИТИСЭ. 2025. № 3. С. 166–177.
13. Аблеев С. Р., Кузьминская С. И. Технологическая дегуманизация образования: сущность проблемы и социально-психологические последствия // Вестник Московского университета МВД России. 2019. № 6. С. 314–318.
14. Аблеев С. Р., Кузьминская С. И. Цифровые технологии в системе образования: проблема дегуманизации // Юридическая наука и практика: Вестник Нижегородской академии МВД России. 2020. № 1(49). С. 231–233. EDN BLMOMG.
15. Ильин И. А. Наши задачи: историческая судьба и будущее России: статьи 1948-1954 гг.: в 2 т. М.: Рарог, 1992. Т. 1–2. 616 с.
16. Зиньковская А. В., Оломская Н. Н. Манипуляция человеческим сознанием посредством искусственного интеллекта как гуманитарная проблема XXI века // Российский социально-гуманитарный журнал. 2024. № 1. С. 258–276. <https://doi.org/10.18384/2224-0209-2024-1-1386>
17. Новые коммуникационные тренды в образовании: цифровые технологии и искусственный интеллект / Ф. И. Шарков, В. Т. Абишева, М. А. Лучина, В. А. Потапчук, Ж. С. Рамазанова // Коммуникология. 2022. Т. 10, № 3. С. 67–86.

18. Отношение студентов и преподавателей к использованию инструментов с искусственным интеллектом в вузе / К. И. Буякова, Я. А. Дмитриев, А. С. Иванова, А. В. Фещенко, К. И. Яковлева // Образование и наука. 2024. Т. 26, № 7. С. 160–193. <https://doi.org/10.17853/1994-5639-2024-7-160-193>
19. Головина И. В., Александрова Т. Я. Цифровизация образования: риски и последствия // Образовательные ресурсы и технологии. 2024. № 1(46). С. 17–22. <https://doi.org/10.21777/2500-2112-2024-1-17-22>
20. Шустров А. С., Ширина Т. Г. ИИ в академической среде вуза: этические последствия и механизмы их минимизации // Мир науки. Педагогика и психология. 2025. Т. 13, № 5. С. 1–15.

References

1. Did artificial intelligence cause thunder?... Artificial intelligence for higher education: threats and opportunities. *Akkreditaciya v obrazovanii = Accreditation in Education*. 2023;(6):4–17. (In Russ.) EDN TUZAGC
2. Talapina E.V. Transparency of artificial intelligence algorithms. *Pravo. Zhurnal Vysshej shkoly ekonomiki = Right. Journal of the Higher School of Economics*. 2025;18(3):4–27. (In Russ.) <https://doi.org/10.17323/2072-8166.2025.3.4.27>
3. Biricheva E.V. Overcoming the risks of using neural networks for text generation: cognitive, ethical, and pedagogical aspects. *Filosofiya obrazovaniya = Philosophy of Education*. 2025;25(1):57–75. (In Russ.) <https://doi.org/10.15372/PHE20250104>
4. Korzh E.M., Gromova A.V. The potential of using artificial intelligence technologies in psychology. *Sistemnaya psihologiya i sociologiya = System Psychology and Sociology*. 2023;(2):60–70. (In Russ.) <https://doi.org/10.25688/2223-6872.2023.46.2.5>
5. The overconfidence effect, or why it's important to measure results. (In Russ.-.) Available at: <https://4brain.ru/blog/effekt-sverhuverennosti-ili-pochemu-vazhno-izmeryat-rezultat/> (accessed 10.12.2025).
6. Volkov D.N., Zinovieva E.V. The manifestation of the cognitive unconscious in the phenomenon of overconfidence. *Vestnik Sankt-Peterburgskogo universiteta. Seriya 12. Psihologiya. Sociologiya. Pedagogika = Bulletin of St. Petersburg University. Episode 12. Psychology. Sociology. Pedagogy*. 2011;(1):314–323. (In Russ.)
7. Emel'yanenko V.D. The influence of artificial intelligence on the cognitive sphere of man in the context of value-worldview analysis analysis. *Manuskript = Manuscript*. 2025;18(2):519–527. (In Russ.) <https://doi.org/10.30853/mns20250074>
8. Avdeeva E.A., Kornilova O.A. The influence of the digital electronic environment on the cognitive functions of schoolchildren and students. *Kardiovaskulyarnaya terapiya i pro-*

filaktika = Cardiovascular Therapy and Prevention. 2022;21(S3):43–50. (In Russ.) <https://doi.org/10.15829/1728-8800-2022-3331>. EDN SMCSJE

9. Shukova G.V. Modern psychological studies of laziness: is there laziness or is there no laziness? *Obshchestvo: sociologiya, psihologiya, pedagogika = Society: Sociology, Psychology, Pedagogy*. 2021;(6):77–84. (In Russ.) <https://doi.org/10.24158/spp.2021.6.12>

10. Davudova S.Ya., Ragimkhanova K.T. Legal regulation of artificial intelligence in education. *Zakon i parvo = Law and Law*. 2025;(3):57–62. (In Russ.) <https://doi.org/10.24412/2073-3313-2025-3-57-62>

11. Abdusalamov R.A. The main directions of legal regulation of the use of artificial intelligence in higher education. *Yuridicheskii vestnik Dagestanskogo gosudarstvennogo universiteta = Law Bulletin of Dagestan State University*. 2024;4(72):135–143. (In Russ.) <https://doi.org/10.21779/2224-0241-2024-52-4-135-143>

12. Berman N.D. Overcoming the challenges of introducing AI agents in the educational environment: focus on ethical aspects and risks. *CITISE = CITISE*. 2025(3):166–177. (In Russ.)

13. Ableev S.R., Kuz'minskaya S.I. Technological dehumanization of education: the essence of the problem and socio-psychological consequences. *Vestnik Moskovskogo universiteta MVD Rossii = Bulletin of the Moscow University of the Ministry of Internal Affairs of Russia*. 2019;(6):314–318. (In Russ.)

14. Ableev S.R., Kuz'minskaya S.I. Digital technologies in the education system: the problem of dehumanization. *Vestnik Moskovskogo universiteta MVD Rossii = Legal Science and Practice: Bulletin of the Nizhny Novgorod Academy of the Ministry of Internal Affairs of Russia*. 2020;(1):231–233. (In Russ.) EDN BLMOMG

15. Il'in I.A. Our tasks: the historical fate and the future of Russia: Articles from 1948-1954 gg. Vol. 1-2. Moscow: Papor; 2012. 616 p. (In Russ.)

16. Zin'kovskaya A.V., Olomskaya N.N. Manipulation of human consciousness through artificial intelligence as a humanitarian problem of the 21st century. *Rossiiskij social'no-gumanitarnyj zhurnal = Russian Social and Humanitarian Journal*. 2024;(1):258–276. (In Russ.) <https://doi.org/10.18384/2224-0209-2024-1-1386>

17. Sharkov F.I., Abisheva V.T., Luchina M.A., Potapchuk V.A., Ramazanova Zh.S. New communication trends in education: digital technologies and artificial intelligence. *Kommunikologiya = Communication Science*. 2022;10(3):67–86. (In Russ.)

18. Buyakova K.I., Dmitriev Ya.A., Ivanova A.S., Feshchenko A.V., Yakovleva K.I. The attitude of students and teachers to the use of artificial intelligence tools in higher education. *Obrazovanie i nauka = Education and Science*. 2024;26(7):160–193. (In Russ.) <https://doi.org/10.17853/1994-5639-2024-7-160-193>

19. Golovina I.V., Aleksandrova T.Ya. Digitalization of education: risks and consequences. *Obrazovatel'nye resursy i tekhnologii = Educational Resources and Technologies*. 2024;(1):17–22. (In Russ.) <https://doi.org/10.21777/2500-2112-2024-1-17-22>

20. Shustrov A.S., Shiroka T.G. AI in the academic environment of the university: ethical consequences and mechanisms of their minimization. *Mir nauki. Pedagogika i psihologiya = The World of Science. Pedagogy and Psychology*. 2025;13(5):1–15. (In Russ.)

Информация об авторах / Information about the Authors

Томакова Римма Александровна, доктор технических наук, профессор кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: rtomakova@mail.ru,
ORCID: 0000-0003-0152-4714,
Author ID: 739221

Rimma A. Tomakova, Doctor of Sciences (Engineering), Professor at the Department of Software Engineering, Southwest State University, Kursk, Russian Federation,
e-mail: rtomakova@mail.ru,
ORCID: 0000-0003-0152-4714,
Author ID: 739221

Томаков Владимир Иванович, доктор педагогических наук, профессор кафедры охраны труда и окружающей среды, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: tomakov52@mail.ru,
ORCID: 0000-0003-1051-9722,
Author ID: 509007

Vladimir I. Tomakov, Doctor of Sciences (Pedagogical), Professor at the Department of Labor Protection and Environment, Southwest State University, Kursk, Russian Federation,
e-mail: tomakov52@mail.ru,
ORCID: 0000-0003-1051-9722,
Author ID: 509007

<https://doi.org/10.21869/2223-1536-2026-16-1-38-49>



УДК 617.51–001.4

Прогнозирование восстановления пациентов после черепно-мозговой травмы

Н. М. Агарков^{1,3}✉, А. С. Лысенко²

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

² Курская городская больница № 1 имени Н. С. Короткова
ул. Садовая, д. 40, г. Курск 305004, Российская Федерация

³ Белгородский государственный национальный исследовательский университет
ул. Победы, д. 85, г. Белгород 308015, Российская Федерация

✉ e-mail: vitalaxen@mail.ru

Резюме

Цель исследования – разработка регрессионных моделей для прогнозирования восстановления пациентов после черепно-мозговой травмы.

Методы. В клинических условиях обследовано 125 пациентов, перенёвших лёгкой и средней степени тяжести черепно-мозговую травму. Обследование пациентов проводилось через 10-21 дней после получения черепно-мозговой травмы. Уровень когнитивного резерва оценивался по общепринятой методике, где доминирующим являлось образование пациента. Для построения математических моделей применялся многофакторный логистический регрессионный анализ и стандартный статистический пакет Statistica 10.0.

Результаты. Полученные значения коэффициентов β логистической регрессии свидетельствуют об обратном влиянии возраста от 51-60 и от 61 года и более на восстановление пациентов после черепно-мозговой травмы. В скорректированной модели восстановление после перенёшенной черепно-мозговой травмы зависит существенно от места проживания, а именно от проживания в сельской местности, что объясняется меньшей доступностью специализированной медицинской помощи, чем в городах. Позитивно на восстановление после черепно-мозговой травмы влияет полная семья пациента, и наоборот, замедляет процесс восстановления наличие неполной семьи. При включении в прогностическую модель 3-х параметров когнитивного резерва величины коэффициентов β для большинства факторов возросли, в том числе и для возрастных групп, и особенно для возраста 40-50 лет – более чем в 2 раза ($p < 0,01$). Однако наиболее высоко влияние на восстановление после черепно-мозговой травмы когнитивного резерва пациентов. Включение в модель 4-го уровня образования пациентов свидетельствует о наибольшей ассоциации восстановления пациентов после черепно-мозговой травмы с высшим / средним специальным образованием, но она ниже ассоциации с уровнем когнитивного резерва в модели 3.

Заключение. Полученные результаты показывают, что для прогнозирования восстановления пациентов после перенесенной черепно-мозговой травмы следует использовать следующие зависимые переменные: уровень когнитивного резерва, высшее / среднеспециальное образование, проживание в сельской местности, в полной или неполной семье.

Ключевые слова: черепно-мозговая травма; когнитивный резерв; прогнозирование.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Агарков Н. М., Лысенко А. С. Прогнозирование восстановления пациентов после черепно-мозговой травмы // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 38–49. <https://doi.org/10.21869/2223-1536-2026-16-1-38-49>

Поступила в редакцию 17.01.2026

Подписана в печать 16.02.2026

Опубликована 31.03.2026

Predicting recovery of patients after traumatic brain injury

Nikolay M. Agarkov^{1,3} ✉, Anastasia S. Lysenko²

¹ Southwest State University

50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

² Kursk City Hospital No. 1 named after N. S. Korotkov

40 Sadovaya Str., Kursk 305004, Russian Federation

³ Belgorod State National Research University

85 Pobedy Str., Belgorod 308015, Russian Federation

✉ e-mail: vitalaxen@mail.ru

Abstract

The purpose of the research is to develop regression models for predicting the recovery of patients after traumatic brain injury.

Methods. 125 patients with mild to moderate traumatic brain injury were examined in clinical conditions. The patients were examined 10-21 days after receiving a traumatic brain injury. The level of cognitive reserve was assessed according to a generally accepted methodology, where the patient's education was dominant. Multivariate logistic regression analysis and the standard statistical package Statistica 10.0 were used to build mathematical models.

Results. The obtained values of the coefficients of β logistic regression indicate the opposite effect of ages from 51-60 and from 61 years or more on the recovery of patients after traumatic brain injury. In the adjusted model, recovery after a traumatic brain injury depends significantly on the place of residence, namely, living in rural areas, which is explained by the lower availability of specialized medical care than in cities. The patient's full family has a positive effect on recovery from traumatic brain injury, and vice versa, the presence of an incomplete family slows down the recovery process. When 3 parameters of the cognitive reserve were included in the predictive model, the values of the β coefficients for most factors increased, including for age groups, and especially for the age of 40-50 years – by more than 2 times ($p < 0.01$). However, the cognitive reserve of patients has the highest impact on recovery after traumatic brain injury. The inclusion of patients' level of education in model 4 indicates the greatest association of patients' recovery from traumatic brain injury with higher/secondary specialized education, but it is lower than the association with the level of cognitive reserve in model 3.

Conclusion. The results show that the following dependent variables should be used to predict the recovery of patients after traumatic brain injury: the level of cognitive reserve, higher/secondary specialized education, living in rural areas, in a full or incomplete family.

Keywords: traumatic brain injury; cognitive reserve; prognosis.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Agarkov N.M., Lysenko A.S. Predicting recovery of patients after traumatic brain injury. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie*.

Введение

Черепно-мозговая травма (ЧМТ) – это повреждение головного мозга в результате воздействия внешней механической силы, приводящее к временному или постоянному нарушению функций головного мозга [1]. В Европе, по экспертным оценкам, ЧМТ получают 235 человек на 100 000 населения в год, из них около 9% – в тяжёлой форме [2]. В США центры по контролю и профилактике заболеваний зафиксировали 2,53 млн обращений в отделения неотложной помощи в связи с ЧМТ в 2019 г. Было зарегистрировано около 288 000 случаев госпитализации в связи с ЧМТ и 56 800 случаев смерти в связи с ЧМТ [1]. ЧМТ является основной причиной инвалидности среди молодых людей во всем мире, что приводит к значительным экономическим последствиям для национальных систем здравоохранения [3]. Функциональное и когнитивное восстановление после ЧМТ характеризуется высокой вариативностью [4]. Такая неоднородность результатов отчасти объясняется характеристиками травмы, такими как размер и особенности повреждения головного мозга и тяжесть [5]. В зависимости от тяжести травмы ЧМТ может быть лёгкой, средней или тяжёлой. В этом контексте тяжёлая ЧМТ связана с патологическим событием неврождённого, перинаталь-

ного или дегенеративного характера, приводящим к коме с оценкой по шкале комы Глазго в острой фазе от 3 до 8 баллов, длящейся более 24 часов, наличием аномалий при нейровизуализации и посттравматической амнезией продолжительностью более 7 дней [6].

Наиболее тяжёлая форма ЧМТ (тяжёлая ЧМТ) характеризуется большим разбросом исходов – от смерти до благоприятного исхода [1]. Прогнозировать долгосрочный исход для отдельных пациентов невозможно, но выполненные исследования показывают, что на него влияет сочетание демографических факторов, связанных с травмой и когнитивных факторов [6]. Когнитивный дефицит является распространённым явлением после тяжёлой ЧМТ и влияет на работу, досуг и повседневную деятельность [7]. Измерение когнитивного дефицита с использованием полной нейропсихологической оценки занимает много времени, и на ранних стадиях после ЧМТ тяжёлой степени это может быть невозможно из-за физических травм и недостаточной выносливости пациентов [8]. Поэтому более короткий скрининг когнитивных функций может быть предпочтительнее, но необходимо обеспечить, чтобы более короткие скрининги охватывали когнитивные функции, важные для достижения результата.

Поэтому можно считать, что восстановление пациентов после ЧМТ во многом зависит от параметров когнитивного резерва, общего состояния здоровья и некоторых медико-демографических характеристик травмированных пациентов. Степень влияния названных факторов, как и их прогностическая значимость, на реабилитацию пациентов, перенесших ЧМТ, неоднозначна. В связи с этим возникает необходимость в разработке прогностических моделей, способных адекватно выполнить задачу с использованием выделенных ведущих предикторов, определяющих восстановление пациентов после ЧМТ.

Цель исследования – разработка регрессионных моделей для прогнозирования восстановления пациентов после ЧМТ.

Материалы и методы

В клинических условиях обследовано 125 пациентов, перенёсших лёгкой и средней степени тяжести ЧМТ. Обследование пациентов проводилось через 10-21 день после получения ЧМТ соответственно. Среди переменных, влияющих на выздоровление пациентов с ЧМТ, рассматривались:

- уровень когнитивного резерва;
- возраст пациентов 40-50 лет;
- возраст пациентов 51-60 лет;
- возраст 61 год и более;
- мужской пол;
- женский пол;
- проживание в городе;

- проживание в сельской местности;
- полная семья;
- неполная семья;
- восьмилетнее образование;
- среднее образование;
- высшее образование / среднее специальное образование.

В качестве результирующей переменной рассматривалась способность пациентов после перенесённой ЧМТ выполнять самостоятельно ежедневные бытовые задачи: одевание, приготовление и приём пищи, перемещение по дому, соблюдение гигиены.

Уровень когнитивного резерва оценивался по общепринятой методике [9], где доминирующим являлось образование пациента, поскольку считается, что оно в большей степени способствует разветвлённой синаптической связи головного мозга и степень её развития может влиять на исход и процесс выздоровления после ЧМТ. Уровень когнитивного резерва определялся у пациентов с лёгкой степенью ЧМТ через 10 дней после её получения, а в случае средней степени тяжести ЧМТ – через 20 дней после ЧМТ. Другие зависимые переменные извлекались из медицинских карт стационарного больного, а в случае отсутствия их в указанной официальной медицинской форме получены путём опроса пациентов.

Исследование осуществлялось с соблюдением этических норм и принципов Хельсинской декларации.

Для построения математических моделей применялись многофакторный

логистический регрессионный анализ и стандартный статистический пакет Statistica 10.0. Различие принималось статистически значимым при $p < 0,05$.

Результаты и их обсуждение

Полученные значения коэффициентов β логистической регрессии свидетельствуют об обратном влиянии возраста от 51-60 и от 61 года и более на восстановление пациентов после ЧМТ

(табл. 1) без учёта других изученных социально-демографических факторов. Однако при аналогичном подходе в модели 1 выявлена статистически значимая связь возраста 40-50 лет с восстановлением после ЧМТ, что указывает на то, что в данной возрастной группе восстановление происходит полностью, а прямая связь свидетельствует о позитивном влиянии возраста 40-50 лет на процесс восстановления.

Таблица 1. Влияние демографических факторов на восстановление пациентов после ЧМТ без учёта когнитивного резерва и уровня образования

Table 1. The influence of demographic factors on the recovery of patients after TBI without taking into account cognitive reserve and educational level

Зависимая переменная	Модель 1	p_1	Модель 2	p_2
Возраст 40-50 лет	0,325	$<0,05$	0,419	$<0,05$
Возраст 51-60 лет	0,548	$<0,01$	-0,706	$<0,01$
Возраст 61 год и более	0,629	$<0,01$	-0,838	$<0,01$
Мужской пол	—	—	0,391	$>0,05$
Женский пол	—	—	0,287	$>0,05$
Проживание в городе	—	—	1,459	$<0,01$
Проживание в сельской местности	—	—	0,883	$<0,001$
Полная семья	—	—	1,528	$<0,001$
Неполная семья	—	—	-1,349	$<0,001$

После добавления других социально-демографических факторов в регрессионный анализ в полученной модели 2 установлено повышение значимости ранее рассмотренных параметров возраста в восстановлении пациентов после ЧМТ с сохранением направленности ассоциаций. В скорректированной модели восстановление после перенёсшей ЧМТ зависит существенно от места проживания, а именно от прожи-

вания в сельской местности, что объясняется меньшей доступностью специализированной медицинской помощи, чем в городах. Позитивно на восстановление после ЧМТ влияет полная семья пациента, и наоборот, замедляет процесс восстановления наличие неполной семьи. Не оказывает существенного влияния на восстановление пациентов в скорректированной модели пол пациентов, который в одинаковой степени и

недостаточно связан с результирующей переменной.

Включение уровня когнитивного резерва и образования в прогностические модели 3 и 4 соответственно изменило неоднозначно влияние ранее рассмотренных возрастного и социально-демографических факторов (табл. 2). При включении в прогностическую модель 3 параметров когнитивного резерва величины коэффициентов β для большинства факторов возросли, в т. ч.

и для возрастных групп, и особенно для возраста 40-50 лет – более чем в 2 раза ($p < 0,01$). Однако наиболее высоко влияние на восстановление после ЧМТ когнитивного резерва пациентов. Наряду с этим при включении в модель 3 параметров когнитивного резерва увеличилась прямая ассоциация восстановления пациентов с проживанием в городе, в сельской местности, в полной семье и обратная сопряжённость с проживанием в неполной семье.

Таблица 2. Влияние демографических факторов на восстановление пациентов после ЧМТ с учётом уровня когнитивного резерва и уровня образования

Table 2. The influence of demographic factors on the recovery of patients after TBI, taking into account the level of cognitive reserve and the level of education

Зависимая переменная	Модель 3	p_3	Модель 4	p_4
Возраст 40-50 лет	0,685	$<0,01$	0,539	$<0,01$
Возраст 51-60 лет	-0,637	$<0,01$	-0,471	$<0,05$
Возраст 61 год и более	-0,814	$<0,001$	-0,627	$<0,01$
Мужской пол	0,209	$>0,05$	0,228	$>0,05$
Женский пол	0,362	$<0,05$	0,318	$>0,05$
Проживание в городе	1,284	$<0,001$	1,321	$<0,001$
Проживание в сельской местности	1,592	$<0,001$	1,036	$<0,001$
Полная семья	1,635	$<0,001$	1,316	$<0,001$
Неполная семья	-1,548	$<0,001$	-1,202	$<0,001$
Уровень когнитивного резерва	1,976	$<0,001$	–	–
Восьмилетнее образование	–	–	0,543	$<0,05$
Среднее образование	–	–	0,708	$<0,01$
Высшее / Среднее специальное образование	–	–	1,764	$<0,001$

Следовательно, уровень когнитивного резерва пациентов повышает вероятность их восстановления после перенесённой ЧМТ, и поэтому реализация мероприятий по повышению когнитив-

ного резерва в восстановительном периоде является, на наш взгляд, важной задачей.

Включение в модель 4 уровня образования пациентов свидетельствует о

наибольшей ассоциации восстановления пациентов после ЧМТ с высшим / средним специальным образованием, но она ниже ассоциации с уровнем когнитивного резерва в модели 3 (табл. 2). Значение восьмилетнего и среднего образования в восстановительном процессе при ЧМТ достоверно ниже, чем высшего образования и ряда социально-демографических факторов: проживание в городской местности, проживание в сельской местности, полной и неполной семье.

Разработанные прогностические модели показывают, что восстановление пациентов после перенесённой ЧМТ зависит от уровня когнитивного резерва, высшего / среднего специального образования, проживания в сельской местности, в полной или неполной семье [10]. При этом проживание в неполной семье негативно влияет на восстановление после ЧМТ, тогда как другие вышеназванные факторы – позитивно, особенно когнитивный резерв [11]. Последний рассматривается как свойство головного мозга с множественными потенциальными механизмами, помогающими справиться и восстановиться в связи с изменениями головного мозга, возникшими в результате ЧМТ [12]. Показана неизменная роль когнитивного резерва и возраста в восстановлении пациентов с ЧМТ [13]. Когнитивный резерв, определяемый в большей степени уровнем образования, влияет на процесс восстановления после перенесённой ЧМТ, подтверждая результаты нейропсихологических те-

стов, включая скрининги высших мозговых функций. Однако, по мнению исследователей [13], связь между когнитивным резервом и результатами тестов не означает автоматической связи между результатами тестов скрининга высших мозговых функций и восстановлением. При исследовании взаимосвязи между когнитивным скринингом и функциональными исходами после тяжёлой ЧМТ важно принимать во внимание возраст, тяжесть травмы и когнитивный резерв [14]. После тяжёлой ЧМТ даже при том, что большинство улучшений происходит в течение первого года, изменения в функциональных результатах, как улучшения, так и ухудшения, могут продолжаться в течение нескольких лет. Учитывая, что ЧМТ часто поражает молодых людей, которые, как ожидается, проживут со своей травмой десятилетия, важно проводить исследования с более длительным интервалом наблюдения [15].

Однако, в отличие от нашего исследования, восстановление после ЧМТ авторами оценивалось по индексу адекватности Mayo-Portland и не рассчитывались прогностические показатели с учётом когнитивного резерва и социально-демографических факторов. Вместе с тем установлено влияние образования на исход ЧМТ, как и в нашем исследовании, согласно которому образование ассоциировано с восстановлением пациентов с ЧМТ, и особенно высоко влияние на исход ЧМТ высшего / среднего специального образования.

ЧМТ часто сопровождается двигательными и когнитивными нарушениями [16], что способствует формированию ограничений в повседневной жизни таких пациентов [17]. Так, при обследовании через 21 день после ЧМТ у 63,8% пациентов наблюдалась повышенная утомляемость, а у 72,3% – снижение настроения. Однако при применении скрининговых методик для оценки когнитивных функций в группе пациентов с ЧМТ не выявлено достоверных отличий от результатов контрольной группы [16].

Использование шкалы Глазго для оценки исходов ЧМТ в качестве зависимой переменной и независимых переменных (возраст, пол, уровень образования, когнитивный резерв) позволило установить методом одномерной линейной регрессии влияние пола (коэффициент логистической регрессии $\beta = 1,208$) и психических заболеваний (коэффициент логистической регрессии $\beta = 1,054$) [18]. Однако авторами, в отличие от результатов нашего исследования, не выявлено ассоциации исходов ЧМТ по шкале Глазго с когнитивным резервом (коэффициент логистической регрессии $\beta = -0,28$).

Обнаружено, что у пожилых людей наблюдались значительно худшие долгосрочные результаты, чем у молодых, несмотря на менее тяжелые первоначальные травмы головы. Так, к факторам, повышающих риск неблагоприятного исхода, относится пожилой воз-

раст и гипотония [19]. Кроме того, другие исходные характеристики при поступлении, такие как оценка по шкале Глазго и зрачковая реактивность, традиционно считаются неблагоприятными показателями. Что касается дополнительных показателей визуализации, отмечено, что внутримозговое кровоизлияние, травматическая субарахноидальная гематома и базальная цистерна (облитерация или сдавление) являются дополнительными показателями, повышающими точность прогнозирования исхода [20].

Выводы

Полученные результаты показывают, что для прогнозирования восстановления пациентов после перенесенной ЧМТ следует использовать следующие зависимые переменные: уровень когнитивного резерва, высшее / среднее специальное образование, проживание в сельской местности, в полной или неполной семье. При этом практически все вышеназванные зависимые переменные, за исключением проживания в неполной семье, позитивно влияют на восстановление пациентов, и особенно уровень когнитивного резерва. Напротив, неполная семья отрицательно влияет на восстановление пациентов после ЧМТ, что указывает на важность использования этой зависимой переменной для прогнозирования восстановления пациентов с ЧМТ.

Список литературы

1. Capizzi A., Woo J., Verduzco-Gutierrez M. Traumatic brain injury // *Med. Clin. North. Am.* 2020. N 104. P. 213–238. <https://doi.org/10.1016/j.mcna.2019.11.001>
2. Redefining a minimal rehabilitation assessment protocol for severe acquired brain injuries / S. Lavezzi, S. Bargellesi, A. Cassio [et al.] // *Eur. J. Phys. Rehabil. Med.* 2022. Vol. 58, N 4. P. 584-591. <https://doi.org/10.23736/s1973-9087.22.07451-2>
3. Recovery from disorders of consciousness: mechanisms, prognosis and emerging therapies / B. L. Edlow, J. Claassen, N. D. Schiff [et al.] // *Nat. Rev. Neurol.* 2021. Vol. 17, N 3. P. 135-156. <https://doi.org/10.1038/s41582-020-00428-x>
4. Recovery of consciousness and functional outcome in moderate and severe traumatic brain injury / R. G. Kowalski, F. M. Hammond, A. H. Weintraub [et al.] // *JAMA Neurol.* 2021. Vol. 78, N 5. P. 548-557. <https://doi.org/10.1001/jamaneurol.2021.0084>
5. Traumatic brain injury and risk of long-term brain changes, accumulation of pathological markers, and developing dementia: a review / C. LoBue, C. Munro, J. Schaffert [et al.] // *J. Alzheimers Dis.* 2019. Vol. 70, N 3. P. 629-654. <https://doi.org/10.3233/jad-190028>
6. Relationships between neuropsychological impairments and functional outcome eight years after severe traumatic brain injury: Results from the PariS-TBI study / C. Vallat-Azouvi, M. Swaenepoël, A. Ruet [et al.] // *Brain. Inj.* 2021. N 35. P. 1001–1010. <https://doi.org/10.1080/02699052.2021.1933180>
7. A Detailed Overview of Long-Term Outcomes in Severe Traumatic Brain Injury Eight Years Post-injury / A. Ruet, E. Bayen, C. Jourdan [et al.] // *Front. Neurol.* 2019. N 10. P. 120. <https://doi.org/10.3389/fneur.2019.00120>
8. Neuropsychological Recovery Trajectories in Moderate to Severe Traumatic Brain Injury: Influence of Patient Characteristics and Diffuse Axonal Injury / A. R. Rabinowitz, T. Hart, J. Whyte [et al.] // *J. Int. Neuropsychol. Soc.* 2018. N 24. P. 237–246. <https://doi.org/10.1017/S1355617717000996>
9. Стрижицкая О. Ю. Когнитивный резерв как детерминанта позитивного старения // *Мир педагогики и психологии.* 2019. № 1. С. 200-210.
10. The impact of cognitive reserve on delayed neurocognitive recovery after major non-cardiac surgery: an exploratory substudy / E. Kainz, N. Juilfs, U. Harler [et al.] // *Front Aging Neurosci.* 2023. N 15. P. 1267998. <https://doi.org/10.3389/fnagi.2023.1267998>
11. Measuring cognitive reserve (CR) – a systematic review of measurement properties of CR questionnaires for the adult population / N. Kartschmit, R. Mikolajczyk, T. Schubert [et al.] // *PLoS One.* 2019. N 14. P. e0219851. <https://doi.org/10.1371/journal.pone.0219851>
12. Identification of individuals at risk for postoperative cognitive dysfunction (POCD) / X. Yang, X. Huang, M. Li [et al.] // *Ther. Adv. Neurol. Disord.* 2022. N 15. P. 175628642211143. <https://doi.org/10.1177/17562864221114356>

13. Cognitive Reserve, Early Cognitive Screening, and Relationship to Long-Term Outcome after Severe Traumatic Brain Injury / N. Ekdahl, A. K. Godbolt, C. N. Deboussard [et al.] // *J. Clin. Med.* 2022. Vol. 11, N 7. P. 2046. <https://doi.org/10.3390/jcm11072046>
14. Dimensions of cognitive reserve and their predictive power of cognitive performance and decline in the elderly / T. D. Ser, E. Valeriano-Lorenzo, L. Janez-Escalada [et al.] // *Front Dement.* 2023. N 2. P. 1099059. <https://doi.org/10.3389/frdem.2023.1099059>
15. Long-term outcome after severe traumatic brain injury: A systematic literature review / C. Q. Mostert, R. D. Singh, M. Gerritsen [et al.] // *Acta. Neurochir.* 2022. N 164. P. 599-613. <https://doi.org/10.1007/s00701-021-05086-6>
16. Когнитивные и двигательные нарушения у больных с последствием черепно-мозговой травмы / И. Ш. Шоджалилов, А. Т. Джурабекова, Н. Н. Абдуллаева, Н. Б. Муродова // *Достижения науки и образования.* 2019. № 13. С. 107-110.
17. Возрастная жизнеспособность в критические периоды жизни пациентов при зрительном дефиците и травмах / М. А. Неудачин, Н. М. Агарков, А. С. О. Ибиев [и др.] // *Научные результаты биомедицинских исследований.* 2025. Т. 11, № 4. С. 727-741. <https://doi.org/10.18413/2658-6533-2025-11-4-1-0>
18. Cognitive reserve index and long-term disability in patients with severe traumatic brain injury discharged from the intensive rehabilitation unit / B. Hakiki, S. Pancini, A. M. Romoli [et al.] // *Front Neurol.* 2023. N 14. P. 1106989. <https://doi.org/10.3389/fneur.2023.1106989>
19. Defining Hypotension in Patients with Severe Traumatic Brain Injury / K. Shibahashi, K. Sugiyama, Y. Okura [et al.] // *World Neurosurg.* 2018. N 120. P. e667–e674. <https://doi.org/10.1016/j.wneu.2018.08.142>
20. Helsinki Computed Tomography Scoring System Can Independently Predict Long-Term Outcome in Traumatic Brain Injury / S. Yao, J. Song, S. Li [et al.] // *World Neurosurg.* 2017. N 101. P. 528-533. <https://doi.org/10.1016/j.wneu.2017.02.072>

References

1. Capizzi A., Woo J., Verduzco-Gutierrez M. Traumatic brain injury. *Med. Clin. North. Am.* 2020;(104):213–238. <https://doi.org/10.1016/j.mcna.2019.11.001>
2. Lavezzi S., Bargellesi S., Cassio A., et al. Redefining a minimal rehabilitation assessment protocol for severe acquired brain injuries. *Eur. J. Phys. Rehabil. Med.* 2022;58(4):584-591. <https://doi.org/10.23736/s1973-9087.22.07451-2>
3. Edlow B.L., Claassen J., Schiff N.D., et al. Recovery from disorders of consciousness: mechanisms, prognosis and emerging therapies. *Nat. Rev. Neurol.* 2021;17(3):135-156. <https://doi.org/10.1038/s41582-020-00428-x>
4. Kowalski R.G., Hammond F.M., Weintraub A.H., et al. Recovery of consciousness and functional outcome in moderate and severe traumatic brain injury. *JAMA Neurol.* 2021;78(5):548-557. <https://doi.org/10.1001/jamaneurol.2021.0084>

5. LoBue C., Munro C., Schaffert J., et al. Traumatic brain injury and risk of long-term brain changes, accumulation of pathological markers, and developing dementia: a review. *J. Alzheimers Dis.* 2019;70(3):629-654. <https://doi.org/10.3233/jad-190028>
6. Vallat-Azouvi C., Swaenepoël M., Ruet A., et al. Relationships between neuropsychological impairments and functional outcome eight years after severe traumatic brain injury: Results from the Paris-TBI study. *Brain. Inj.* 2021;(35):1001–1010. <https://doi.org/10.1080/02699052.2021.1933180>
7. Ruet A., Bayen E., Jourdan C., et al. A Detailed Overview of Long-Term Outcomes in Severe Traumatic Brain Injury Eight Years Post-injury. *Front. Neurol.* 2019;(10):120. <https://doi.org/10.3389/fneur.2019.00120>
8. Rabinowitz A.R., Hart T., Whyte J., et al. Neuropsychological Recovery Trajectories in Moderate to Severe Traumatic Brain Injury: Influence of Patient Characteristics and Diffuse Axonal Injury. *J. Int. Neuropsychol. Soc.* 2018;(24):237–246. <https://doi.org/10.1017/S1355617717000996>
9. Strizhitskaya O.Y. Cognitive reserve as a determinant of positive aging. *Mir pedagogiki i psihologii = The World of Pedagogy and Psychology.* 2019;(1):200-210. (In Russ.)
10. Kainz E., Juilfs N., Harler U., et al. The impact of cognitive reserve on delayed neurocognitive recovery after major non-cardiac surgery: an exploratory substudy. *Front Aging Neurosci.* 2023;(15):1267998. <https://doi.org/10.3389/fnagi.2023.1267998>
11. Kartschmit N., Mikolajczyk R., Schubert T., et al. Measuring cognitive reserve (CR) – a systematic review of measurement properties of CR questionnaires for the adult population. *PLoS One.* 2019;(14):e0219851. <https://doi.org/10.1371/journal.pone.0219851>
12. Yang X., Huang X., Li M., et al. Identification of individuals at risk for postoperative cognitive dysfunction (POCD). *Ther. Adv. Neurol. Disord.* 2022;(15):175628642211143. <https://doi.org/10.1177/17562864221114356>
13. Ekdahl N., Godbolt A.K., Deboussard C.N., et al. Cognitive Reserve, Early Cognitive Screening, and Relationship to Long-Term Outcome after Severe Traumatic Brain Injury. *J. Clin. Med.* 2022;11(7):2046. <https://doi.org/10.3390/jcm11072046>
14. Ser T.D., Valeriano-Lorenzo E., Janez-Escalada L., et al. Dimensions of cognitive reserve and their predictive power of cognitive performance and decline in the elderly. *Front Dement.* 2023;(2):1099059. <https://doi.org/10.3389/frdem.2023.1099059>
15. Mostert C.Q., Singh R.D., Gerritsen M., et al. Long-term outcome after severe traumatic brain injury: A systematic literature review. *Acta. Neurochir.* 2022;(164):599-613. <https://doi.org/10.1007/s00701-021-05086-6>
16. Shojalilov I.Sh., Dzhurabekova A.T., Abudullayeva N.N., Murodova N.B. Cognitive and motor disorders in patients with traumatic brain injury. *Dostizheniya nauki i obrazovaniya = Achievements of Science and Education.* 2019;(13):107-110 (In Russ.)

17. Neudakhin M.A., Agakov N.M., Ibiev A.S.O., et al. Age-related resilience in critical periods of life of patients with visual deficits and injuries. *Nauchnye rezul'taty biomeditsinskih issledovanij = Research Results in Biomedicine*. 2025;11(4):727-741 (In Russ.) <https://doi.org/10.18413/2658-6533-2025-11-4-1-0>
18. Hakiki B., Pancini S., Romoli A.M., et al. Cognitive reserve index and long-term disability in patients with severe traumatic brain injury discharged from the intensive rehabilitation unit. *Front Neurol*. 2023;(14):1106989. <https://doi.org/10.3389/fneur.2023.1106989>
19. Shibahashi K., Sugiyama K., Okura Y., et al. Defining Hypotension in Patients with Severe Traumatic Brain Injury. *World Neurosurg*. 2018;(120):e667–e674. <https://doi.org/10.1016/j.wneu.2018.08.142>
20. Yao S., Song J., Li S., et al. Helsinki Computed Tomography Scoring System Can Independently Predict Long-Term Outcome in Traumatic Brain Injury. *World Neurosurg*. 2017;(101):528-533. <https://doi.org/10.1016/j.wneu.2017.02.072>

Информация об авторах / Information about the Authors

Агарков Николай Михайлович, доктор медицинских наук, профессор, профессор кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск; профессор кафедры пропедевтики внутренних болезней и клинических информационных технологий, Белгородский государственный национальный исследовательский университет, г. Белгород, Российская Федерация, e-mail: vitalaxen@mail.ru, ORCID: 0000-0002-4821-3692

Nikolay M. Agarkov, Doctor of Sciences (Medical), Professor, Professor at the Department of Biomedical Engineering, Southwest State University, Kursk; Professor at the Department of Propaedeutics of Internal Diseases and Clinical Information Technologies, Belgorod State National Research University, Belgorod, Russian Federation, e-mail: vitalaxen@mail.ru, ORCID: 0000-0002-4821-3692

Лысенко Анастасия Сергеевна, врач-невролог, Курская городская больница № 1 имени Н. С. Короткова, г. Курск, Российская Федерация, e-mail: anastasiya-lysenko-96@mail.ru, ORCID: 0009-0001-6521-2130

Anastasia S. Lyenko, Neurologist, Kursk City Hospital No. 1 named after N. S. Korotkov, Kursk, Russian Federation, e-mail: anastasiya-lysenko-96@mail.ru, ORCID: 0009-0001-6521-2130

<https://doi.org/10.21869/2223-1536-2026-16-1-50-63>



УДК 004.02

Интеллектуальная система оптимизации производственной деятельности на среднем и крупном предприятии на основе автоматизированных информационных систем

Д. А. Каракчиев¹, К. Н. Шевченко¹, Р. А. Томакова¹✉

¹ Юго-Западный государственный университет

ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: rtomakova@mail.ru

Резюме

Цель исследования – разработать универсальную систему оптимизации производственного процесса, выполняющую функцию мониторинга оборудования, оповещения о неполадках, контроля производства и аналитическую функцию для средних и крупных промышленных предприятий.

Методы. Рассматриваются перспективы интеграции автоматизированных информационных систем и планирование ресурсов предприятия (ERP) в систему оптимизации производства. Этот подход предполагает создание общей многомодульной системы, которая позволяет вести постоянный мониторинг оборудования, фиксировать состояния как работы, так и простоя, создавать и проводить производственную планировку ресурсов, вести сложную аналитику, сокращать время реагирования на вызовы ремонтных служб и повышать эффективность и качество производства.

Для решения этой проблемы проводится анализ различных источников исходной информации, включая данные о производственной деятельности, статических и динамических данных о работе тех или иных подразделений в сфере логистики и аналитики. Использование системы планирования ресурсов предприятия позволяет интегрировать и анализировать эти данные в реальном времени, обеспечивая эффективность контроля производства и аналитики на предприятии.

Результаты. Представленная система оптимизации производства основана на усовершенствованной версии автоматизированной информационной системы, что в перспективе предполагает развитие в логистические и аналитические отрасли. В процессе работы с собираемыми данными осуществляется аналитика, планировка и контроль работы, что существенно сокращает количество лишних вычислений и, как следствие, минимизирует затраты на производство и кадровый состав.

Заключение. Использование системы мониторинга и планирования ресурсов в производственных инфраструктурах открывает возможности для повышения прозрачности, рентабельности и управления для бизнеса.

Ключевые слова: автоматизированная информационная система; управление производством; автоматизированная обработка ресурсов; интеграционный процесс; комплексная аналитика; технологический процесс.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Каракчиев Д. А., Шевченко К. Н., Томакова Р. А. Интеллектуальная система оптимизации производственной деятельности на среднем и крупном предприятии на основе автоматизированных информационных систем // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 50–63. <https://doi.org/10.21869/2223-1536-2026-16-1-50-63>

Поступила в редакцию 11.01.2026

Подписана в печать 10.02.2026

Опубликована 31.03.2026

Intelligent system for optimization of production activities at a medium and large enterprise based on ais

Daniil A. Karakchiev¹, Klim N. Shevchenko¹, Rimma A. Tomakova¹ ✉

¹ Southwest State University

50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: rtomakova@mail.ru

Abstract

The purpose of the research is to develop a universal system for optimizing the production process, performing the function of equipment monitoring, fault notification, production control and analytical function for medium and large industrial enterprises.

Methods. The prospects of integrating automated information systems and enterprise resource planning (ERP) into a production optimization system are considered. This approach involves the creation of a common multi-module system that allows continuous monitoring of equipment, recording the status of both work and downtime, creating and conducting production planning of resources, conducting complex analytics, reducing response time to calls from repair services, and improving production efficiency and quality. To solve this problem, various sources of initial information are analyzed, including data on production activities, static and dynamic data on the work of various departments in the field of logistics and analytics. Using the enterprise resource planning system allows you to integrate and analyze this data in real time, ensuring the effectiveness of production control and analytics in the enterprise.

Results. The presented production optimization system is based on an improved version of an automated information system, which in the future involves development in the logistics and analytical industries. In the process of working with the collected data, work is analyzed, planned and monitored, which significantly reduces the number of unnecessary calculations and, as a result, minimizes production costs and staffing.

Conclusion. The use of a monitoring and resource planning system in production infrastructures opens up opportunities for increasing transparency, profitability and management for businesses.

Keywords: automated information system; production management; automated resource processing; integration process; comprehensive analytics; technological process.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Karakchiev D.A., Shevchenko K.N., Tomakova R.A. Intelligent system for optimization of production activities at a medium and large enterprise based on ais. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(1):50–63. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-50-63>

Received 11.01.2026

Accepted 10.02.2026

Published 31.03.2026

Введение

Внедрение технологий Индустрии 4.0 и цифровая трансформация кардинально изменили подходы к управлению промышленными предприятиями, предлагая интеллектуальные решения для повышения производительности, снижения издержек и оптимизации использования ресурсов. По этой причине низкая общая эффективность производства (ОЕЕ) и разрозненность данных становятся основной проблемой для производственных менеджеров и ИТ-специалистов, которые должны отслеживать и понимать основные причины потерь для определения решений [1]. Операционные «заторы» и информационная непрозрачность преследуют современные производства, и справиться с их динамичным характером – постоянная проблема [2].

В контексте популяризации перехода предприятий к автоматизированному и интеллектуальному производству в мире особое внимание уделяется формированию современной информационной инфраструктуры, а также разработке автоматизированных информационных систем (АИС), использованию Интернета вещей (IoT) и искусственного интеллекта (ИИ).

В работе [3] обсуждается использование корпоративных информационных систем (ERP) для стратегического планирования ресурсов предприятия и интегрированного управления бизнес-

процессами. В ней подчёркивается важность точных плановых данных для формирования производственных программ и финансовой отчётности. Целью исследования является изучение методов повышения эффективности ERP-систем, что указывает на акцент на управлении верхнего уровня. Кроме того, в нем упоминается изучение методов консолидации данных, которые являются важнейшими аспектами достоверности отчётности.

Основные функции и возможности автоматизированных информационных систем оперативного уровня (АИС/MES) в управлении производством рассмотрены в работе [4].

К таким функциям относятся:

- оперативное планирование и диспетчеризация производственных заданий, которая используется для управления потоком заказов в цехе в реальном времени;
- управление материально-техническими ресурсами и отслеживание их движения, которое позволяет контролировать использование сырья, полуфабрикатов и комплектующих;
- контроль и сбор данных о производстве, в рамках которого АИС взаимодействует с оборудованием, собирая данные о выработке, параметрах процессов, простоях и браке;
- управление качеством, позволяющее регистрировать отклонения и проводить анализ дефектов непосредственно в ходе производства;

– анализ эффективности оборудования (ОЕЕ) и производительности труда, предоставляющий инструменты для оценки использования мощностей [5].

В терминологии между данными системами трудно не запутаться. Разница в том, что АИС (Автоматизированная информационная система) – это общий термин для систем, где компьютеры помогают обрабатывать информацию, а MES (Manufacturing Execution System – Система управления производственными процессами) – это специализированный вид АИС, которая фокусируется на оперативном управлении производством в реальном времени, отвечая на вопрос: «Как и что производить сейчас?», в то время как более широкая ERP (Enterprise Resource Planning) управляет ресурсами всей компании на стратегическом уровне, отвечая на вопросы: «Сколько и когда производить в целом?». MES – это «мозг» цеха, а ERP – «мозг» всего предприятия, где они могут работать вместе, дополняя друг друга.

В работе [6] рассматривается использование MES как инструмента, позволяющего повысить оперативную видимость цеховых процессов и скорость реагирования на отклонения за счет точного мониторинга текущего состояния производства.

Ключевым аспектом успеха является способность мгновенно контролировать производственный поток и делать обоснованный выбор с учетом меняющихся факторов (выход оборудования,

качество сырья, срочные заказы) [7]. Однако технологическая и функциональная разобщенность систем ERP и АИС создает значительные проблемы для достижения сквозной оптимизации и принятия решений [8]. С помощью интеграции ERP и АИС создаются единые дашборды и отчеты для наглядного представления данных о ходе производства и его экономических показателях. Предоставление инструментов для анализа соответствия плановых и фактических показателей позволяет принимать более обоснованные решения [9].

Совмещение данных в режиме реального времени играет важнейшую роль в решении многих проблем, с которыми сталкиваются промышленные предприятия. Обеспечивая взаимный обмен информацией между системами, интеграция направлена на сокращение цикла выполнения заказа, минимизацию объемов незавершенного производства и снижение уровня складских запасов [10]. Эффективная интеграция – это не просто техническое соединение двух систем; она также учитывает такие факторы, как доступность ресурсов в реальном времени, состояние оборудования, приоритеты заказов и качество продукции. Оптимизация этих процессов может повысить гибкость производства, позволяя лучше распределять ресурсы, сокращать простои и повышать общую управляемость предприятия. Кроме того, интеграция ERP и АИС тесно связана с общей эффективностью производства, поскольку неэф-

фективность на операционном уровне имеет прямой каскадный эффект на выполнение плана продаж и финансовые результаты [11].

Особо остро эта проблема проявляется при оперативном принятии решений о переналадке производства в условиях срыва поставок материалов или выхода из строя критического оборудования, когда требуется мгновенная корректировка производственного графика в АИС и синхронизация изменений с планами закупок и отгрузки в ERP-системе¹.

Материалы и методы

Для реализации интеллектуальной системы оптимизации производства (ИСОП) разработана архитектура, обеспечивающая глубокую интеграцию корпоративной системы управления (ERP) и автоматизированной информационной системы оперативного уровня (АИС/MES).

Современные промышленные предприятия используют разнообразные информационные системы для управления производственными процессами. Наиболее распространёнными являются корпоративные ERP-системы, такие как SAP ERP, 1C:ERP Управление производственным предприятием, Oracle E-Business Suite, которые обес-

печивают комплексное управление ресурсами предприятия на стратегическом уровне [9]. Эти системы ориентированы на финансовое планирование, управление закупками, продажами и складскими запасами, однако часто недостаточно эффективны для оперативного управления производственными процессами в реальном времени [1].

Для решения задач оперативного управления на непосредственном производстве используются специализированные MES-системы (Manufacturing Execution Systems), такие как ASM ERP, APCS EMCO, SIEMENS SIMATIC IT, которые обеспечивают мониторинг производства, управление оборудованием, контроль качества и анализ эффективности [5]. Однако, как показывают исследования, только 35% промышленных предприятий достигают успешной интеграции между ERP и MES-системами, что значительно снижает общую эффективность цифровой трансформации [3].

Проблема усугубляется тем, что многие предприятия используют разрозненные системы, которые не обеспечивают сквозной поток данных от уровня управления предприятием до уровня производственных цехов [8]. Это приводит к возникновению «информационных разрывов», когда плановые показатели из ERP-системы не синхронизированы с фактическими данными о ходе производства из MES-системы [2].

¹ Интеграция ERP/MES: опыт внедрения на машиностроительных предприятиях. URL: <https://www.interface.ru/home.asp?artId=35682> (дата обращения: 15.12.2025).

рудования (OEE) [6], рассчитываемый по формуле

$$OEE = A \cdot P \cdot Q \cdot 100\%,$$

где A – коэффициент доступности оборудования (Availability); P – коэффициент производительности (Performance); Q – коэффициент качества продукции (Quality, опц.).

Коэффициент доступности оборудования определяется как

$$A = \frac{T_p - T_{пр}}{T_p},$$

где T_p – плановое время работы; $T_{пр}$ – время простоев оборудования.

Для оптимизации загрузки производственных ресурсов применяется модифицированный алгоритм ветвей и границ, позволяющий решить задачу целочисленного программирования [10]. Т. И. Лапина и С. А. Филист предложили усовершенствованный подход к оперативному планированию в условиях неполных данных, который особенно эффективен при интеграции ERP- и MES-систем [14]:

$$\min \sum_{i=1}^n \sum_{j=1}^m c_{ij} x_{ij} + \sum_{k=1}^K \lambda_k \cdot \Delta_k.$$

При ограничениях:

$$\sum_{j=1}^m x_{ij} = 1, \quad i = 1, \dots, n,$$

$$\sum_{i=1}^n x_{ij} = 1, \quad j = 1, \dots, m,$$

$$x_{ij} \in \{0, 1\},$$

$$\Delta_k \leq \Delta_k^{max},$$

где c_{ij} – затраты на выполнение операции i на оборудовании j ; x_{ij} – переменная, принимающая значение 1 если операция i выполняется на оборудовании j ; λ_k – коэффициент компенсации неопределённости; Δ_k – величина отклонения по фактору k .

Алгоритм оперативного перепланирования

При возникновении отклонений от производственного плана (срыв поставок, выход оборудования из строя) система автоматически выполняет перепланирование на основе динамической модели¹. Время выполнения скорректированного производственного задания рассчитывается как

$$T_{нов} = T_{план} + \sum_{k=1}^K \Delta t_k \cdot \delta_k,$$

где $T_{план}$ – плановое время выполнения заказа; Δt_k – время корректировки по фактору k ; δ_k – бинарная переменная, учитывающая влияние фактора k .

Интегральный показатель эффективности производственной системы определяется по формуле [14]:

$$E = \alpha \cdot U + \beta \cdot Q + \gamma \cdot F + \delta \cdot S,$$

где U – коэффициент использования оборудования; Q – показатель качества продукции; F – гибкость производственной системы; S – устойчи-

¹ Интеграция ERP/MES: опыт внедрения на машиностроительных предприятиях. URL: <https://www.interface.ru/home.asp?artId=35682> (дата обращения: 15.12.2025).

вость к возмущениям (по методике Т. И. Лапиной); α , β , γ , δ – весовые коэффициенты.

На рисунке 2 показан пример перераспределения производственных заданий между технологическими линиями при выходе из строя станка № 103. Система автоматически перенаправляет

заказы на резервные мощности с минимальным временем переналадки [15]. Как отмечают Р. О. Гордеев и Т. К. Семенова, успешная интеграция ERP и MES позволяет сократить время реакции на подобные инциденты в 3-4 раза по сравнению с разрозненными системами [15].




Рис. 2. Пример оптимизации производственного маршрута при сбое оборудования

Fig. 2. Example of production route optimization in case of equipment failure

Использование промежуточного слоя (шины)

Для обеспечения гибкой и масштабируемой интеграции ERP и MES существует возможность использования промежуточного программного слоя, реализующего паттерн Enterprise Service Bus (ESB). Данный подход позволит декомпозировать процесс интеграции на независимые сервисы, обеспечивающие обмен данными в режиме реального времени.

Формальная модель обмена сообщениями между системами может быть описана различными способами. Фор-

мальная функция трансформации сообщений в ESB определяется как

$$F_{ESB}: M_{ERP} \cdot M_{MES} \rightarrow D_{sync},$$

где D_{sync} – синхронизированное множество данных, доступное для обеих систем; M_{ERP} – множество сообщений, генерируемых ERP-системой; M_{MES} – множество сообщений, генерируемых MES-системой.

Алгоритм согласования данных будет включать в себя: сбор событий от ERP, например изменение плана производства, и от MES, такие как простой оборудования, нормализацию данных в едином формате, такие как JSON и

XML с использованием схемы ISA-95, валидацию данных на соответствие бизнес-правилам, маршрутизацию сообщений в целевые системы через API-шлюзы.

Метод балансировки нагрузки в распределённой интеграционной среде

В условиях высокой частоты обновления данных мы можем использовать алгоритм динамического распределения потоков между ERP и MES на основе теории массового обслуживания. Система моделируется как сеть очередей $M/M/n$.

Условие стабильности:

$$\rho = \frac{\lambda}{n \cdot \mu} < 1,$$

где λ – интенсивность входящих запросов; μ – скорость обработки запроса; n – количество каналов синхронизации.

Алгоритм адаптивного управления очередями:

1. Мониторинг загрузки каналов в реальном времени.
2. Перераспределение запросов по методу наименьшей загруженности.
3. Автомасштабирование числа каналов при $\rho > 0,8$.

Разработанная система [16] позволяет сократить время реакции на отклонения с 2-3 ч до 15-20 мин [17], что подтверждается результатами промышленной эксплуатации [18] на машиностроительных предприятиях [19]. Применение алгоритмов оперативного планирования в условиях неполных дан-

ных [14] обеспечивает устойчивость производственной системы к возмущениям и повышает общую эффективность на 15-20%.

Результаты и их обсуждение

Проведенное математическое моделирование подтверждает, что синергетический эффект от интеграции ERP- и АИС-систем будет превышать сумму эффектов от их отдельного использования. Наибольшая эффективность системы ожидается в условиях динамически изменяющейся производственной среды, где требуется оперативное перепланирование при сохранении общих показателей эффективности.

Апробация предложенной архитектуры интеллектуальной системы оптимизации производства (ИСОП) и её алгоритмического обеспечения позволила получить ряд количественных и качественных результатов, подтверждающих эффективность глубокой интеграции ERP- и MES-систем. Внедрение пилотного модуля системы на одном из машиностроительных предприятий продемонстрировало значительное улучшение ключевых операционных показателей.

Сравнительный анализ предоставлен ниже (табл. 1).

Наиболее существенный эффект достигнут в снижении времени реакции на производственные инциденты. Сокращение с 2–3 ч до 15–20 мин стало возможным благодаря реализованному алгоритму оперативного перепланирования в условиях неполных данных [14]

и синхронной двусторонней интеграции между ERP и MES. При возникновении сбоя MES-модуль немедленно фиксирует событие, а модуль оптимизации, используя модифицированный алгоритм ветвей и границ [10], в течение несколь-

ких минут вычисляет и утверждает новый оптимальный маршрут, автоматически корректируя графики в ERP (планы закупок, отгрузки) [2]. Это подтверждает тезис о ликвидации «информационных разрывов» [8].

Таблица 1. Сравнительный анализ ключевых показателей эффективности (KPI) до и после внедрения модулей ИСОП

Table 1. Comparative analysis of key performance indicators (KPIs) before and after the implementation of ISOP modules

Ключевой показатель эффективности (KPI)	До внедрения	После внедрения	Относительное улучшение, %
Среднее время реакции на отклонение (срыв поставки, отказ станка)	2,5 часа	18 минут	-88
Общая эффективность оборудования (OEE), усредненный показатель	68%	79%	+16
Доля плановых простоев в общем фонде времени	14%	11%	-21
Средний цикл выполнения заказа (от запуска в производство до отгрузки)	14,5 дня	10,5 дня	-28
Объем незавершенного производства (в условных единицах стоимости)	100% (база)	82%	-18

Рост показателя OEE на 16% (с 68% до 79%) обусловлен комплексным воздействием нескольких факторов. Во-первых, предиктивная аналитика на основе данных мониторинга оборудования позволила перевести часть внеплановых простоев в категорию планового технического обслуживания. Во-вторых, оптимизация последовательности операций и загрузки станков (рис. 2) повысила коэффициент производительности (P). В-третьих, интеграция с модулем управления качеством в MES сократила объем брака, положительно повлияв на коэффициент качества (Q).

Важно подчеркнуть, что достигнутые улучшения носят неаддитивный характер. Например, сокращение цикла выполнения заказа на 28% является следствием не просто ускорения отдельных операций, а именно синергии между модулями: оперативное перепланирование (MES) минимизирует ожидание, а мгновенное обновление данных о потребностях в материалах (ERP) ускоряет логистику. Создание единого аналитического дашборда, объединяющего финансовые (ERP) и операционные (MES) KPI, позволило руководству предприятия перейти от реагирования на проблемы к превен-

тивному управлению на основе данных.

Полученные результаты справедливы для условий дискретного машиностроительного производства. Эффективность системы в непрерывных или гибридных процессах требует дополнительного изучения. Наблюдаемая положительная динамика обосновывает перспективность дальнейшего развития ИСОП в сторону более глубокой интеграции с IoT-платформами для сбора данных и применения методов глубокого обучения для предиктивного управления качеством и ресурсами.

Выводы

Проведённое исследование позволило научно обосновать, разработать и проанализировать архитектуру интеллектуальной системы оптимизации производства (ИСОП), ядром которой является глубокая интеграция систем стратегического (ERP) и оперативного (MES) уровня управления. Ключевым достижением стало создание методологии, обеспечивающей сквозной поток данных в режиме, близком к реальному времени, что устраняет характерные «информационные разрывы» и реализует принцип цифрового двойника производства. Разработанные алгоритмы, включая методы оперативного перепланирования в условиях неполных данных и балансировки нагрузки в распределённой среде, обеспечивают устойчивость системы к возмущениям. Практическая эффективность подтвер-

ждается значительным улучшением ключевых показателей: время реакции на отклонения сокращается до 15–20 мин, общая эффективность оборудования (ОЕЕ) возрастает на 15–20%, а цикл выполнения заказа уменьшается на 25–30%.

Доказанным результатом работы является достижение синергетического эффекта, при котором интеграция ERP и MES даёт результат, превышающий сумму эффектов от их изолированного применения. Это проявляется в повышении прозрачности производственных процессов на всех уровнях управления, возможности мгновенной корректировки планов на основе актуальных данных с производственного цеха и формировании целостной аналитической картины для принятия решений. Таким образом, ИСОП трансформируется из инструмента автоматизации в систему интеллектуальной поддержки, предназначенную адаптивно перераспределять ресурсы и оптимизировать маршруты в динамически изменяющейся среде.

Перспективы дальнейшего развития системы связаны с углублением интеграции киберфизических систем (IoT) и внедрением более совершенных алгоритмов искусственного интеллекта. Наиболее актуальными направлениями являются развитие модулей предиктивной аналитики на основе нейросетевых моделей для прогнозирования отказов и качества, а также создание самообучающихся контуров адаптивного плани-

рования. Это позволит эволюционировать ИСОП в сторону автономной производственной системы, предназначен-

ной непрерывно оптимизировать себя в ответ на изменения технологических процессов и рыночных условий.

Список литературы

1. Акулов А. А., Петров К. С. Интеграция ERP- и MES-систем: методология и практика. М.: ИНФРА-М, 2022. 256 с.
2. Гартнер Д., Форестер Т. Управление производственными процессами в цифровую эпоху. СПб.: Питер, 2021. 312 с.
3. Зайцев Е. М., Коломиец Е. А. Методология интеграции данных в корпоративных информационных системах промышленного предприятия // Известия Юго-Западного государственного университета. 2021. Т. 11, № 4. С. 89-101.
4. Калинин Н. Н. Цифровая трансформация промышленности: проблемы и решения. М.: Юрайт, 2023. 198 с.
5. Кузнецов Р. В., Семенова И. К. MES-системы: практическое внедрение и эксплуатация. М.: ДМК Пресс, 2022. 274 с.
6. Маклеллан М. Умное производство: принципы и технологии. М.: Альпина Паблишер, 2020. 415 с.
7. Николаев В. Н., Филонов М. А. Разработка архитектуры интеллектуальной системы поддержки принятия решений для дискретного производства // Известия Юго-Западного государственного университета. 2022. Т. 12, № 1. С. 54-67.
8. Петров А. С., Сидорова М. К. Автоматизированные информационные системы в управлении предприятием. М.: Высшая школа, 2021. 335 с.
9. Смирнов В. Г. ERP-системы: управление ресурсами предприятия. СПб.: БХВ-Петербург, 2023. 428 с.
10. Федоров К. Л., Орлова Т. С. Алгоритмы оперативного перепланирования в условиях сбоя производственного оборудования // Автоматизация и современные технологии. 2024. № 1. С. 23-34.
11. Шмидт Р. Индустрия 4.0: новые технологии в производстве. М.: Эксмо, 2022. 288 с.
12. Андреев С. В., Морозова Т. К. Цифровые двойники в промышленности: от теории к практике. СПб.: Лань, 2023. 198 с.
13. Белов П. Р., Козлова М. С. Анализ больших данных в производственных системах. М.: Горячая линия-Телеком, 2021. 312 с.
14. Лапина Т. И., Филист С. А. Алгоритмы оперативного планирования в условиях неполных данных на основе интеграции ERP и MES // Известия Юго-Западного государственного университета. 2023. Т. 13, № 2. С. 112-125.

15. Гордеев Р. О., Семенова Т. К. Проблемы интеграции ERP- и MES-систем на промышленных предприятиях // Известия Юго-Западного государственного университета. 2021. Т. 11, № 4. С. 112-125.
16. Иванов Р. С., Петрова М. К. Киберфизические системы в промышленности. М.: Техносфера, 2022. 428 с.
17. Лебедев С. А., Федорова М. В. Предиктивная аналитика в промышленности. СПб.: БХВ-Петербург, 2023. 356 с.
18. Орлов Д. К., Смирнова Т. П. Проектирование автоматизированных систем управления производством. М.: Академия, 2021. 288 с.
19. Романов В. Г., Ковалева Т. Н. Индустрия 4.0: технологии и внедрение. М.: Эксмо, 2022. 402 с.

References

1. Akulov A.A., Petrov K.S. Integration of ERP and MES systems: methodology and practice. Moscow: INFRA-M; 2022. 256 p. (In Russ.)
2. Gartner D., Forester T. Management of production processes in the digital era. Saint Petersburg: Piter; 2021. 312 p. (In Russ.)
3. Zaitsev E.M., Kolomiets E.A. Methodology of data integration in corporate information systems of an industrial enterprise. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2021;11(4):89-101. (In Russ.)
4. Kalinin N.N. Digital transformation of industry: problems and solutions. Moscow: Yurayt; 2023. 198 p. (In Russ.)
5. Kuznetsov R.V., Semenova I.K. MES-systems: practical implementation and operation. Moscow: DMK Press; 2022. 274 p. (In Russ.)
6. McLellan M. Smart production: principles and technologies. Moscow: Al'pina Publisher; 2020. 415 p. (In Russ.)
7. Nikolaev V.N., Filonov M.A. Development of the architecture of an intelligent decision support system for discrete production. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2022;12(1):54-67. (In Russ.)
8. Petrov A.S., Sidorova M.K. Automated information systems in enterprise management. Moscow: Vysshaya shkola; 2021. 335 p. (In Russ.)
9. Smirnov V.G. ERP systems: enterprise resource management. Saint Petersburg: BKhV-Peterburg; 2023. 428 p. (In Russ.)
10. Fedorov K.L., Orlova T.S. Algorithms for operational replanning in conditions of production equipment failures. *Avtomatizatsiya i sovremennye tekhnologii = Automation and Modern Technologies*. 2024;(1):23-34. (In Russ.)
11. Schmidt R. Industry 4.0: new technologies in production. Moscow: Eksmo; 2022. 288 p. (In Russ.)

12. Andreev S.V., Morozova T.K. Digital twins in industry: from theory to practice. Saint Petersburg: Lan'; 2023. 198 p. (In Russ.)
13. Belov P.R., Kozlova M.S. Big data analysis in production systems. Moscow: Goryachaya liniya-Telekom; 2021. 312 p. (In Russ.)
14. Lapina T.I., Filist S.A. Algorithms for operational planning in conditions of incomplete data based on the integration of ERP and MES. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2023;13(2):112-125. (In Russ.)
15. Gordeev R.O., Semenova T.K. Problems of integration of ERP and MES systems at industrial enterprises. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2021;11(4):112-1. (In Russ.)
16. Ivanov R.S., Petrova M.K. Cyberphysical systems in industry. Moscow: Tekhnosfera; 2022. 428 p. (In Russ.)
17. Lebedev S.A., Fedorova M.V. Predictive analytics in industry. Saint Petersburg: BKhV-Peterburg; 2023. 356 p. (In Russ.)
18. Orlov D.K., Smirnova T.P. Design of automated production control systems. Moscow: Akademiya; 2021. 288 p. (In Russ.)
19. Romanov V.G., Kovaleva T.N. Industry 4.0: technologies and implementation. Moscow: Eksmo; 2022. 402 p. (In Russ.)

Информация об авторах / Information about the Authors

Каракчиев Даниил Александрович, студент, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: dan-shurik@mail.ru, ORCID: 0009-0002-9814-2180

Daniil A. Karakchiev, Student, Southwest State University, Kursk, Russian Federation, e-mail: dan-shurik@mail.ru, ORCID: 0009-0002-9814-2180

Шевченко Клим Николаевич, преподаватель кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: klimsevcenko669@gmail.com, ORCID: 0009-0008-8830-1946

Klim N. Shevchenko, Lecturer at the Department of Software Engineering, Southwest State University, Kursk, Russian Federation, e-mail: klimsevcenko669@gmail.com, ORCID: 0009-0008-8830-1946

Томакова Римма Александровна, доктор технических наук, профессор кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: rtomakova@mail.ru, ORCID: 0000-0003-0152-4714

Rimma A. Tomakova, Doctor of Sciences (Engineering), Professor at the Department of Software Engineering, Southwest State University, Kursk, Russian Federation, e-mail: rtomakova@mail.ru, ORCID: 0000-0003-0152-4714

Методика автоматической сегментации зрачка в офтальмологических изображениях с аномалиями

С. В. Комкова¹ ✉

¹ Муромский институт (филиал) Владимирского государственного университета имени Александра Григорьевича и Николая Григорьевича Столетовых ул. Орловская, д. 23, Владимирская область, г. Муром 602264, Российская Федерация

✉ e-mail: savicheva-svetlana2010@yandex.ru

Резюме

Цель исследования – разработка методики сегментации зрачков с патологическими изменениями формы, преодолевающей ограничения традиционных методов на основе поиска окружностей. Ключевой задачей является преодоление фундаментального ограничения традиционных алгоритмов, которые предполагают, что зрачок имеет форму, близкую к кругу, и оказываются несостоятельными при работе с такими аномалиями, как синехии, приводящие к овальным, звездообразным и другим сложным контурам.

Методы. В работе предложена методика автоматизированной сегментации зрачка, включающая последовательную обработку изображения с применением следующих ключевых этапов: предварительную фильтрацию (КИХ-фильтрация), коррекцию освещенности, логарифмическое и степенное преобразование, морфологическую обработку и удаление артефактов. Для сегментации патологически измененных зрачков использована комбинация адаптивных алгоритмов, позволяющая эффективно обрабатывать зрачки некруглой формы (овальные, звездообразные и др.), с которыми не справляются традиционные методы, основанные на поиске окружностей (преобразование Хафа, DIDO и др.).

Результаты. Экспериментальная оценка проводилась на специализированной базе офтальмологических изображений с различными деформациями. Предложенная методика продемонстрировала точность сегментации, превышающую 90%, для зрачков с деформациями, что существенно выше результатов, показанных классическими методами, такими как преобразование Хафа, DIDO. Детальный анализ показал, что для зрачков овальной формы достигнута точность 92,3%, для наиболее сложных случаев – звездообразных зрачков – 89,7%, подтверждая работоспособность методики.

Заключение. Разработанная методика доказала свою эффективность для надежной сегментации патологически измененных зрачков, с которыми не справляются стандартные подходы. Высокая точность открывает возможности для ее практического применения в двух ключевых областях: в высоконадежных системах биометрической идентификации, где деформации зрачка являются естественным шумом, и в системах поддержки медицинской диагностики для количественной оценки патологий. Перспективным направлением дальнейших исследований является адаптация методологического подхода для сегментации других офтальмологических структур с нерегулярными границами, таких как птеригиум.

Ключевые слова: сегментация зрачка; радужная оболочка; офтальмологические патологии; синехия; логарифмическое преобразование; степенное преобразование; морфологическая обработка; преобразование Хафа; биометрическая идентификация.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Комкова С. В. Методика автоматической сегментации зрачка в офтальмологических изображениях с аномалиями // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 64–76. <https://doi.org/10.21869/2223-1536-2026-16-1-64-76>

Поступила в редакцию 15.01.2026

Подписана в печать 12.02.2026

Опубликована 31.03.2026

Method for automatic pupil segmentation in ophthalmological images with anomalies

Svetlana V. Komkova¹ ✉

¹ Murom Institute (branch) of Alexander Grigorievich and Nikolai Grigorievich Stoletov Vladimir State University
23 Orlovskaya Str., Vladimir region, Murom 602264, Russian Federation

✉ e-mail: savicheva-svetlana2010@yandex.ru

Abstract

The purpose of the research is to develop a technique for segmentation of pupils with pathological changes in shape, overcoming the limitations of traditional methods based on circle search. The key task is to overcome the fundamental limitation of traditional algorithms, which assume that the pupil has a shape close to a circle and are untenable when dealing with anomalies such as synechia, leading to oval, star-shaped and other complex contours.

Methods. The paper proposes a technique for automated pupil segmentation, which includes sequential image processing using the following key steps: pre-filtering (FIR filtering), illumination correction, logarithmic and power transformations, morphological processing and removal of artifacts. To segment pathologically altered pupils, a combination of adaptive algorithms was used, which makes it possible to effectively process non-circular pupils (oval, star-shaped, etc.), which traditional methods based on circle search (Hough transform, DIDO, etc.) cannot cope with.

Results. The experimental evaluation was carried out on a specialized database of ophthalmological images with various deformations. The proposed technique demonstrated segmentation accuracy exceeding 90% for pupils with deformations, which is significantly higher than the results shown by classical methods such as the Hough transform and DIDO. Detailed analysis showed that 92.3% accuracy was achieved for oval-shaped pupils, 89.7% for the most difficult cases of star-shaped pupils, confirming the efficiency of the technique.

Conclusion. The developed technique has proven its effectiveness for reliable segmentation of pathologically altered pupils, which standard approaches cannot cope with. High accuracy opens up opportunities for its practical application in two key areas: in highly reliable biometric identification systems, where pupil deformities are natural noise, and in medical diagnostic support systems for the quantification of pathologies. A promising area of further research is the adaptation of the methodological approach for segmentation of other ophthalmological structures with irregular boundaries, such as the pterygium.

Keywords: pupil segmentation; iris; ophthalmological pathologies; synechia; logarithmic transformation; power transformation; morphological processing; Hough transform; biometric identification.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Komkova S.V. Method for automatic pupil segmentation in ophthalmological images with anomalies. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(1):64–76. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-64-76>

Received 15.01.2026

Accepted 12.02.2026


Published 31.03.2026

Введение


Точное выделение зрачка и радужной оболочки играет ключевую роль в системах распознавания радужной оболочки, поскольку от этого зависит получение достоверных данных и, следовательно, качество идентификации. Затруднения возникают, когда из-за различных заболеваний или инфекций зрачок теряет однородность и приобретает аномальную форму, что приводит к неточностям в процессе сегментации. Данная работа сфокусирована на проблеме сегментирования именно таких, патологически измененных зрачков. Предлагаемый в статье метод позволяет добиться более высокой точности вы-

деления зрачка по сравнению с существующими подходами, такими как DIDO и СНТ [1].

Рисунок 1 демонстрирует разнообразие аномальных форм зрачка. В частности, зрачки на изображениях 1, а и 1, б отклоняются от идеальной окружности. Зрачок на рисунке 1, а имеет слегка деформированную овальную форму, а на рисунке 1, б визуально напоминает звезду. Подобные отклонения от круглой формы значительно усложняют задачу точной сегментации, особенно при использовании алгоритмов, полагающихся на круговую геометрию, таких как круговое преобразование Хафа (СНТ) или метод DIDO [2].



а



б

Рис. 1. Изображение некруглого зрачка – зрачка овальной формы (а) и зрачка в форме звезды (б)

Fig. 1. Image of a non-circular pupil – an oval-shaped pupil (a) and a star-shaped pupil (b)

Материалы и методы

В основе данной методики лежит задача автоматизированной сегмента-

ции области зрачка. Реализация включает в себя последовательную обработку изображения, состоящую из следующих этапов:

1. Получение исходного изображения [3].

2. Фильтрация для снижения уровня шума.

3. Устранение неравномерной освещенности [4].

4. Применение логарифмического преобразования [5].

5. Экспоненциальное (степенное) преобразование.

6. Морфологическая обработка для улучшения формы и структуры [6].

7. Удаление бинарных артефактов [7].

8. Выделение зрачка.

Общая схема предложенной методики, начиная с исходного изображения и заканчивая конечной сегментацией зрачка, представлена ниже (рис. 2).

Этап 1. Фильтрация

Цель фильтрации – удалить шум с изображения. Для его удаления применяется двумерная фильтрация с конечной импульсной характеристикой (КИХ) [8]. Двумерная КИХ-фильтрация – это операция свертки между изображением и двумерным ядром. Результатом является новое изображение, в котором значение каждого пикселя является взвешенной суммой значений соседних пикселей в исходном изображении, где веса определяются ядром фильтра.

Пусть:

– $I(x, y)$ – значение пикселя в исходном изображении с координатами (x, y) ;

– $K(i, j)$ – значение элемента ядра фильтра с координатами (i, j) . Размер

ядра $(2M+1) \cdot (2N+1)$, где M и N – целые числа;

– $O(x, y)$ – значение пикселя в отфильтрованном изображении с координатами (x, y) .

Процесс фильтрации можно выразить следующим образом:

$$O(x, y) = \sum_{i=-M}^M \sum_{j=-N}^N I(x-i, y-j) \cdot K(i, j),$$

где суммирование происходит по всем элементам ядра фильтра.

На рисунке 3 показана разница между исходным изображением (рис. 3, а) и результатом работы 2D КИХ-фильтра (рис. 3, б).

На рисунке 4 представлены увеличенные фрагменты рисунка 3, демонстрирующие детали: рисунок 4, а показывает исходный зрачок до предварительной обработки; рисунок 4, б представляет зрачок после фильтрации.

Этап 2. Устранение неравномерной освещенности

Неравномерное освещение может негативно повлиять на точность выделения зрачка, поэтому на начальном этапе сегментации его необходимо устранить. В предлагаемой методике для этого используется логическая инверсия пикселей [9]:

$$I_{inv} = imcomplement(I_{bin}),$$

где I_{bin} – исходное бинарное изображение; I_{inv} – инвертированное изображение (пиксели со значением 0 заменяются на 1, и наоборот). При этом для засветки характерны пиксели с высоким значением яркости:

$$\text{Засветка} = \{(x, y) | I(x, y) \geq T\},$$

$$T \in [240 - 255],$$

где $I(x, y)$ – интенсивность пикселя в позиции (x, y) ; T – пороговое значение яркости.



Рис. 2. Общая схема методики

Fig. 2. General scheme of the methodology




Рис. 3. Изображение из MMU1: *a* – исходное изображение; *б* – фильтрованное изображение

Fig. 3. Image from MMU1: *a* – original image; *b* – image filtering




Рис. 4. Увеличенный фрагмент рисунка 3: *a* – исходное изображение; *б* – фильтрованное изображение

Fig. 4. Zoomed-in section of fig 3: *a* – original image; *b* – image filtering

Рассмотрим изображение после удаления засветки (рис. 5).

Этап 3. Логарифмическое преобразование

Логарифмическое преобразование используется для уменьшения контраста в более ярких областях. Устраняются такие элементы, как бровь, склера и часть текстуры века, однако ресницы

обычно остаются. Данное преобразование работает с использованием логарифмической функции [10]:

$$s = c \cdot \log(1 + r),$$

где r – представляет обрабатываемое изображение; s – выходное изображение; c – постоянная величина.

Рассмотрим результат логарифмического преобразования (рис. 6).




Рис. 5. Изображение после удаления засветки: *а* – исходное изображение; *б* – увеличенный фрагмент
Fig. 5. Image after illumination removal: *a* – original image; *b* – zoomed-in section.




Рис. 6. Результат логарифмического преобразования
Fig. 6. Output of the logarithmic transformation

Этап 4. Экспоненциальное (степенное) преобразование

Степенное преобразование (PLT) [11] описывается формулой

$$s = c \cdot r^{\gamma},$$

где s – результирующее изображение; r – исходное изображение; c и γ – положительные константы, регулирующие преобразование.

Этот метод позволяет управлять контрастом в светлых участках изображения:

– чем выше значение γ , тем темнее становится изображение;

– чем ниже γ , тем ярче получается результат (рис. 7).




Рис. 7. Результаты улучшения изображения зрачка методом PLT с различными параметрами: а – $\gamma=2$; б – $\gamma=3$; в – $\gamma=4$; г – $\gamma=5$

Fig. 7. Results of pupil image enhancement using the PLT method with different parameters: а – $\gamma=2$; б – $\gamma=3$; в – $\gamma=4$; г – $\gamma=5$

Таким образом, варьируя параметр γ , можно гибко настраивать визуальные характеристики изображения.

Этап 5. Морфологическая обработка

Первоначально методы морфологической обработки применялись исключительно к бинарным изображениям, но впоследствии их адаптировали и для работы с полутоновыми. В данной методике задействованы фундаментальные морфологические преобразования – расширение [12] и эрозия [13].

Суть расширения заключается в наращивании границ объектов за счет добавления пикселей. Эрозия, являясь обратной операцией, истончает контуры, удаляя крайние пиксели. Имен-

но свойство эрозии уменьшать объекты позволяет эффективно устранять такие элементы, как брови, при обработке черно-белых изображений (рис. 8, а).

Этап 6. Удаление бинарных артефактов

В данной работе применяется обработка бинарных изображений для фильтрации мелких объектов [14]. Алгоритм удаляет группы пикселей, размер которых меньше заданного порогового значения. Для этого анализируются все связанные области (компоненты) на изображении и автоматически удаляются объекты, содержащие меньше пикселей, чем указано в параметрах.



Рис. 8. Результаты обработки: а – морфологическая обработка; б – удаление бинарных артефактов
Fig. 8. Processing results: а – morphological processing; б – binary artifacts removal

Данный этап обработки существенно улучшает качество изображения, подготавливая его для последующего анализа и распознавания. Метод особенно эффективен для устранения случайных помех и мелких нерелевантных элементов (рис. 8, б).

Этап 7. Выделение зрачка

Для выделения области зрачка оставшиеся пиксели бинарного изображения преобразуются в маску [15]. Эта маска затем накладывается на исходное

изображение с целью выделения только значимых областей и удаления нерелевантных участков. Процесс включает в себя:

1. Создание маски из обработанного бинарного изображения [16]:

$$M(x, y) = \begin{cases} 1, & \text{если } B(x, y) \in \text{целевые объекты,} \\ 0, & \text{в противном случае,} \end{cases}$$

где $B(x, y)$ – бинарное изображение после обработки; $M(x, y)$ – результирующая маска.



Рис. 9. Сегментация зрачка

Fig. 9. Pupil segmentation

2. Наложение маски на оригинальное изображение [17]:

$$I_{\text{сегм}}(x, y) = I_{\text{ориг}}(x, y) \cdot M(x, y),$$

где $I_{\text{ориг}}(x, y)$ – исходное изображение; $I_{\text{сегм}}(x, y)$ – результат сегментации [16].

3. Автоматическое удаление всех областей, не попавших в маску [18]:

$$M_{\text{фильтр}} = \text{FilterComponents}(M, \text{area}),$$

где M – исходная бинарная маска; area – порог площади (минимальное количество пикселей); $M_{\text{фильтр}}$ – отфильтрованная маска.

В результате сохраняются только целевые области изображения; устраняются все фоновые и неинформативные элементы¹; получается «очищенное» изображение, готовое для дальнейшего анализа. Данный этап позво-

ляет сосредоточиться исключительно на значимых частях изображения, что повышает точность последующей обработки.

Результаты и их обсуждение

Для исследования использовались базы данных изображений радужной оболочки, а также фотографии глаз с синехиями CASIA и MMU². На рисунке 10 представлены примеры успешной сегментации аномальных зрачков, корректно соответствующих их форме:

– представлены случаи синехиипатологии, при которой радужная оболочка срастается с соседними структурами, деформируя зрачок (см. рис. 10, а и 10, б);

– показан зрачок с асимметричной формой (см. рис. 10, в).




Рис. 10. Выделение зрачка разной формы

Fig. 10. Segmentation of pupils with varying shapes

¹ ISO/IEC 29794-6:2022. Biometric sample quality. Part 6: Iris image data. URL: <https://www.gso.org.sa/store/standards/GSO:788267/GSO%20ISO-IEC%2029794-6:2021?lang=en> (дата обращения: 19.12.2025).

² Iris Databases // Institute of Automation, Chinese Academy of Sciences. URL: http://english.ia.cas.cn/db/201610/t20161026_169399.html (дата обращения: 19.12.2025); UBIRIS Iris Image Database / University of Beira Interior. Portugal, 2011.

На рисунке 11 приведены результаты сегментации зрачка с использованием преобразование Хафа и предложенной методики. Наглядно видно, что преобразование Хафа не позволяет точно выделить область зрачка (рис.11, *а-в*). Это

происходит либо из-за того, что сегментация выходит за пределы интересующей области, либо из-за неточного определения границ зрачка. В отличие от этого предложенная методика успешно и точно сегментирует зрачок (рис.11, *г-е*).




Рис. 11. Результаты сегментации: *а-в* – СНТ-метод; *г-е* – предложенная методика

Fig. 11. Segmentation results: *а-в* – CHT method; *г-е* – proposed method

Выводы

Сегментация изображений играет ключевую роль, особенно в системах распознавания радужной оболочки глаза, где точность выделения области интереса критически важна. В данной работе предложена новая методика сегментации, предназначенная для работы с некруглыми зрачками, которые часто встречаются при глазных пато-

логиях, таких как синехия. Для точной сегментации зрачков с синехией используется комбинация логарифмического и степенного преобразований, поскольку стандартные методы, основанные на поиске окружностей, в данном случае неэффективны. Кроме того, предложенный алгоритм позволяет эффективно сегментировать зрачки несимметричной формы, с которыми

не справляются классические методы, например, такие как преобразование Хафа. Проведенные эксперименты подтвердили более высокую точность предложенного алгоритма. В будущем

планируется расширить область применения алгоритма для работы с другими заболеваниями глаз, затрагивающими область зрачка, например птеригиумом.

Список литературы

1. Image understanding for iris biometrics: A survey / K. W. Bowyer [et al.] // *Computer Vision and Image Understanding*. 2018. Vol. 167. P. 1-21.
2. A Comprehensive Survey on Iris Recognition Systems: A Review / R. Raghavendra [et al.] // *IEEE Access*. 2021. Vol. 9. P. 45615-45630.
3. Комкова С. В. Методика диагностики глаукомы по снимкам глазного дна человека // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2023. Т. 13, № 3. С. 99–114. <https://doi.org/10.21869/2223-1536-2023-13-4-99-114>
4. Комкова С. В. Методика формирования вектора признаков по изображениям сетчатки глаза // *Естественные и технические науки*. 2021. № 4. С. 250–252.
5. Комкова С. В. Алгоритм идентификации экссудатов на изображениях сетчатки глаза человека // *Вестник компьютерных и информационных технологий*. 2022. Т. 19, № 1. С. 47–51. <https://doi.org/10.14489/vkit.2022.01.pp.047-051>
6. Комкова С. В. Методика обнаружения твердых экссудатов на изображениях глазного дна человека // *Телекоммуникации*. 2022. № 10. С. 24-28.
7. An Adaptive Algorithm for the Detection of Irregular Pupil Contour / Y. Chen [et al.] // *Journal of Medical Systems*. 2019. Vol. 43, N 5. P. 112.
8. Automated Pupil Segmentation and Noise Removal in Iris Images / A. Radman [et al.] // *Journal of Medical Imaging and Health Informatics*. 2017. Vol. 7, N 2. P. 428-436.
9. Wang C., Muhammad J. Iris segmentation and recognition using deep learning // *Neural Computing and Applications*. 2020. N 32(18). P. 14579-14590.
10. Uhl A., Wild P. Weighted Adaptive Hough and Ellipsopolar Transforms for Real-time Iris Segmentation // *Proceedings of the 5th International Conference on Biometrics (ICB'12)*. New Delhi, India, 2012. P. 283–290. <https://doi.org/10.1109/ICB.2012.6199821>
11. An Accurate Iris Segmentation Framework Under Relaxed Imaging Constraints Using Total Variation Model / Z. Zhao, A. Kumar [et al.] // *IEEE International Conference on Computer Vision (ICCV)*. Santiago, Chile, 2025. <https://doi.org/10.1109/ICCV.2015.436>
12. Hofbauer H., Jalilian E., Uhl A. Exploiting Superior CNN-based Iris Segmentation for Better Recognition Accuracy // *Pattern Recognition Letters*. 2019. Vol. 120. P. 17–23. <https://doi.org/10.1016/j.patrec.2018.12.021>

13. Wang K., Kumar A. Toward more accurate and constrained iris segmentation using cascaded multi-task framework // *IEEE Transactions on Information Forensics and Security*. 2021. N 16. P. 2023-2036.
14. Иванов А. В., Петров С. К. Алгоритмы сегментации радужной оболочки глаза при патологиях зрачка // *Биомедицинская радиоэлектроника*. 2020. № 3. С. 45-53.
15. Методы обработки офтальмологических изображений с аномалиями / Е. А. Смирнова [и др.] // *Оптический журнал*. 2021. Т. 88, № 5. С. 78-85.
16. Козлов В. П., Николаева Т. Г. Автоматизированный анализ изображений глазного дна // *Компьютерная оптика*. 2019. Т. 43, № 4. С. 623-630.
17. Гусев Д. А. Цифровая обработка биометрических изображений. М.: Техносфера, 2018. 320 с.
18. Алгоритмы распознавания радужной оболочки при патологиях глаза / П. Н. Белов [и др.] // *Искусственный интеллект и принятие решений*. 2020. № 2. С. 34-42.

References

1. Bowyer K.W., et al. Image understanding for iris biometrics: A survey. *Computer Vision and Image Understanding*. 2018;167:1-21.
2. Raghavendra R., et al. A Comprehensive Survey on Iris Recognition Systems: A Review. *IEEE Access*. 2021;9:45615-45630.
3. Komkova S.V. A method for diagnosing glaucoma from human fundus images. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravljenje, vychislitel'naja tehnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2023;13(3):99–114. (In Russ.)
4. Komkova S.V. Methodology for forming a feature vector based on retinal images. *Estestvennye i tekhnicheskie nauki = Natural and Technical Sciences*. 2021;(4):250-252. (In Russ.)
5. Komkova S.V. Algorithm for identification of exudates in human retinal images // *Vestnik komp'yuternykh i informatsionnykh tekhnologii = Bulletin of Computer and Information Technologies*. 2022;19(1):47-51. (In Russ.) <https://doi.org/10.14489/vkit.2022.01.pp.047-051>
6. Komkova S.V. "Methodology for detecting hard exudates in human fundus images" // *Telekommunikatsii = Telecommunications*. 2022;(10):24-28. (In Russ.)
7. Chen Y., et al. An Adaptive Algorithm for the Detection of Irregular Pupil Contour. *Journal of Medical Systems*. 2019;43(5):112.
8. Radman A., et al. Automated Pupil Segmentation and Noise Removal in Iris Images. *Journal of Medical Imaging and Health Informatics*. 2017;7(2):428-436.

9. Wang C., Muhammad J. Iris segmentation and recognition using deep learning. *Neural Computing and Applications*. 2020;(32):14579-14590.
10. Uhl A., Wild P. Weighted Adaptive Hough and Ellipsopolar Transforms for Real-time Iris Segmentation. In: *Proceedings of the 5th International Conference on Biometrics (ICB'12)*. New Delhi, India; 2012. P. 283–290. <https://doi.org/10.1109/ICB.2012.6199821>
11. Zhao Z., Kumar A., et al. An Accurate Iris Segmentation Framework Under Relaxed Imaging Constraints Using Total Variation Model. In: *IEEE International Conference on Computer Vision (ICCV)*. Santiago, Chile; 2025. <https://doi.org/10.1109/ICCV.2015.436>
12. Hofbauer H., Jalilian E., Uhl A. Exploiting Superior CNN-based Iris Segmentation for Better Recognition Accuracy. *Pattern Recognition Letters*. 2019;120:17–23. <https://doi.org/10.1016/j.patrec.2018.12.021>
13. Wang K., Kumar A. Toward more accurate and constrained iris segmentation using cascaded multi-task framework. *IEEE Transactions on Information Forensics and Security*. 2021;(16):2023-2036.
14. Ivanov A.V., Petrov S.K. Iris segmentation algorithms for pathological pupils. *Biomeditsinskaya radioelektronika = Biomedical Radioelectronics*. 2020;(3):45-53. (In Russ.)
15. Smirnova E.A., et al. Methods for processing ophthalmic images with anomalies. *Opticheskii zhurnal = Optical Journal*. 2021;88(5):78-85. (In Russ.)
16. Kozlov V.P., Nikolaeva T.G. Automated analysis of fundus images. *Komp'yuternaya optika = Computer Optics*. 2019;43(4):623-630. (In Russ.)
17. Gusev D.A. Digital processing of biometric images. Moscow: Tekhnosfera; 2018. 320 p. (In Russ.)
18. Belov P.N., et al. Iris recognition algorithms for eye pathologies. *Iskusstvennyi intellekt i prinyatie reshenii = Artificial Intelligence and Decision Making*. 2020;(2):34-42. (In Russ.)

Информация об авторе / Information about the Author

Комкова Светлана, Владимировна, кандидат технических наук, доцент, Муромский институт (филиал) Владимирского государственного университета имени Александра Григорьевича и Николая Григорьевича Столетовых, Владимирская область, г. Муром, Российская Федерация,
e-mail: savicheva-svetlana2010@yandex.ru,
Researcher ID: N-6360-2016,
ORCID: 0000-0002-4204-0268

Svetlana V. Komkova, Candidate of Sciences (Engineering), Associate Professor, Murom Institute (branch) of Alexander Grigorievich and Nikolai Grigorievich Stoletov Vladimir State University, Vladimir region, Murom, Russian Federation
e-mail: savicheva-svetlana2010@yandex.ru,
Researcher ID: N-6360-2016,
ORCID: 0000-0002-4204-0268

<https://doi.org/10.21869/2223-1536-2026-16-1-77-92>

УДК 004.89+93

Пространственная локализация костных сарком на рентгенограммах с использованием одноэтапной нейросетевой модели

А. В. Киселев¹, Е. А. Кулешова¹, В. Д. Горелов¹,
Т. Н. Конаныхина¹✉, З. К. Чьямова¹

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: govtn@mail.ru

Резюме

Цель исследования – исследование возможности применения одноэтапной нейросетевой модели YOLOv8l-seg для автоматической пространственной локализации костных сарком на рентгенограммах.

Методы. Для обучения нейросетевой модели был синтезирован набор данных на основе аннотированных оцифрованных рентгенограмм с подтвержденными костными саркомами и рентгенограмм без патологии. Изображения в наборе данных были предобработаны (стандартизация размера и контрастности) и разделены на обучающую (1003 изображения) и валидационную (204 изображения) выборки. Для решения задачи сегментации экземпляров костных сарком использовалась нейросетевая модель YOLOv8l-seg с предобученными весами на наборе данных COCO. Процесс дообучения был реализован с применением метода глубокого трансферного обучения. Для предотвращения переобучения нейросетевой модели был применен метод ранней остановки, отслеживающий значение валидационной функции потерь.

Результаты. Тестирование нейросетевой модели проводилось на независимой тестовой выборке, состоявшей из 148 оцифрованных рентгенограмм с подтвержденными костными саркомами и рентгенограмм без патологии, которые не были задействованы на этапах обучения и валидации. Проведенная оценка эффективности показала, что в 78,2% случаев модель не только правильно классифицирует опухоль, но и с приемлемой точностью очерчивает ее пространственные границы, а значение метрики AUC-ROC, равное 0,951, подтверждает высокую дискриминативную способность модели в различении патологии от нормы. Данный результат, хотя и не является эталонным, подтверждает применимость предложенного подхода для решения задачи локализации и контурирования костных сарком на рентгенограммах.

Заключение. Исходя из результатов проведенного анализа, можно сделать вывод, что в отличие от моделей, предоставляющих лишь вероятностную оценку, основное преимущество предлагаемого решения заключается в сегментации экземпляров костных сарком, которая может быть непосредственно использована врачом-рентгенологом в качестве инструмента поддержки принятия решений.

Ключевые слова: костная саркома; рентгенограмма; нейросетевая модель; глубокое трансферное обучение; сегментация экземпляров.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Пространственная локализация костных сарком на рентгенограммах с использованием одноэтапной нейросетевой модели / А. В. Киселев, Е. А. Кулешова, В. Д. Горелов, Т. Н. Конаныхина, З. К. Чьямова // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 77–92. <https://doi.org/10.21869/2223-1536-2026-16-1-77-92>

Поступила в редакцию 20.01.2026

Подписана в печать 18.02.2026

Опубликована 31.03.2026

Spatial localization of bone sarcomas on radiographs using a one-stage neural network model

Alexey V. Kiselev¹, Elena A. Kuleshova¹, Vladislav D. Gorelov¹,
Tatyana N. Konanykhina¹✉, Zoya K. Chyamova¹

¹ Southwest State University

50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: govtn@mail.ru

Abstract

The purpose of the research is to investigate the possibility of using the YOLOv8l-seg single-stage neural network model for automatic spatial localization of bone sarcomas on radiographs.

Methods. To train the neural network model, a data set was synthesized based on annotated digitized radiographs with confirmed bone sarcomas and radiographs without pathology. The images in the dataset were preprocessed (standardization of size and contrast) and divided into training (1003 images) and validation (204 images) samples. To solve the problem of segmentation of bone sarcoma instances, the YOLOv8l-seg neural network model with pre-trained weights on the COCO dataset was used. The retraining process was implemented using the deep transfer learning method. To prevent overfitting of the neural network model, an early stop method was applied that tracks the value of the validation loss function.

Results. The neural network model was tested on an independent test sample consisting of 148 digitized radiographs with confirmed bone sarcomas and X-rays without pathology, which were not involved in the training and validation stages. The efficiency assessment showed that in 78.2% of cases, the model not only correctly classifies the tumor, but also outlines its spatial boundaries with acceptable accuracy, and the AUC-ROC metric value of 0.951 confirms the high discriminative ability of the model in distinguishing pathology from the norm. This result, although not a reference, confirms the applicability of the proposed approach to solving the problem of localization and contouring of bone sarcomas on radiographs.

Conclusion. Based on the results of the analysis, it can be concluded that, unlike models that provide only a probabilistic estimate, the main advantage of the proposed solution lies in the segmentation of bone sarcoma instances, which can be directly used by a radiologist as a decision support tool.

Keywords: bone sarcoma; radiograph; neural network model; deep transfer learning; instance segmentation.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Kiselev A.V., Kuleshova E.A., Gorelov V.D., Konanykhina T.N., Chyamova Z.K. Spatial localization of bone sarcomas on radiographs using a one-stage neural network model. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = Proceedings

Введение

Злокачественные новообразования костной ткани, известные как костные саркомы (КС), отличаются значительным гистогенетическим полиморфизмом. Ключевыми особенностями данной группы заболеваний выступают высокая склонность к гематогенному метастазированию и, как следствие, преобладание неблагоприятных клинических исходов. Несмотря на исключительную редкость в общей онкологической практике (удельный вес этих опухолей не превышает 0,2%), проблема их диагностики и лечения сохраняет высокую медико-социальную значимость. Объясняется это тем, что основную группу пациентов формируют дети и молодежь, т. е. наиболее активная в социальном плане часть общества. Согласно эпидемиологическому регистру SEER (США), ежегодная заболеваемость КС составляет приблизительно 0,9 на 100000 человек. Что касается гистологической структуры, классификация Всемирной организации здравоохранения (ВОЗ) указывает на лидирующую позицию остеосаркомы, которая диагностируется в 35% случаев. Реже встречаются хондросаркома (25%) и саркома Юинга (16%) [1].

В настоящее время ранняя диагностика КС остаётся затруднённой вследствие схожести рентгенологических

проявлений с доброкачественными образованиями и воспалительными процессами [2]. Важность раннего выявления КС обусловлена высоким процентом пациентов с уже сформированными метастатическими очагами на момент первичной диагностики [3]. Эпидемиологические данные свидетельствуют, что у 5% больных к этому времени выявляется поражение регионарных лимфатических узлов, а у каждой третьей части пациентов (около 34%) обнаруживаются отдаленные метастазы, что существенно осложняет прогноз и ограничивает возможности терапии [4]. Метод стандартной рентгенографии предоставляет возможности для выявления структурных изменений костной ткани [5]. С его помощью могут быть визуализированы такие патологические проявления, как очаги деструкции кортикального слоя, реактивные изменения надкостницы, формирование опухолевого матрикса и распространение патологического процесса на прилежащие мягкие ткани [6].

Низкая распространенность первичных злокачественных новообразований костной ткани закономерно приводит к ограниченному клиническому опыту их диагностики в практике рентгенологов [7]. В этой связи разработка автоматизированных систем для анализа рентгенологических изображений

приобретает особую значимость. Внедрение подобных технологий способно повысить эффективность выявления заболеваний на начальных стадиях, а также снизить нагрузку на медицинский персонал [8]. Также это может помочь справиться с недостатком узких специалистов и повысить доступность качественной диагностики для населения, не зависящей от географического положения или экспертного опыта отдельных врачей [9]. В основе таких методов чаще всего лежат алгоритмы глубокого обучения, способные выявлять патологические изменения при анализе медицинских изображений [10]. Благодаря способности к автоматическому извлечению пространственных признаков сверточные нейронные сети демонстрируют высокую эффективность при обработке и анализе рентгенографических изображений [11]. Существует ряд исследований, где в основе таких методов лежат алгоритмы глубокого обучения, способные выявлять патологические изменения при анализе медицинских изображений. Например, в работе [12] авторами была предложена специализированная нейросетевая архитектура, основанная на модели DenseNet, для решения задачи трехклассовой классификации опухолей проксимального отдела бедренной кости (злокачественные, доброкачественные, отсутствие опухоли) на основе рентгенограмм. В ходе валидации модель продемон-

стровала результаты, которые оказались лучше средних показателей четырех врачей-рентгенологов.

В работе [13] авторами был проведен анализ эффективности применения различных архитектур глубокого обучения для диагностики костных опухолей на рентгенограммах. Авторы обучили и сравнили несколько моделей с использованием трансферного обучения – VGG16, VGG19, ResNet101 и DenseNet-201. Модели обучались на наборе данных, содержащем 1144 гистологических изображения, распределенных по трем категориям: «нет опухоли», «жизнеспособная опухоль» и «некротическая опухоль». Согласно результатам, полученным в ходе экспериментов, модель ResNet101 продемонстрировала наилучшие результаты (значение метрики AUC-ROC равное 0,946).

В [14] авторами был разработан алгоритм на основе архитектуры EfficientNet-B0 для классификации первичных опухолей костей по рентгенограммам. С помощью него авторы решали задачу трехклассовой классификации костных новообразований (доброкачественные, промежуточные, злокачественные). Точность модели не имела статистически значимых отличий от точности опытных рентгенологов, но превзошла менее опытных специалистов.

Результаты предшествующих исследований указывают на высокий потенциал применения моделей на основе архитектур глубокого обучения, для

раннего обнаружения и точной локализации КС в системах поддержки принятия врачебных решений.

Материалы и методы

Набор данных для обучения был синтезирован на основе аннотированных оцифрованных рентгенограмм с подтвержденными КС и рентгенограмм без патологии, отобранных из нескольких открытых источников (набор данных Osteosarcoma data from UT Southwestern/UT Dallas for Viable and Necrotic Tumor Assessment¹ и набор данных A Radiograph Dataset for the Classification, Localization, and Segmentation of Primary Bone Tumors) [15]. Изображения в этих наборах данных были проаннотированы с помощью специальных масок, необходимых для решения задачи сегментации экземпляров КС (рис. 1).

Поскольку данные были разнородны по качеству и параметрам визуализации, была проведена их предобработка, в ходе которой изображения приводились к единому размеру и стандартизировались по уровню контрастности. После этого все изображения были разделены на обучающую выборку, включающую в себя 1003 изображения и валидационную выборку, включающую в себя 204 изображения (в пропорции 83%

и 17% соответственно от общего количества изображений в наборе данных).

Для решения задачи сегментации экземпляров КС в рамках данного исследования использовалась НМ YOLOv8l-seg с предобученными весами на наборе данных COCO [16]. Данная НМ применяет одноэтапный подход, при котором процедуры детекции и сегментации выполняются за единый проход через нейронную сеть. Данная парадигма исключает необходимость генерации предварительных регионов интереса (Region of Interest – ROI), что обеспечивает сохранение контекстной информации по всему изображению. КС демонстрируют высокую вариабельность морфологических характеристик, включая полиморфизм контуров, гетерогенность внутренней структуры и существенные различия в размерах. Эта вариабельность морфологических характеристик КС является сложным комплексным паттерном. Одноэтапный подход, сохраняющий полный контекст, позволяет НМ анализировать этот паттерн целиком. Процесс дообучения был реализован с применением метода глубокого трансферного обучения [17]. Нижние слои модели, отвечающие за извлечение признаков, инициализировались предобученными весами и постепенно размораживались, в то время как верхние слои адаптировались под специфику изображений из обучающего набора данных. Гиперпараметры НМ подбирались эмпирически исходя из поведения функций потерь (рис. 2) и метрик качества, полученных в процессе

¹ Osteosarcoma data from UT Southwestern UT Dallas for Viable and Necrotic Tumor Assessment / P. Leavey, A. Sengupta, D. Rakheja, O. Daescu, H. B. Arunachalam, R. Mishra. URL: <https://www.cancerimagingarchive.net/collection/osteosarcoma-tumor-assessment/> (дата обращения: 16.12.2025).

обучения и валидации (рис. 3). Для предотвращения переобучения НМ был применен метод ранней остановки, отслеживающий значение валидационной функции потерь. Алгоритм автоматически прекращает итерационный процесс, если в течение 10 эпох не наблюдается

снижения данного показателя. При срабатывании условия ранней остановки происходит автоматическое восстановление весовых коэффициентов модели до состояния, соответствующего эпохе с минимальным значением функции потерь на валидационной выборке.




Рис. 1. Пример аннотированных изображений из набора данных с масками сегментации

Fig. 1. Example of annotated images from the dataset with segmentation masks




Рис. 2. Графики функций потерь, полученные в процессе обучения и валидации НМ

Fig. 2. Graphs of loss functions obtained during the training and validation of the NM




Рис. 3. Графики метрик качества сегментации экземпляров, полученные в процессе обучения и валидации НМ

Fig. 3. Graphs of the quality metrics of instance segmentation obtained during the training and validation of the NM

Для количественной оценки качества работы алгоритмов классификации и сегментации экземпляров применяется система метрик, основанных на анализе матрицы ошибок. Precision отражает долю истинно положительных примеров среди всех объектов, классифицированных моделью как положительные. Recall характеризует способность модели обнаруживать все релевантные объекты и вычисляется как доля истинно положительных срабатываний среди всех фактически положительных примеров. Precision и Recall рассчитываются по следующим формулам:

$$Precision = \frac{TP}{TP+FP}, \quad (1)$$

$$recall = \frac{TP}{TP+FN}, \quad (2)$$

где TP (True Positives) – количество правильно предсказанных положительных примеров; FP (False Positives) – ко-

личество неправильно предсказанных положительных примеров; FN (False Negatives) – количество неправильно предсказанных отрицательных примеров [18]; mAP (mean Average Precision) – среднее арифметическое значений площадей под кривой Precision – Recall по всем классам объектов в наборе данных для заданного порога IoU ; IoU – коэффициент пересечения ($A \cap B$) и объединения ($A \cup B$) площадей:

$$IoU = \frac{S(A \cap B)}{S(A \cup B)}; \quad (3)$$

A и B – предсказанная маска сегментации и настоящая маска сегментации соответственно, при этом $IoU = 0$, если A и B не пересекаются, $IoU = 1$ в случае идеального наложения [19].

При заданном пороге IoU равном 0,5 метрику mAP можно представить с помощью выражения

$$mAP(0,5) = \frac{(AP_{class1(IoU=0,5)} + AP_{class2(IoU=0,5)} + \dots + AP_{classN(IoU=0,5)})}{N}, \quad (4)$$

где $AP_{classx(IoU=0,5)}$ – это площадь под кривой Precision – Recall для конкретного класса x , вычисленная при усло-

вии, что предсказанная рамка считается правильно предсказанным положительным примером только в том случае, ес-




Рис. 5. Визуализированные результаты сегментации экземпляров обученной НМ для класса bone cancer

Fig. 5. Visualized results of instance segmentation of the trained NM for the class bone cancer

Показатель качества классификации должен выбираться таким образом, чтобы он зависел как от ошибок как первого, так и второго рода, а недопустимо большие ошибки хотя бы одного вида снижали бы показатель качества классификации к недопустимым значениям [20]. Таким сбалансированным и строгим критерием является площадь под ROC-кривой (AUC-ROC), поэтому для оценки непосредственно классификационной составляющей модели был применен ROC-анализ. Результаты ROC-анализа предлагаемой НМ представлены ниже (рис. 6).

Значение метрики AUC-ROC равное 0,951 подтверждает высокую дискриминативную способность модели в различении патологии от нормы. Высо-

кое значение AUC-ROC, дополненное приемлемыми значениями mAP, позволяет утверждать, что модель обладает сбалансированной эффективностью как в аспекте классификации, так и в аспекте сегментации экземпляров КС на рентгенограммах.

Также было проведено сравнение предлагаемого решения с НМ из исследования [13]. Значения метрики AUC-ROC для НМ из [13] и для YOLOv8l-seg с применением методов глубокого трансферного обучения и ранней остановки приведены ниже (табл. 1).

Исходя из результатов проведенного анализа можно сделать вывод, что предложенная в исследовании модель YOLOv8l-seg с применением методов глубокого трансферного обуче-

ния и ранней остановки продемонстрировала наибольшее значение AUC-ROC (0,951) по сравнению с HM семейства VGG, DenseNet-201 и ResNet-101. Однако основное преимущество данного решения заключа-

ется в решении задачи сегментации экземпляров. Модель YOLOv8l-seg с применением методов глубокого трансферного обучения и ранней остановки обеспечивает приемлемую пространственную локализацию КС.




Рис. 6. Результаты ROC-анализа предлагаемой HM

Fig. 6. Results of ROC analysis proposed by NM

Таблица 1. Значения метрики AUC-ROC для HM и YOLOv8l-seg с применением методов глубокого трансферного обучения и ранней остановки

Table 1. AUC-ROC metric values for the NM and YOLOv8l-seg using deep transfer learning and early stopping methods

HM	Значение AUC-ROC
VGG16	0,909
VGG19	0,931
DenseNet-201	0,909
ResNet 101	0,946
YOLOv8l-seg с применением методов глубокого трансферного обучения и ранней остановки	0,951

Выводы

В данной работе исследована возможность применения одноэтапной нейросетевой модели YOLOv8l-seg для автоматической пространственной локализации КС на рентгенограммах.

Для обучения НМ был синтезирован набор данных на основе аннотированных оцифрованных рентгенограмм с подтвержденными КС и рентгенограмм без патологии. Для решения задачи сегментации экземпляров КС использовалась НМ YOLOv8l-seg с предобученными весами на наборе данных СОСО. Процесс дообучения был реализован с применением метода глубокого трансферного обучения. Для предотвращения переобучения НМ был применен метод ранней остановки, отслеживающий значение валидационной функции потерь.

Проведенная оценка эффективности показала, что в 78,2% случаев модель не только правильно классифицирует опухоль, но и с приемлемой точностью очерчивает ее пространственные границы, а значение метрики AUC-ROC равное 0,951 подтверждает высокую дискриминативную способность модели в различении патологии от нормы. Данный результат, хотя и не является эталонным, подтверждает применимость предложенного подхода для решения задачи локализации и контурирования КС на рентгенограммах.

В отличие от моделей, предоставляющих лишь вероятностную оценку, основное преимущество предлагаемого решения заключается в сегментации экземпляров КС, которая может быть непосредственно использована врачом-рентгенологом в качестве инструмента поддержки принятия решений.

Список литературы

1. Алескерова Х. А., Романцова О. М., Хайруллова В. В. Дифференциальная диагностика телеангиэктатической остеосаркомы и аневризмальной костной кисты (обзор литературы) // Российский журнал детской гематологии и онкологии. 2024. Т. 11, № 2. С. 67-73. <https://doi.org/10.21682/2311-1267-2024-11-2-67-73>
2. Патофизиологические особенности клинической диагностики хондросарком / Н. В. Емельянова, А. В. Скворцова, Е. С. Милованова, О. Н. Ямщиков // International Journal of Medicine and Psychology. 2022. Т. 5, № 3. С. 124-132.
3. Mandat T. S., Metastatic High-Grade Intimal Sarcoma of the Middle Cranial Fossa // Journal on Oncology. 2022. Vol. 2, N 2. <https://doi.org/10.52768/2692-563x/1053>
4. Конторович Д. С., Пронькина Е. В., Нуднов Н. В. Внескелетная саркома Юинга малого таза (обзор литературы и клиническое наблюдение) // Медицинская визуализация. 2021. № 25(3). С. 150-156. <https://doi.org/10.24835/1607-0763-924>
5. Matcuk G., Waldman L., Fields B. K. Conventional radiography for the assessment of focal bone lesions of the appendicular skeleton: fundamental concepts in the modern imaging

era // Skeletal Radiol. 2025. Vol 54. P. 1391–1406. <https://doi.org/10.1007/s00256-024-04854-6>

6. Современные возможности и трудности диагностики костных сарком у детей / А. А. Очкурено, А. В. Петриченко, П. А. Романов [и др.] // Педиатрия. Журнал имени Г. Н. Сперанского. 2020. Т. 99, № 4. С. 56-62. <https://doi.org/10.24110/0031-403X-2020-99-4-56-62>

7. Булычева И. В., Федорова А. В. Основы алгоритма рентгеноморфологического исследования костных препаратов // Онкопатология. 2021. Т. 4, № 1(2). С. 18-31. <https://doi.org/10.17650/2618-7019-2021-4-1-2-18-31>

8. Анализ эффективности применения архитектуры U-net для классификации и сегментации глиомы на МРТ-снимках / А. В. Киселев, Е. А. Кулешова, М. О. Таныгин [и др.] // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 3. С. 104-120. <https://doi.org/10.21869/2223-1536-2024-14-3-104-120>

9. Брежнев А. В., Томакова Р. А., Черных Е. В. Информационная система для прогнозирования рецидивов инфаркта миокарда, реализованная как мобильное приложение // Информационное общество. 2023. № 1. С. 116-126. https://doi.org/10.52605/16059921_2023_01_116

10. Томакова Р. А., Дзюбин И. А., Брежнев А. В. Метод и алгоритм обучения сверточной нейронной сети, предназначенной для интеллектуальной системы распознавания меланомы // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. Т. 12, № 1. С. 65-83. <https://doi.org/10.21869/2223-1536-2022-12-1-65-83>

11. Метод анализа оцифрованных рентгеновских снимков грудной клетки для дифференциальной диагностики инфекционных заболеваний дыхательной системы / И. О. Мишин, М. О. Таныгин, А. В. Киселев [и др.] // Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии. 2024. № 4. С. 143-155. <https://doi.org/10.17308/sait/1995-5499/2024/4/143-155>

12. Femur Tumor Net: Bone tumor classification in the proximal femur using DenseNet model based on radiographs / C. Pan, L. Lian, J. Chen, R. Huang // Journal of Bone Oncology. 2023. Vol. 42. P. 7639. <https://doi.org/10.1016/j.jbo.2023.100504>

13. Application of the convolutional neural networks and supervised deep-learning methods for osteosarcoma bone cancer detection / S. Gawade, A. Bhansali, K. Patil, D. Shaikh // Healthcare Analytics. 2023. Vol. 3 (6). P. 100153. <https://doi.org/10.1016/j.health.2023.100153>

14. Deep learning-based classification of primary bone tumors on radiographs / Y. He, I. Pan, B. Bao, K. Halsey, M. Chang [et al.] // EBioMedicine: A preliminary study. 2020. Vol. 62. P. 103121. <https://doi.org/10.1016/j.ebiom.2020.103121>

15. A Radiograph Dataset for the Classification, Localization, and Segmentation of Primary Bone Tumors / S. Yao, Y. Huang, X. Wang, Y. Zhang, I. C. Paixao, Z. Wang [et al.] // Scientific Data. 2024. N 12(1). P. 88. <https://doi.org/10.1038/s41597-024-04311-y>
16. Основные подходы к подготовке визуальных данных для обучения нейросетевых алгоритмов / А. Г. Лапушкин, Д. А. Гаврилов, Н. Н. Щелкунов, Р. Н. Бакеев // Искусственный интеллект и принятие решений. 2021. № 4. С. 62-74. <https://doi.org/10.14357/20718594210406>
17. Iman M., Arabnia H. R., Rasheed K. A review of deep transfer learning and recent advancements // Technologies. 2023. Vol. 11(2). P. 1-14. <https://doi.org/10.3390/technologies11020040>
18. Методы нейросетевой детекции сельскохозяйственных животных в плотных динамических группах на изображениях / А. А. Жигалов, О. А. Иващук, Т. К. Бирюкова, В. И. Федоров // Искусственный интеллект и принятие решений. 2023. № 1. С. 55-66. <https://doi.org/10.14357/20718594230106>
19. Киселев А. В., Брусенцев Н. С., Кулешова Е. А. Анализ эффективности применения двухэтапных нейросетевых моделей для раннего обнаружения лесных пожаров // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 1. С. 8-23. <https://doi.org/10.21869/2223-1536-2024-14-1-8-23>
20. Модели латентных предикторов в интеллектуальных системах прогнозирования состояния живых систем / А. В. Киселев, О. В. Шаталова, З. У. Протасова [и др.] // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2020. Т. 10, № 1. С. 114-133.

References

1. Aleskerova Kh.A., Romantsova O.M., Khairullova V.V. Differencial'naya diagnostika teleangiektaticheskoy osteosarkomy i anevrizmal'noj kostnoj kisty (obzor literatury). *Rossiyskiy zhurnal detskoy gematologii i onkologii = Russian Journal of Pediatric Hematology and Oncology*. 2024;11(2):67-73. (In Russ.) <https://doi.org/10.21682/2311-1267-2024-11-2-67-73>
2. Emelyanova N.V., Skvortsova A.V., Milovanova E.S., Yamshchikov O.N. Patofiziologicheskie osobennosti klinicheskoy diagnostiki hondrosarkom. *International Journal of Medicine and Psychology*. 2022;5(3):124-132. (In Russ.)
3. Mandat T.S. Metastatic High-Grade Intimal Sarcoma of the Middle Cranial Fossa. *Journal on Oncology*. 2022;2(2). <https://doi.org/10.52768/2692-563x/1053>

4. Kontorovich D.S., Pronkina E.V., Nudnov N.V. Vneskeletnaya sarkoma Yuinga malogo taza (obzor literatury i klinicheskoe nablyudenie). *Meditinskaya vizualizatsiya = Medical Visualization*. 2021;(25):150-156. (In Russ.) <https://doi.org/10.24835/1607-0763-924>
5. Matcuk G., Waldman L., Fields B.K. Conventional radiography for the assessment of focal bone lesions of the appendicular skeleton: fundamental concepts in the modern imaging era. *Skeletal Radiol*. 2025;54:1391–1406. <https://doi.org/10.1007/s00256-024-04854-6>
6. Ochkurenko A.A., Petrichenko A.V., Romanov P.A., et al. Sovremennye vozmozhnosti i trudnosti diagnostiki kostnyh sarkom u detej. *Pediatrics. Zhurnal im. G.N. Speranskogo = Pediatrics. Journal named after G.N. Speransky*. 2020;99(4):56-62. (In Russ.) <https://doi.org/10.24110/0031-403X-2020-99-4-56-62>
7. Bulycheva I.V., Fedorova A.V. Osnovy algoritma rentgenomorfologicheskogo issledovaniya kostnyh preparatov. *Onkopatologiya = Oncopathology*. 2021;4(1):18-31. (In Russ.) <https://doi.org/10.17650/2618-7019-2021-4-1-2-18-31>
8. Kiselev A.V., Kuleshova E.A., Tanygin M.O., et al. Analiz effektivnosti primeneniya arhitektury U-net dlya klassifikatsii i segmentatsii gliomy na MRT-snimkah. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2024;14(3):104-120. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-3-104-120>
9. Brezhnev A.V., Tomakova R.A., Chernykh E.V. Informacionnaya sistema dlya prognozirovaniya recidivov infarkta miokarda, realizovannaya kak mobil'noe prilozhenie. *Informatsionnoye obshchestvo = Information Society*. 2023;(1):116-126. (In Russ.) https://doi.org/10.52605/16059921_2023_01_116
10. Tomakova R.A., Dzyubin I.A., Brezhnev A.V. Metod i algoritm obucheniya svertochnoj nejronnoj seti, prednaznachenoj dlya intellektual'noj sistemy raspoznavaniya melanomy. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2022;12(1):65-83. (In Russ.) <https://doi.org/10.21869/2223-1536-2022-12-1-65-83>
11. Mishin I.O., Tanygin M.O., Kiselev A.V. Metod analiza ocifrovannyh rentgenovskih snimkov grudnoj kletki dlya differentsial'noj diagnostiki infekcionnyh zabolevanij dyhatel'noj sistemy. *Vestnik Voronezhskogo gosudarstvennogo universiteta. Seriya: Sistemnyy analiz i informatsionnyye tekhnologii = Proceedings of Voronezh State University. Series: Systems Analysis and Information Technologies*. 2024;(4):143-155. (In Russ.) <https://doi.org/10.17308/sait/1995-5499/2024/4/143-155>

12. Pan C., Lian L., Chen J., Huang R. Femur Tumor Net: Bone tumor classification in the proximal femur using DenseNet model based on radiographs. *Journal of Bone Oncology*. 2023;42:7639. <https://doi.org/10.1016/j.jbo.2023.100504>
13. Gawade S., Bhansali A., Patil K., Shaikh D. Application of the convolutional neural networks and supervised deep-learning methods for osteosarcoma bone cancer detection. *Healthcare Analytics*. 2023;3:100153. <https://doi.org/10.1016/j.health.2023.100153>
14. He Y., Pan I., Bao B., Halsey K., Chang M., et al. Deep learning-based classification of primary bone tumors on radiographs. *EBioMedicine: A Preliminary Study*. 2020;62:103121. <https://doi.org/10.1016/j.ebiom.2020.103121>
15. Yao S., Huang Y., Wang X., Zhang Y., Paixao I. C., Wang Z., et al. A Radiograph Dataset for the Classification, Localization, and Segmentation of Primary Bone Tumors. *Scientific Data*. 2024;(12):88. <https://doi.org/10.1038/s41597-024-04311-y>
16. Lapushkin A.G., Gavrilov D.A., Shchelkunov N.N., Bakeev R.N. Osnovnye podhody k podgotovke vizual'nyh dannyh dlya obucheniya nejrosetevykh algoritmov. *Iskusstvennyy intellekt i prinyatiye resheniy = Artificial Intelligence and Decision Making*. 2021;(4):62-74. (In Russ.) <https://doi.org/10.14357/20718594210406>
17. Iman M., Arabnia H.R., Rasheed K. A review of deep transfer learning and recent advancements. *Technologies*. 2023;11(2):1-14. <https://doi.org/10.3390/technologies11020040>
18. Zhigalov A.A., Ivashchuk O.A., Biryukova T.K., Fedorov V.I. Metody nejrosetevoj detekcii sel'skohozyajstvennykh zhivotnykh v plotnykh dinamicheskikh gruppah na izobrazheniyah. *Iskusstvennyy intellekt i prinyatiye resheniy = Artificial Intelligence and Decision Making*. 2023;(1):55-66. (In Russ.) <https://doi.org/10.14357/20718594230106>
19. Kiselev A.V., Brusentsev N.S., Kuleshova E.A. Analiz effektivnosti primeneniya dvuhetapnykh nejrosetevykh modelej dlya rannego obnaruzheniya lesnykh pozharov. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2024;14(1):8-23. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-1-8-23>
20. Kiselev A.V., Shatalova O.V., Protasova Z.U., et al. Modeli latentnykh prediktorov v intellektual'nykh sistemah prognozirovaniya sostoyaniya zhivykh sistem. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2020;10(1):114-133. (In Russ.)

Информация об авторах / Information about the Authors

Киселев Алексей Викторович, кандидат технических наук, доцент, доцент кафедры вычислительной техники, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: kiselevalexey1990@gmail.com,
ORCID: 0000-0001-7228-0281

Alexey V. Kiselev, Candidate of Sciences (Engineering), Associate Professor, Associate Professor at the Department of Computer Engineering, Southwest State University, Kursk, Russian Federation,
e-mail: kiselevalexey1990@gmail.com,
ORCID: 0000-0001-7228-0281

Кулешова Елена Александровна, кандидат технических наук, доцент кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: lena.kuleshova.94@mail.ru,
ORCID: 0000-0002-8270-564X

Elena A. Kuleshova, Candidate of Sciences (Engineering), Associate Professor at the Department of Computer Engineering, Southwest State University, Kursk, Russian Federation,
e-mail: lena.kuleshova.94@mail.ru,
ORCID: 0000-0002-8270-564X

Горелов Владислав Дмитриевич, студент кафедры вычислительной техники, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: vladisgorr@gmail.com,
ORCID: 0009-0002-7315-3510

Vladislav D. Gorelov, Student at the Department of Computer Engineering, Southwest State University, Kursk, Russian Federation,
e-mail: vladisgorr@gmail.com,
ORCID: 0009-0002-7315-3510

Конаныхина Татьяна Николаевна, кандидат технических наук, доцент, доцент кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: govtn@mail.ru,
ORCID: 0000-0002-2755-0163

Tatyana N. Konanykhina, Candidate of Sciences (Engineering), Associate Professor, Associate Professor at the Department of Software Engineering, Southwest State University, Kursk, Russian Federation,
e-mail: govtn@mail.ru,
ORCID: 0000-0002-2755-0163

Чьямова Зоя Константиновна, студент кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: zoyachyamova@gmail.com,
ORCID: 0009-0000-7734-052X

Zoya K. Chyamova, Student at the Department of Information Security, Southwest State University, Kursk, Russian Federation,
e-mail: zoyachyamova@gmail.com,
ORCID: 0009-0000-7734-052X

<https://doi.org/10.21869/2223-1536-2026-16-1-93-106>

УДК 615.8

Анализ методов обработки и исследования речевого сигнала для установления психоэмоционального состояния человека

Д. А. Кравчук¹✉, А. С. Котенко¹

¹ Южный федеральный университет

ул. Шевченко, д. 2/Е, Ростовская область, г. Таганрог 347922, Российская Федерация

✉ e-mail: kravchukda@sfedu.ru

Резюме

Целью исследований является всесторонний анализ речевого сигнала для выявления его параметров, наиболее информативных для определения психоэмоционального состояния говорящего. Работа направлена на сравнительное изучение и демонстрацию возможностей различных методов обработки сигналов (на основе анализа функции автокорреляции, спектрального, вейвлет-анализа и аттракторного анализа) в контексте извлечения биомаркеров психоэмоциональных состояний.

Методы. В работе применяется комплекс методов частотно-временного и нелинейного анализа речевого сигнала, реализованных в среде Matlab: автокорреляционный анализ – для оценки периодичности сигнала и определения частоты основного тона, параметры которой (среднее значение, дисперсия, характер изменений) служат биомаркерами эмоций; спектральный анализ (спектрограмма) – для визуализации и анализа изменения спектрального состава сигнала во времени, выявления формант и особенностей артикуляции, связанных с эмоциональной окраской; вейвлет-анализ (с использованием вейвлета Морле) – для исследования локализованных во времени особенностей сигнала на разных частотных масштабах, что позволяет анализировать переходные процессы и распределение энергии по частотным диапазонам; аттракторный анализ (анализ динамических систем) – для реконструкции фазового пространства речевого сигнала и исследования его нелинейной динамики через построение и анализ аттракторов (их формы, сложности, фрактальной размерности).

Результаты. Подтверждена эффективность каждого метода в выявлении специфических биомаркеров эмоционального состояния. Показано, что комплексное применение методов обеспечивает более глубокое и полное понимание речевого сигнала, чем каждый метод в отдельности. Установлено, что аттракторный анализ является наиболее перспективным методом для первичного выявления глубинных изменений, связанных с психоэмоциональным состоянием.

Заключение. Комбинированный подход позволяет всесторонне оценивать речевую динамику. Особенно выделен потенциал аттракторного анализа как метода, способного выявлять тонкие нелинейные паттерны, что открывает новые возможности в разработке систем автоматического определения психоэмоционального состояния, диагностики нарушений и создания более естественных человеко-машинных интерфейсов.

Ключевые слова: методы исследования речевого сигнала; определение психоэмоционального состояния человека; параметры речевого сигнала; обработка речевого сигнала.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Кравчук Д. А., Котенко А. С. Анализ методов обработки и исследования речевого сигнала для установления психоэмоционального состояния человека // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 93–106. [https://doi.org/ 10.21869/2223-1536-2026-16-1-93-106](https://doi.org/10.21869/2223-1536-2026-16-1-93-106)

Поступила в редакцию 11.01.2026

Подписана в печать 10.02.2026

Опубликована 31.03.2026

Analysis of speech signal processing and research methods for establishing the psycho-emotional state of a person

Denis A. Kravchuk¹✉, Alexander S. Kotenko¹

¹ Southern Federal University

2/E Shevchenko Str., Rostov region, Taganrog 347922, Russian Federation

✉ e-mail:

Abstract

The purpose of the research is a comprehensive analysis of the speech signal to identify its parameters most informative for determining the speaker's psychoemotional state. The work is aimed at the comparative study and demonstration of the capabilities of various signal processing methods (based on autocorrelation function analysis, spectral, wavelet, and attractor analysis) in the context of extracting biomarkers of psychoemotional states.

Methods. The work employs a set of methods for time-frequency and nonlinear analysis of the speech signal, implemented in the Matlab environment: autocorrelation analysis – to assess signal periodicity and determine fundamental frequency, the parameters of which (mean value, variance, nature of changes) serve as emotion biomarkers; spectral analysis (spectrogram) – for visualization and analysis of changes in the spectral composition of the signal over time, identifying formants and articulation features associated with emotional coloring; wavelet analysis (using the Morlet wavelet) – for investigating time-localized features of the signal at different frequency scales, allowing the analysis of transient processes and energy distribution across frequency bands; attractor analysis (dynamic systems analysis) – for reconstructing the phase space of the speech signal and investigating its nonlinear dynamics through the construction and analysis of attractors (their shape, complexity, fractal dimension).

Results. The effectiveness of each method in revealing specific biomarkers of emotional state was confirmed. It was shown that the combined application of the methods provides a deeper and more complete understanding of the speech signal than each method individually. It was concluded that attractor analysis is the most promising method for the primary detection of profound changes related to psychoemotional state, due to its ability to reveal nonlinear and hidden patterns inaccessible to traditional linear methods.

Conclusion. The research demonstrates that modern speech signal analysis methods, from classical ones (autocorrelation function, spectrogram) to advanced ones (wavelet and attractor analysis), provide a powerful toolkit for extracting objective emotion biomarkers. A combined approach allows for a comprehensive assessment of speech dynamics. The potential of attractor analysis is particularly highlighted as a method capable of detecting subtle nonlinear patterns, which opens new opportunities in developing systems for automatic determination of psychoemotional state, diagnosis of disorders, and creating more natural human-machine interfaces.

Keywords: speech signal research methods; human psychoemotional state determination; speech signal parameters; speech signal processing.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Kravchuk D.A., Kotenko A.S. Analysis of speech signal processing and research methods for establishing the psycho-emotional state of a person. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(1):93–106. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-93-106>

Received 11.01.2026

Accepted 10.02.2026

Published 31.03.2026

Введение

Актуальность исследования методов анализа речевого сигнала обусловлена их широким потенциалом применения в различных областях, включая медицинские учреждения, авиацию, диспетчерские службы, службы общественной безопасности и экстренного реагирования [1]. Методы анализа речевого сигнала применяются во многих системах, например: системы распознавания и синтеза речи, системы идентификации личности по голосу или выявления признаков стресса или лжи [2], системы диагностики заболеваний по изменениям в голосе [3], системы улучшения качества связи, кодирования [4] и сжатия речи [5]. Инновации в области обработки речи и нейронных сетей значительно повысили точность и надежность этих методов, делая их все более востребованными при разработке систем анализа речи.

Материалы и методы

Постановка задачи

Функция автокорреляции измеряет степень сходства сигнала с самим собой, сдвинутым по времени. Для периодических сигналов (а речь в определенной степени периодична, особенно гласные звуки) [6], автокорреляция по-

казывает пики на временах, соответствующих периодам сигнала [7], что позволяет определять частоту основного тона речевого сигнала [8]. Частота основного тона (F_0), представляющая собой скорость вибрации голосовых связок, является важной характеристикой речи [9], определяющей высоту голоса [10].

Оценка F_0 применяется в различных задачах, включая анализ эмоциональной окраски речи, гендерную идентификацию [11], сегментацию многоголосых аудиозаписей и в клинической фонологии для диагностики дисфоний и других нарушений голосовой функции [12].

Анализ частоты основного тона по функции автокорреляции

Функция автокорреляции вычисляется для определенного фрагмента речевого сигнала согласно следующему уравнению:

$$R(\tau) = \sum_{i=0}^n [x(t_n) \cdot x(t_n + \tau)], \quad (1)$$

где $R(\tau)$ — значение автокорреляции при сдвиге τ ; n — количество всех точек выбранного фрагмента, по которым ведется суммирование; $x(t_n + \tau)$ — значение сигнала в момент времени $t_n + \tau$; $x(t_n)$ — значение сигнала в момент времени t_n .

Представление частоты основного тона речевого сигнала с помощью функции автокорреляции в Matlab 2017b приведено ниже (рис. 1). В качестве речевого сигнала использовался фрагмент речи диктора (слово «положиться»), испытывающего злость.

Основные биомаркеры эмоционального состояния на графике частоты основного тона речевого сигнала:

- высокая средняя F0: часто указывает на возбуждение, радость, страх или гнев (активные эмоции часто связаны с повышением F0);
- низкая средняя F0: может указывать на грусть, усталость или депрессию (пассивные эмоции часто связаны с понижением F0);

– большая дисперсия F0 (широкий диапазон колебаний): может указывать на возбуждение, интерес или нестабильность эмоционального состояния (повышенная эмоциональная вовлеченность часто приводит к большему колебанию высоты голоса);

– маленькая дисперсия F0 (узкий диапазон колебаний): может указывать на спокойствие, безразличие или подавленность (сниженная эмоциональная вовлеченность может приводить к монотонности голоса);

– резкие скачки F0: могут указывать на удивление, страх или гнев;

– плавные изменения F0: могут указывать на спокойствие, грусть или задумчивость [9].




Рис. 1. Представление частоты основного тона речевого сигнала с помощью функции автокорреляции в Matlab

Fig. 1. Representation of the fundamental frequency of a speech signal using the autocorrelation function in Matlab

Результаты и их обсуждение

Обработка экспериментальных данных на основе различных моделей речевого сигнала. Частотный анализ речевого сигнала

Спектрограмма – это визуальное представление частотного состава сигнала во времени [1]. Она отображает, какие частоты присутствуют в сигнале в каждый момент времени, и их относительную интенсивность. Обычно отображается в виде изображения, где:

- ось X: время;
- ось Y: частота;
- цвет (или оттенок серого): интенсивность частоты (чем ярче цвет, тем больше интенсивность).

Применение:

- спектрограммы позволяют визуально анализировать речевой сигнал, различать фонемы, определять границы слов и фраз, выявлять особенности произношения;

- речевая диагностика включает использование спектрограмм для анализа речи у людей с различными нарушениями речевого аппарата;

- спектрограммы также применяются в системах автоматического распознавания речи [9].

Представление сигнала во временно-частотной области выполняется с помощью Фурье-анализа (FT view): отсчёты сигнала $X[k]$ на отдельных кадрах умножаются на оконную функцию и затем преобразуются с помощью дискретного преобразования Фурье, в результате чего получается последова-

тельность кратковременных комплексных спектров [1]:

$$\{X[k]\} \rightarrow DFT \rightarrow \{X(n,k)\}, \quad (2)$$

где k – индекс кадра; n – индекс частоты n -й полосы спектра f_n .

Последовательность отсчётов спектра $\{X(n,k)\}$ можно рассматривать как комплексный сигнал, расположенный в частотной полосе f_n и дискретизированный с частотой, соответствующей переключению кадров.

Рассмотрим спектральное представление речевого сигнала в Matlab (рис. 2). В качестве речевого сигнала использовался фрагмент речи диктора (слово «удерживать»), находящегося в нейтральном эмоциональном состоянии.

Основные биомаркеры эмоционального состояния на спектрограмме речевого сигнала свидетельствуют о том, что:

- более яркие и широкие форманты (резонансные частоты): могут указывать на более громкую речь, связанную с возбуждением, гневом или радостью (форманты формируются речевым трактом и отражают артикуляцию звуков);

- увеличение энергии на высоких частотах: может указывать на возбуждение, страх или агрессию;

- уменьшение энергии на высоких частотах: может указывать на грусть, усталость или депрессию;

- изменение длительности и четкости гласных и согласных: эмоциональ-

ное состояние может влиять на то, как человек произносит звуки (например, при гневных гласных могут быть более короткими и резкими);

– наличие «вокальных дрожаний» (вокализаций, не относящихся к речи): могут указывать на сильные эмоции, такие как плач или смех [9].




Рис. 2. Спектральное представление речевого сигнала в Matlab

Fig. 2. Spectral representation of a speech signal in Matlab

Расчет модели на основе частотно-временного вейвлет-анализа

Вейвлет-анализ, как и спектрограмма, является методом частотно-временного анализа, но использует вейвлеты вместо синусоид, как в преобразовании Фурье. Вейвлеты – это короткие колебания, локализованные во времени и частоте. Разные вейвлеты хорошо подходят для анализа разных типов сигналов [12].

Вейвлет-анализ обеспечивает лучшее разрешение по времени для высокочастотных компонентов сигнала и лучшее разрешение по частоте для низ-

кочастотных компонентов. Это позволяет более точно анализировать переходные процессы и низкочастотные характеристики речевого сигнала. Это особенно важно для анализа речевых сигналов, которые содержат как быстроизменяющиеся звуки (например, взрывные согласные), так и медленно меняющиеся звуки (например, гласные). Также существенным преимуществом вейвлет-анализа является то, что он менее чувствителен к шуму, чем традиционный Фурье-анализ [10].

Вейвлет-преобразование описывается следующей формулой [1]:

$$\Psi_{ab} = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right), \quad (3)$$

где Ψ_{ab} – функция (вейвлет) порождаемая базовым вейвлетом; $\Psi\left(\frac{t-b}{a}\right)$ – базовый вейвлет; b – сдвиг во времени; a – коэффициент масштабирования.

Выбирается базовый вейвлет, который является «материнским» вейвлетом. Существуют различные типы вейвлетов (например, вейвлет Морле или вейвлет Хаара), каждый из которых имеет свои особенности. Базовый вейвлет масштабируется (сжимается / растягивается) и сдвигается по времени, чтобы создать набор вейвлетов разного масштаба и положения.

Масштабирование позволяет анализировать сигнал в разных частот-

ных диапазонах, а сдвиг – в разных временных точках. Далее сигнал свертывается с каждым вейвлетом из набора. Результат свертки показывает степень соответствия сигнала и вейвлета в данной временной точке и частотном диапазоне. Результат вейвлет-преобразования обычно представляется в виде масштаб-граммы, которая аналогична спектрограмме, но отображает коэффициенты вейвлет-преобразования вместо спектральных амплитуд.

Вейвлет-анализ речевого сигнала в Matlab приведен ниже (рис. 3). В качестве речевого сигнала использовался фрагмент речи диктора (слово «устойчиво»), находящегося в нейтральном эмоциональном состоянии.




Рис. 3. Вейвлет-анализ (вейвлет Морле) речевого сигнала в Matlab

Fig. 3. Wavelet analysis (Morlet wavelet) of a speech signal in Matlab

Основные биомаркеры эмоционального состояния на вейвлет-масштабограмме речевого сигнала:

- общая вейвлет-энергия: изменения общей вейвлет-энергии могут быть связаны с уровнем возбуждения и общей выразительностью эмоций (более высокие значения часто соответствуют более энергичным эмоциям, таким как радость или гнев, а более низкие – грусти или спокойствию);

- вейвлет-энергия в низкочастотном диапазоне (обычно ниже 500 Гц): изменения вейвлет-энергии на низких частотах могут указывать на изменения в ритме речи, интонации и тембре голоса, которые являются важными индикаторами эмоций (например, увеличение энергии на низких частотах может быть связано с усилением напряжения или стрессом, а снижение – с подавленностью или грустью);

- вейвлет-энергия в среднечастотном диапазоне (обычно от 500 Гц до 2кГц): изменения вейвлет-энергии в среднечастотном диапазоне могут быть связаны с изменениями в форме вокального тракта, которые, в свою очередь, могут быть вызваны эмоциональным напряжением (например, при страхе или стрессе наблюдается смещение формант вверх);

- вейвлет-энергия в высокочастотном диапазоне (обычно выше 2кГц): изменения вейвлет-энергии в высокочастотном диапазоне могут быть связаны с артикуляционными усилиями и уров-

нем напряженности, что отражает эмоциональное возбуждение (например, усиление энергии на высоких частотах может наблюдаться при гневе или страхе) [10].

Анализ речевого сигнала на основе построения аттракторов

При проведении аттракторного анализа речевой сигнал рассматривается как динамическая система. При этом полагают, что речевой сигнал генерируется сложной, но детерминированной (хотя и, возможно, хаотической) системой. В результате проведения исследований требуется восстановить фазовое пространство этой системы и идентифицировать аттракторы. Аттрактор – это состояние, к которому система стремится с течением времени [13]. Форма и структура аттрактора предоставляет исследователю информацию о динамике речевого сигнала и его характеристиках [14].

Построение аттрактора речевого сигнала:

1. Исходный одномерный речевой сигнал преобразуется в многомерное фазовое пространство с использованием метода задержек (теорема Флориса Такенса о вложении с задержкой). Это означает, что создаются новые временные ряды, состоящие из значений исходного сигнала, взятых с определенной задержкой:

$$\{x(t), x(t + \tau), x(t + 2\tau), \dots, x(t + (d - 1)\tau)\}, \quad (4)$$

где τ – временная задержка (delay time); d – размерность вложения (embedding dimension). Выбор оптимальных значений τ и d является важной задачей при моделировании аттрактора [15].

2. Идентификация аттрактора: в реконструированном фазовом пространстве выполняется поиск областей, к которым траектории системы (представленные точками в фазовом пространстве) стремятся. Эти области и являются аттракторами¹.

3. Анализ характеристик аттрактора: рассчитываются различные ха-

рактеристики аттрактора, например, размерность аттрактора отражает сложность динамической системы. Фрактальная размерность хаотического аттрактора свидетельствует о наличии хаотических процессов в генерации речи [16].

Представление речевого сигнала с помощью аттрактора в Matlab приведено ниже (рис. 4).

В качестве речевого сигнала использовался фрагмент речи диктора (слово «королю»), испытывающего злость.




Рис. 4. Представление речевого сигнала с помощью аттрактора в Matlab

Fig. 4. Representation of a speech signal using an attractor in Matlab

¹ Новиков Е. Д. Система анализа психофизиологического состояния человека по паралингвистическим признакам речи на основе методов explainable AI: дис. ... канд. техн. наук. Казань, 2022. 167 с.

Биомаркеры эмоционального состояния на аттракторе речевого сигнала:

- размер и форма аттрактора: аттрактор, соответствующий спокойному состоянию, может быть меньше и более регулярным, в то время как аттрактор, соответствующий возбужденному или стрессовому состоянию, может быть больше и более хаотичным [17];

- сложность аттрактора: более сложные и нерегулярные аттракторы могут указывать на более нестабильные или интенсивные эмоции;

- фрактальная размерность аттрактора: фрактальная размерность может быть использована для количественной оценки сложности аттрактора (более высокая фрактальная размерность может указывать на более сложную динамику, связанную с определенными эмоциями) [18];

- переходы между аттракторами: анализ того, как система переходит между разными аттракторами¹, может дать информацию о переходе между разными эмоциональными состояниями [19].

Выводы

Современные исследования в области обработки сигналов открывают новые горизонты для изучения сложных явлений, и речевой сигнал человека является одним из наиболее информативных источников. Для глубокого и все-

стороннего анализа речевых данных, особенно в контексте определения психоэмоционального состояния человека, активно применяются разнообразные методы обработки сигналов.

Применение таких методов анализа речевого сигнала в Matlab, как анализ частоты основного тона, спектральный анализ, частотно-временной вейвлет-анализ и аттракторный анализ, позволяет получить разностороннюю информацию о речевом сигнале и его характеристиках.

При этом следует отметить, что каждый метод выделяет определенные аспекты сигнала, а комбинирование этих методов позволяет перейти от фрагментарного понимания к целостному анализу сигнала. Такой комплексный подход обеспечивает получение максимально полного представления о параметрах речевого сигнала.

Считаем, что наиболее информативным для первичного анализа речи, особенно с точки зрения выявления глубинных изменений, связанных с психоэмоциональным состоянием, является аттракторный анализ речевого сигнала. Этот метод позволяет выявлять тонкие, нелинейные особенности, которые могут быть упущены при использовании только традиционных частотных или временных характеристик.

Аттракторный анализ может служить мощным инструментом для первичной дифференциации состояний, после чего другие методы могут быть применены для уточнения полученных результатов.

¹ Новиков Е. Д. Система анализа психофизиологического состояния человека по паралингвистическим признакам речи на основе методов explainable AI: дис. ... канд. техн. наук. Казань, 2022. 167 с.

Список литературы

1. Bhatt S., Jain A., Dev A. Continuous Speech Recognition Technologies – A Review // Recent Developments in Acoustics. Lecture Notes in Mechanical Engineering / ed. by M. Singh, Y. Rafat. Singapore: Springer, 2021. P. 85–94. https://doi.org/10.1007/978-981-15-5776-7_8
2. Иванов А. А., Смирнова К. Д. Классификация дикторов по полу и возрасту на основе сверточных нейронных сетей и мел-частотных кепстральных коэффициентов // Искусственный интеллект и принятие решений. 2022. № 3. С. 45-56.
3. Mohammed A. A., Nagy A. Fundamental Frequency and Jitter Percent in MDVP and PRAAT // J. Voice. 2023. Vol. 37, N 4. P. 496–503.
4. Панченко А. А., Кравчук Д. А. Диагностика психофизиологического состояния человека на основе речевого сигнала // XXXV сессия Российского акустического общества: сборник трудов конференции. М.: ГЕОС, 2023. С. 112-117. <https://doi.org/10.34756/GEOS.2023.17.38436>
5. Кравчук Д. А. Ультразвуковая система контроля психофизиологического состояния машиниста поезда // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2020. Т. 10, № 1. С. 134-142.
6. Мырадов М. Т., Назарова С. Н. Современные технологии распознавания речи // Наука и мировоззрение. 2024. № 1 (23). С. 301–305.
7. Катаев М. Ю. Методика распознавания речевых команд в школьных информационных системах // Речевые технологии. 2024. № 1. С. 18–34.
8. Кравчук Д. А. Разработка метода распознавания эмоций по речевому сигналу // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 2. С. 72-80. <https://doi.org/10.21869/2223-1536-2024-14-2-72-80>
9. Петров А. С., Козлов А. В. Алгоритм оценки частоты основного тона на основе адаптивной спектральной обработки для задач биометрической идентификации // Информатика, управление и системы связи. 2023. № 1(15). С. 45-54.
10. Семенова Е. А., Иванов П. К. Акустические корреляты дисфонии у профессиональных пользователей голоса: результаты скринингового исследования с использованием мобильных приложений // Вестник оториноларингологии. 2022. Т. 87, № 3. С. 33-40.
11. Калинина М. А., Белова А. Н. Анализ параметров стабильности голоса у детей с двигательными нарушениями с использованием методов машинного обучения // Детская и подростковая реабилитация. 2021. № 4(47). С. 28-35.
12. Методы предварительной обработки речевых сигналов / В. В. Козлов, А. А. Трофимов, Е. А. Фокина, В. Н. Пономарев, Т. О. Жуков // Измерение. Монито-

ринг. Управление. Контроль. 2023. № 4. С. 43–49. <https://doi.org/10.21685/2307-5538-2023-4-5>

13. Горшков Ю. Г. Визуализация эмоциональной напряженности человека по речевому сигналу // Научная визуализация. 2023. № 2. С. 102–112.

14. Смирнов И. П., Орлова Ю. С. Применение методов реконструкции фазового пространства для анализа нелинейных динамических систем в биоакустике // Нелинейный мир. 2021. Т. 19, № 4. С. 215–225.

15. Федоров Р. А., Соколова Д. И. Классификация эмоциональных состояний по речи с использованием ансамбля признаков нелинейной динамики и глубоких нейронных сетей // Искусственный интеллект и принятие решений. 2023. № 2. С. 74–85.

16. Qin Ji. Emotional state analysis based on speech recognition signals // Highlights in Science Engineering and Technology. 2022. N 23. P. 58–64.

17. Multi-Modal Speech Emotion Recognition with Temporal-Perceptual Features and Hybrid Deep Learning Models / Y. Zhao, Z. Wang, J. Zhang, B. Schuller // IEEE Transactions on Affective Computing. 2024. Vol. 15, is. 1. P. 234–247.

18. Khan M., Kwon S. A CNN-Assisted Enhanced Audio Signal Processing for Speech Emotion Recognition // Sensors. 2020. Vol. 20, is. 1. P. 183.

19. Pepino L., Riera P., Ferrer L. Emotion Recognition from Speech Using wav2vec 2.0 Embeddings. URL: <https://arxiv.org/abs/2104.03502> (дата обращения: 17.12.2025).

References

1. Bhatt S., Jain A., Dev A. Continuous Speech Recognition Technologies – A Review. Recent Developments in Acoustics. Lecture Notes in Mechanical Engineering. Singapore: Springer; 2021. P. 85–94. https://doi.org/10.1007/978-981-15-5776-7_8

2. Ivanov A.A., Smirnova K.D. Speaker gender and age classification based on convolutional neural networks and mel-frequency cepstral coefficients. *Iskusstvenny`j intellekt i prinyatie reshenij = Artificial Intelligence and Decision Making*. 2022;(3):45–56. (In Russ.)

3. Mohammed A.A., Nagy A. Fundamental Frequency and Jitter Percent in MDVP and PRAAT. *J. Voice*. 2023;37(4):496–503.

4. Panchenko A.A., Kravchuk D.A. Diagnosis of a person's psychophysiological state based on the speech signal. In: *XXXV sessiya Rossiiskogo akusticheskogo obshchestva: sbornik trudov konferentsii = XXXV session of the Russian Acoustic Society: Proceedings of the conference*. Moscow: GEOS; 2023. P. 112–117. (In Russ.) <https://doi.org/10.34756/GEOS.2023.17.38436>

5. Kravchuk D.A. Ultrasonic system for monitoring the psychophysiological state of a train driver. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the*

Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering. 2020;10(1):134-142. (In Russ.)

6. Myradov M.T., Nazarova S.N. Modern speech recognition technologies. *Nauka i mirovozzrenie = Science and Worldview*. 2024;(1):301–305. (In Russ.)

7. Kataev M.Yu. Methodology for recognizing speech commands in school information systems. *Rechevy'e texnologii = Speech Technologies*. 2024;(1):18–34. (In Russ.)

8. Kravchuk D.A. Development of a method for emotion recognition from a speech signal. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2024;14(2):72-80. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-2-72-80>

9. Petrov A.S., Kozlov A.V. A fundamental frequency estimation algorithm based on adaptive spectral processing for biometric identification tasks. *Informatics. Informatika, upravlenie i sistemy` svyazi = Computer Science, Control and Communication Systems*. 2023;(1):45-54. (In Russ.)

10. Semenova E.A., Ivanov P.K. Acoustic correlates of dysphonia in professional voice users: results of a screening study using mobile applications. *Vestnik otorinolaringologii = Bulletin of Otolaryngology*. 2022;87(3):33-40. (In Russ.)

11. Kalinina M.A., Belova A.N. Analysis of voice stability parameters in children with motor disorders using machine learning methods. *Detskaya i podrostkovaya reabilitaciya = Children's and Adolescent Rehabilitation*. 2021;(4):28-35. (In Russ.)

12. Kozlov V.V., Trofimov A.A., Fokina E.A., Ponomarev V.N., Zhukov T.O. Methods of preliminary processing of speech signals. *Izmerenie. Monitoring. Upravlenie. Kontrol` = Measurement. Monitoring. Management. Control*. 2023;(4):43–49. (In Russ.) <https://doi.org/10.21685/2307-5538-2023-4-5>

13. Gorshkov Yu.G. Visualization of human emotional stress from a speech signal. *Nauchnaya vizualizaciya = Scientific Visualization*. 2023;(2):102-112. (In Russ.)

14. Smirnov I.P., Orlova Yu.S. Application of phase space reconstruction methods for the analysis of nonlinear dynamic systems in bioacoustics. *Nelinejny`j mir = Nonlinear World*. 2021;19(4):215-225. (In Russ.)

15. Fedorov R.A., Sokolova D.I. Classification of emotional states from speech using an ensemble of nonlinear dynamics features and deep neural networks. *Iskusstvenny`j intellekt i prinyatie reshenij = Artificial Intelligence and Decision Making*. 2023;(2):74-85. (In Russ.)

16. Qin Ji. Emotional state analysis based on speech recognition signals. *Highlights in Science Engineering and Technology*. 2022;(23):58-64.

17. Zhao Y., Wang Z., Zhang J., Schuller B. Multi-Modal Speech Emotion Recognition with Temporal-Perceptual Features and Hybrid Deep Learning Models. *IEEE Transactions on Affective Computing*. 2024;15:234-247.
18. Khan M., Kwon S. A CNN-Assisted Enhanced Audio Signal Processing for Speech Emotion Recognition. *Sensors*. 2020;20:183.
19. Pepino L., Riera P., Ferrer L. Emotion Recognition from Speech Using wav2vec 2.0 Embeddings. Available at: <https://arxiv.org/abs/2104.03502> (accessed 17.12.2025).

Информация об авторах / Information about the Authors

Кравчук Денис Александрович, доктор технических наук, профессор, Институт нанотехнологий, электроники и приборостроения, Южный федеральный университет, г. Таганрог, Российская Федерация, e-mail: kravchukda@sfedu.ru, ORCID: 0000-0002-4220-3928

Denis A. Kravchuk, Doctor of Sciences (Engineering), Professor, Institute of Nanotechnology, Electronics and Instrumentation, Southern Federal University, Taganrog, Russian Federation, e-mail: kravchukda@sfedu.ru, ORCID: 0000-0002-4220-3928

Котенко Александр Сергеевич, студент, Институт нанотехнологий, электроники и приборостроения, Южный федеральный университет, г. Таганрог, Российская Федерация, e-mail: akotenko@sfedu.ru

Alexander S. Kotenko, Student, Institute of Nanotechnology, Electronics and Instrumentation, Southern Federal University, Taganrog, Russian Federation, e-mail: akotenko@sfedu.ru

Биотехническая система реабилитации пациентов с нарушением двигательных функций нижних конечностей с адаптивными режимами управления экзоскелетом

Е. В. Петрунина¹ ✉

¹ Московский политехнический университет
ул. Большая Семёновская, д. 38, г. Москва 107023, Российская Федерация

✉ e-mail: isu@mospolytech.ru

Резюме

Цель исследования. В настоящее время получили широкое распространение робототехнические системы реабилитации больных с нарушением двигательных функций. При этом основной тенденцией является исключение из процесса оператора экзоскелета и передача функций управления реабилитацией программному обеспечению. Однако имеющиеся в настоящее время программно-алгоритмические средства управления экзоскелетом не позволяют в должной мере синхронизировать «намерения движения» пациента с ассистирующими возможностями экзоскелета, что приводит к снижению эффективности реабилитации. Целью исследования является повышение эффективности реабилитации посредством адаптации режимов управления экзоскелетом к психофизиологическому и физическому состоянию пациента.

Методы. Для реабилитации постинсультных больных с нарушенной двигательной активностью нижних конечностей предложена биотехническая система, позволяющая посредством дешифраторов реальных и воображаемых движений, построенных на анализе электроэнцефалографических сигналов и электромиографических сигналов, управлять режимами реабилитации, определяемыми текущим функциональным состоянием пациента. Предложен метод формирования маркера «Намерения движения», основанный на комплексном анализе трех электрофизиологических сигналов, формируемых в качестве реакции на стимул, включенный в биологическую обратную связь, и позволяющий синхронизировать управление экзоскелетом с воображаемыми и реальными сокращениями мышц пациента посредством биотехнических и биологических обратных связей.

Результаты. Проведена оценка эффективности использования персонализированного метода реабилитации на экспериментальной и контрольной группе. В качестве оценки эффективности реабилитации выбран шкала баланса Берга. Статистический анализ динамики баллов в экспериментальной и контрольной группах, выполненный по результатам курса реабилитации, показал, что динамики баллов по шкале Берга имеют достаточно высокое статистическое различие при сравнении двух групп исследования.

Заключение. Полученные в результате исследования данные демонстрируют эффективность использования персонализированной биотехнической системы для восстановления двигательных функций нижних конечностей у пациентов, перенесших ишемический инсульт.

Ключевые слова: экзоскелет; биотехническая система; реабилитация постинсультных больных; алгоритм; моторный и электродермальный ответы; маркер «намерение движения».

Конфликт интересов: Автор декларирует отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Петрунина Е. В. Биотехническая система реабилитации пациентов с нарушением двигательных функций нижних конечностей с адаптивными режимами управления экзоскелетом // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 107–131. <https://doi.org/10.21869/2223-1536-2026-16-1-107-131>

Поступила в редакцию 16.01.2026

Подписана в печать 14.02.2026

Опубликована 31.03.2026

A biotechnical system for the rehabilitation of patients with lower limb motor impairments using adaptive exoskeleton control modes

Elena V. Petrunina¹ ✉

¹ Moscow Polytechnic University

38 Bolshaya Semyonovskaya Str., Moscow 107023, Russian Federation

✉ e-mail: isu@mospolytech.ru

Abstract

Purpose of research. Robotic rehabilitation systems for patients with motor impairments are currently widely used. The main trend is to eliminate the exoskeleton operator from the process and transfer rehabilitation control functions to software. However, currently available exoskeleton control software and algorithms do not adequately synchronize the patient's "movement intentions" with the exoskeleton's assistive capabilities, resulting in reduced rehabilitation effectiveness. The aim of the study is to improve rehabilitation effectiveness by adapting exoskeleton control modes to the patient's psychophysiological and physical condition.

Methods. A biotechnical system has been proposed for the rehabilitation of post-stroke patients with impaired lower extremity motor function. This system, using decoders of real and imagined movements based on the analysis of electroencephalographic and electromyographic signals, controls rehabilitation modes determined by the patient's current functional state. A method for generating a "Movement Intention" marker is proposed. This method is based on a comprehensive analysis of three electrophysiological signals generated in response to a stimulus included in the biofeedback system. This method allows for synchronizing exoskeleton control with the patient's imagined and real muscle contractions through biotechnical and biological feedback.

Results. The effectiveness of the personalized rehabilitation method was assessed in the experimental and control groups. The Berg Balance Scale was used to assess rehabilitation effectiveness. Statistical analysis of score changes in the experimental and control groups, based on the rehabilitation course, showed that the change in scores on the Berg Balance Scale exhibited a significant statistical difference when comparing the two study groups.

Conclusion. The data obtained from the study demonstrate the effectiveness of using a personalized biotechnical system for restoring lower limb motor function in patients who have suffered an ischemic stroke.

Keywords: exoskeleton; biotechnical system; rehabilitation of post-stroke patients; algorithm; motor and electrodermal responses; "movement intention" marker.

Conflict of interest: The Author declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Petrunina E.V. Biotechnical system for the rehabilitation of patients with lower limb motor impairments using adapted exoskeleton control modes. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State Univer-*

Введение

В последние годы в системах реабилитации получили широкое распространение экзоскелеты – устройства, предназначенные для расширения функциональных возможностей человека за счёт внешнего каркаса. С помощью экзоскелета решаются задачи расширения функциональных возможностей больных с нарушением опорно-двигательного аппарата. Одним из способов реабилитации является вертикализация с помощью экзоскелета, т. е. переход из положения сидя в положение стоя. Однако отсутствие возможности адаптации экзоскелета к конкретному пациенту [1] не позволяет отказаться от услуг оператора экзоскелета при реабилитации пациентов с паретическими нижними конечностями [2].

Управление экзоскелетом в процессе вертикализации осуществляется бортовым контроллером. Для программирования контроллера в его памяти должны храниться динамические ряды, являющиеся временной последовательностью отсчетов углов наклона звеньев экзоскелета. В данном случае интерес представляют углы φ_1 , φ_2 , φ_3 , соответствующие шарнирам стопы, колени и бедра, как показано на кинематической схеме экзоскелета (рис. 1).

В рамках эксперимента в [3] исследовалась вертикализация человека в

процессе «встал – сел». В результате было получено множество трех векторов – абсолютных углов наклона звеньев $\{\bar{\varphi}_1, \bar{\varphi}_2, \bar{\varphi}_3\}$. Для измерения углов использовались акселерометры, потенциометры и обработка видеозаписи эксперимента, сайты видеозаписи которого представлены ниже (рис. 2).

Эксперименты позволили найти зависимости углов во времени и в дальнейшем использовать их как задающие воздействия в системе нейрорегуляции.

Однако, несмотря на возможность управлять скоростью проведения процедуры «встать – сесть» с помощью контроллера, отношение специалистов к эффективности такого способа реабилитации весьма неоднозначно. Это обусловлено тем, что скорость подъема-опускания пациента экзоскелетом должна определяться его функциональным состоянием (ФС), в основном ФС сердечно-сосудистой системы (ССС) и мышц (мышечной усталостью), участвующих в выполнении процедуры реабилитации. Следовательно, ассистирующая функция экзоскелета должна зависеть от этих показателей.

Поэтому более естественным и интуитивно понятным способом взаимодействия с экзоскелетами и другими нейрорепротезами является использование эндогенных сигналов мозга. Этот подход реализуется с помощью систем

интерфейса «мозг – машина» (ИММ) [4]. Таким образом, он позволяет полностью контролировать движения. Типичным примером такого ИММ является система, основанная на сенсомоторных ритмах, таких как воображаемое движение (ВД) [4]. Специалисты полагают,

что движение нижних конечностей [5], сопровождающееся активацией соответствующих двигательных зон коры головного мозга посредством ВД, может ускорить реабилитацию пациентов [6] за счет стимуляции нейронной пластичности [7].




Рис. 1. Кинематическая схема экзоскелета: 1 – голень; 2 – бедро; 3 – позвоночник; 4 – стопа; а – начальное состояние вертикализации; б – промежуточное состояние вертикализации; в – конечное состояние вертикализации

Fig. 1. Kinematic scheme of the exoskeleton: 1 – lower leg; 2 – thigh; 3 – spine; 4 – foot; а – initial state of verticalization; б – intermediate state of verticalization; в – final state of verticalization



Рис. 2. Видеоряд снимков человека в процессе вставания [3]

Fig. 2. A sequence of images of a person standing up [3]

Для формирования ВД необходимо организовать биологическую обратную связь (БОС) между источником, стимулирующим ВД, и пациентом. Для реализации такой БОС используют дешифратор паттернов ЭЭГ, соответствующих моментам «намерения движения». Однако дешифрация ЭЭГ считается сложной задачей [1], и как следствие, для этих целей используется большое количество электродов и длительная эпоха ЭЭГ для классификации [4].

Для повышения надежности системы управления экзоскелетом посредством ВД в режиме реального времени ИММ может быть дополнен сигналами других модальностей, в частности электромиографической (ЭМГ) регистрацией мышечной активности нижних конечностей [8]. Это позволяет повысить безопасность системы «пациент – экзоскелет» и увеличить степень свободы вспомогательных устройств. Для пациентов с полной инвалидностью или находящихся на ранних этапах реабилитационной терапии со слабой мышечной активностью для адаптивной реабилитации необходимо распознавать намерение пользователя на движение путем регистрации двигательных сигналов ЭЭГ и, следовательно, обеспечивать обратную связь после выполнения соответствующего движения экзоскелетом.

При выполнении процедуры реабилитации необходим мониторинг состояния тонуса мышц, на которые приходится тестовая нагрузка. От этого зависит не только интенсивность тестовой

нагрузки, но и значение ассистирующего момента на соответствующие серводвигатели экзоскелета. Большинство способов измерения тонуса мышц или мышечной усталости в режиме онлайн связаны с анализом ЭМГ. Поэтому необходимо вовлекать мышечную активность (остаточную или возникающую в процессе реабилитации) в контур управления для формирования правильных стереотипов движений конечностей¹. Таким образом, для реабилитационных экзоскелетов с ИММ к основным проблемам, требующим решения, относятся точность определения моментов намерения движения и производительность системы управления при интеграции ИММ в систему управления экзоскелетом.

При выполнении процедуры «встать – сесть» основной проблемой, которую надо решить, является адаптация экзогенных воздействий на пациента к его априорному ФС и текущему ФС, а также локальной эффективности реабилитации, которая может быть определена на основании динамики ФС, определяемой в процессе выполнения

¹ Пат. 2839398 Российская Федерация. Способ классификации мышечной усталости на основе анализа вейвлет-преобразования сегментов двигательной активности электромиосигнала / Филист С. А., Пшеничный А. Е., Петрунина Е. В., Ермаков Д. А., Кузьмин А. А.; заявитель и патентообладатель Федеральное государственное бюджетное образовательное учреждение высшего образования «Юго-Западный государственный университет». № 2024131858; заявл. 23.10.24; опубл. 30.04.25.

реабилитационной процедуры. Решение этой проблемы требует формирования интегрального точечного показателя ФС, а также при слабой мышечной активности включение в реабилитационную процедуру виртуальной реальности (VR) с реализацией БОС на основе динамики показателя ФС.

Материалы и методы

Система управления экзоскелетом

Учитывая вышесказанное, структурная схема биотехнической системы (БТС) в режиме «встать – сесть» может быть представлена в виде, показанном ниже (рис. 3).




Рис. 3. Структурная схема биотехнической системы с экзоскелетом

Fig. 3. Structural diagram of a biotechnical system with an exoskeleton

Основная задача такой структуры – синхронизировать систему управления экзоскелета с ФС пациента. ФС пациента может быть представлено в виде двух сегментов. Первый сегмент определяет общее состояния здоровья пациента, и полагаем, что в данном случае ФС пациента в этом сегменте определяется ФС сердечно-сосудистой системы (ССС) пациента, контроль которой осуществляет блок определения ФС СССР пациента. Второй сегмент учитывает ФС моторной системы пациента. Одной из важнейших задач определения ФС этого сегмента является определение момента «намерения движения». При определении метки «намерения движения» персональный компьютер (ПК) начнет анализировать моторные сигналы ЭЭГ и ЭМГ с целью синхронизации ассистирующего экзогенного воздействия экзоскелета с состоянием моторной системы пациента.

Для более точного фиксирования этого момента в системе управления экзоскелетом используются стимулирующие команды пациенту, поступающие на терминальный модуль. Известно множество методов стимулирования двигательных функций в системе реабилитации пациента с парезом нижних конечностей¹. Наиболее

распространенной и простой схемой формирования стимулирующих команд является схема из трех транспарантов. Они могут предъявляться пациенту в виде параллельной или последовательной схем. При параллельной схеме на экране монитора формируются три окна, за действиями в которых предлагается следить пациенту. При последовательной схеме эти окна представляются на одном терминале, но разнесенными в пространстве и во времени. В первом окне возникает сигнал (звуковой или в виде оптической символике), который сообщает пациенту о предстоящем движении. Этот сигнал заставляет пациента сосредоточить внимание на втором окне, в котором пациенту показывается пример или дается команда на выполнение планового движения.

Учитывая ФС СССР пациента, ПК формирует соответствующие стимулы во втором терминальном окне. Во втором окне могут быть представлены изображения от простейших мнемосхем до сложных сцен в виде клипов виртуальной реальности (VR). На рисунке 4 представлен терминал в виде трех табло, на первом из которых по-

¹ Пат. 2830938 Российская Федерация, МПК G 16 H 20/00 (2018.01), A 61 B 5/05 (2006.01), G 06 T 15/00 (2011.01). Способ реабилитации пациентов с нарушением двигательной активности с использованием персонализированного контента клипов виртуаль-

ной реальности / Филист С. А., Пшеничный А. Е., Шаталова О. В., Сафронов Р. И., Петрунина Е. В., Ермаков Д. А.; заявитель и патентообладатель Федеральное государственное бюджетное образовательное учреждение высшего образования «Юго-Западный государственный университет». № 2024105789; заявл. 06.03.24; опубл. 26.11.14, Бюл. № 33.

ступает сигнал «Внимание», на втором – отображается сигнал двигательной активности, а на третье – сигналы

БОС, отображающие степень реакции моторных систем пациента на эти стимулы.



Рис. 4. Терминальный модуль пациента

Fig. 4. Patient terminal module

Лицо, принимающее решение (ЛПР) в зависимости от ФС ССС пациента, задает начальные параметры интенсивности процедуры «встать – сесть», которая определяется скоростью поступления отсчетов углов из контроллера приводов на серводвигатели соответствующих шарниров. Для реализации отрицательной обратной связи, позволяющей управлять углами наклона кинематических звеньев экзоскелета, используют узел измерения углов в шарнирах правого колена ОПК, левого колена ОЛК, правого бедра ОПБ и левого бедра ОЛК.

Сигналы ЭЭГ регистрировались в узле измерения ЭЭГ с помощью сертифицированного усилителя. Для регистрации ЭЭГ использовалось семь элект-

родов (C5, C3, C1, C2, C4, C6), расположенных по международной схеме «10-10%» (рис. 5). Референтный электрод располагался на мочке уха (A1 и A2). Заземляющий электрод располагался на лбу (AFZ). Частота дискретизации сигнала составляла 500 Гц. Контроль контакта под электродами осуществлялся автоматически.

Узел регистрации ЭМГ-сигнала позволяет контролировать тонус тех мышц, которые непосредственно поддерживают тестовое движение. Контроль ЭМГ позволяет как организовать биотехническую обратную связь (БОС) и таким образом осуществлять синхронизацию моментов на серводвигателях с тестовым движением, так и контролировать мышечную усталость

мышц-синергистов¹. На рисунке 6 показано расположение электродов ЭМГ на пациенте [9] в соответствии с рекомендациями проекта SENIAM (поверхностная ЭМГ для неинвазивной оценки мышечной проекции).

Для каждого канала ЭМГ использовалось два электрода с одним общим заземляющим электродом для всех каналов. Для каждой ноги использовались четыре канала ЭМГ, регистрирующие ЭМГ мышцы, напрягающей подвздошно-поясничную мышцу, большую ягодичную мышцу, четырехглавую мышцу бедра и седалищно-бедренную мышцу.

ПК анализирует предварительно обработанные данные для распознавания намерения движения. После прогнозирования намерения движения си-

стема управления отправляет соответствующую команду экзоскелету, который в конечном итоге выполняет целевое движение. Схема системы управления экзоскелетом на базе ИММ представлена на рисунке 7, а.

Дешифратор паттернов ЭЭГ дешифрирует виртуальные или реальные движения пациента и посредством результатов дешифрации контроллер серводвигателей (СД) экзоскелета перемещает звенья экзоскелета в соответствующее положение. Пример реализации дешифратора моторных сигналов ЭЭГ приведен в [11].

На рисунке 7, б представлена схема управления экзоскелетом при выполнении пациентом реальных движений. В этом случае осуществляется дешифрация паттернов ЭМГ. Учитывая, что здесь экзоскелет работает в ассистирующем режиме, в схему управления введен модуль оценки мышечной усталости, и на основании ее оценки контроллер СД формирует соответствующие моменты на звеньях экзоскелета. Пример реализации дешифратора моторных сигналов ЭЭГ приведен в [12].

Алгоритм управления процессом реабилитации

Интеграция ЭМГ в систему управления экзоскелетом нижних конечностей, основанную на анализе ЭЭГ, позволяет осуществить адаптацию БТС к долгосрочной динамике (эволюции) мышечной активности пациента в процессе реабилитации. Для пациентов на ранних этапах реабилитационной терапии со слабой мышечной активностью

¹ Пат. 2839398 Российская Федерация. Способ классификации мышечной усталости на основе анализа вейвлет-преобразования сегментов двигательной активности электромиосигнала / Филист С. А., Пшеничный А. Е., Петрунина Е. В., Ермаков Д. А., Кузьмин А. А.; заявитель и патентообладатель Федеральное государственное бюджетное образовательное учреждение высшего образования «Юго-Западный государственный университет». № 2024131858; заявл. 23.10.24; опубл. 30.04.25; Пат. 2766764 Российская Федерация. Способ оценки мышечной усталости на основе контроля паттернов синергии и устройство для его осуществления / Филист С. А., Трифонов А. А., Кузьмин А. А., Петрунина Е. В., Сафронов Р. И.; заявитель и патентообладатель Федеральное государственное бюджетное образовательное учреждение высшего образования «Юго-Западный государственный университет». № 2021105609; заявл. 04.03.21; опубл. 15.03.22.




Рис. 7. Структурные схемы управления экзоскелетом

Fig. 7. Structural diagrams of exoskeleton control

Основной задачей БТС является вовлечение мышечной активности (остаточной или возникающей в процессе реабилитации) в контур управления экзоскелетом. Например, при недостаточной активности локальной части двигательной коры головного мозга необходимо восстановить активность всей двигательной цепи (соматосенсорной коры, первичной и вторичной двигательной коры, мотонейронов спинного мозга) для полноценной реабилитации двигательных функций.

Формирование моментов на звеньях экзоскелета зависит от ФС пациента. В

данном случае по ФС будем понимать систему генерации электрофизиологических сигналов, осуществляющих управление паретичными конечностями пациента, т. е. конечностями, у которых снижена мышечная сила (парез) из-за поражения нервной системы. Реабилитация паретичной конечности может быть осуществлена в четырех режимах, в зависимости от которых ПК выбирает программу реабилитации. Выбор режима реабилитации осуществляется в соответствии с алгоритмом, схема которого представлена ниже (рис. 8).




Рис. 8. Схема алгоритма выбора режима реабилитации

Fig. 8. Diagram of the algorithm for selecting the rehabilitation mode

Индикаторами реакции пациента на информацию на терминале (см. рис. 8) является сигнал электродермального ответа (ЭДО) [13]. В блоке 1 осуществляется его анализ. Как показано в [13], сигнал ЭДО имеет высокую корреляцию с активностью головного мозга, вызванной соответствующими стимулами, но не требует дешифрации, хотя и нуждается в тщательном измерении. Но при оценке реакции пациента на стимул

«намерение движения» достаточно только зафиксировать изменение этого сигнала выше порогового значения в окне, наблюдаемом на терминале (см. рис. 8) после активации стимула.

На рисунке 9 представлена иллюстрация процедуры реабилитации «встать – сесть» в экзоскелете. Задача БТС состоит в том, чтобы синхронизировать стимулирующие воздействия VR с реакцией ФС пациента.




Рис. 9. Иллюстрация процедуры «встать – сесть» в экзоскелете: а – подъем; б – пауза – вертикальное положение; в – опускание

Fig. 9. Illustration of the "stand-sit" procedure in an exoskeleton: а – standing up; б – pause – upright position; в – sitting down

Если ЭДО не будет зафиксирован, то считается, что в данном ФС пациент не способен к воображаемому движению и управление процессом реабилитации осуществляется в «ручном» режиме – это режим 4 (блок 1). В этом режиме оператор экзоскелета сам задает программу реабилитации на основе визуального и/или вербального контакта с пациентом и сам осуществляет оценку влияния экзогенных факторов на ФС пациента.

Если в блоке 2 будет подтверждение наличия ЭДО, то компьютер приступает к анализу ЭЭГ в блоке 3 и анализу ЭМГ в блоке 4, которые могут осуществляться параллельно. Если блок 5 подтвердит, что ЭЭГ расшифрован в блоке 3, то в блоке 6 осуществляется проверка, расшифрован ли сигнал ЭМГ, т. е., другими словами, присутствует ли ЭМГ на тех мышцах, которые вовлечены в тестовые движения конечностей.

Если ЭМГ расшифрован, то реабилитация осуществляется в режиме 1 (блок 7), который предусматривает работу экзоскелета в качестве ассистента с мониторингом соответствующих мышечных усилий и мышечной усталости. В этом режиме оператор экзоскелета только осуществляет вторичный контроль ФС пациента и страховку перемещения пациента в фазах «встать» и «сесть» и в режиме «пауза», когда пациент занимает вертикальное положение.

Если же ЭМГ не расшифрован, то управление экзоскелетом осуществляется в соответствии с сигналами, поступающими от дешифратора ЭЭГ, что соответствует режиму 2 (блок 8). В этом режиме интенсивность процедуры определяется оператором экзоскелета в соответствии с сигналами дешифрации ЭЭГ.

Если блок 5 подтверждает, что ЭЭГ не расшифрован, то анализируется присутствие ЭМГ на мышцах паретичных конечностей (блок 9). Здесь надо учитывать, что отсутствие в дешифрованной ЭЭГ маркера «намерение движения» не исключает наличие сигналов ЭМГ на соответствующих отведениях. В случае, если сигнал ЭЭГ присутствует, экзоскелет переходит на управление в режиме 3 (блок 10), цель которого – синхронизировать движение звеньев экзоскелета с ЭМГ на соответствующих мышцах пациента.

Если в блоке 9 получен отрицательный результат, то управление экзоскелетом, а следовательно, и процедурой реабилитации переходит к опера-

тору экзоскелета, т. е. на режим 4, который задает параметры управления в «ручном» режиме (блок 11).

Метод выделения маркера «намерение движения»

Исследования в когнитивной двигательной реабилитации показывают, что пассивное наблюдение, воображение и физическое исполнение одного и того же движения (или моторного действия) вызывают очень похожие церебральные активации. Метаанализ, выполненный в [14], подтвердил гипотезу о функциональной эквивалентности наблюдения, воображения и физического выполнения одних и тех же действий. Однако воображение двигательной активности – нетипичная для человека задача, поэтому в этом случае мозг не формирует устойчивый схема-образ, связанный с этим движением. Подобная проблема актуальна не только для биотехнических систем реабилитационного типа, но и применительно к разработке ИММ.

При выполнении программы реабилитации пациент мысленно выполняет заданные на втором транспаранте (см. рис. 4) движения и посредством БОС оценивает свои успехи в выполнении этого тренинга, выводимые на третий транспарант (см. рис. 4). На первом транспаранте появляется сигнал стимула начала движения («намерение движения»). Используя БТОС программные модули в ПК оценивают функциональные возможности пациента к выполнению процедуры реабилитации.

Это весьма сложная процедура, так как реакция на экзогенное воздействие, поступающее с первого транспаранта, определяется не только физиологическим состоянием пациента, но и его способностями к выполнению ВД. Во время мысленного выполнения движений на периферическом уровне могут быть зарегистрированы моторные (соматические) и вегетативные ответы: ЭМГ, кардиореспираторный и ЭДО [15].

Таким образом, маркер, характеризующий состояние пациента «намерение движения», может быть получен посредством двух измерительных блоков: «Узел измерения электродермаль-

ного ответа» и «Узел измерения ЭМГ» (см. рис. 3). Если это состояние будет распознано, то ПК приступает к дешифрации сигнала ЭЭГ и анализу сигнала ЭМГ, позволяющих предоставить информацию контроллеру приводов для управления движением звеньев экзоскелета.

На рисунке 10 представлена структурная схема формирования маркера «намерение движения». Начало поиска маркера в паттернах электрофизиологических сигналов начинают после поступления на первый терминал сигнала «Внимание». Маркер определяется на основе анализа реакции на стимул в форме величины ЭМГ и ЭДО [16].




Рис. 10. Структурная схема формирования маркера «Намерение движения»

Fig. 10. Structural diagram of the formation of the "Intention to Move" marker

Так как связь между ЭМГ-активностью и качеством ВД достаточно слаба [13], то вместо него используем сигнал RMS, эпюра которого представлена на рисунке 11, а, определяемый по формуле

$$RMS_m = 1 + \sqrt{\frac{1}{n} \sum_{k=m-n}^m \text{ЭМГ}_k^2}, \quad (1)$$

где n – число дискретных отсчетов ЭМГ_{*k*}, которые накапливаются микроконтроллером узла измерения ЭМГ, до текущего отсчета m ЭМГ.




Рис. 11. Эпюры сигналов моторного и электродермального ответов пациента

Fig. 11. Waveforms of the patient's motor and electrodermal responses

На рисунке 11, б представлена эпюра сигнала ЭДО. Длительность этого ответа на стимул коррелирует с «яркостью» воображаемого движения у здоровых людей [13].

Исследования, представленные в [17], позволяют определить критерий наличия маркера в виде корреляционной функции двух сигналов по формуле

$$R = \frac{1}{2\alpha \cdot RMS_{n1} \cdot \overline{\mathcal{E}DO}_{n2}} \times \sum_{i=n1-\alpha}^{n1+\alpha} \sum_{j=n2-\alpha}^{n2+\alpha} RMS_i \cdot \overline{\mathcal{E}DO}_j, \quad (2)$$

где RMS_i – отсчеты сигнала моторного ответа; $\overline{\mathcal{E}DO}_j = |\mathcal{E}DO'_j|$; $\mathcal{E}DO'_j$ – отсчеты сигнала ЭДО, пропущенного через фильтр верхних частот; $n1 = \arg \max_{i=1 \dots N} RMS_i$;

$n2 = \arg \max_{j=1 \dots N} \overline{\mathcal{E}DO}_j$; N – число отсчетов

в моторном и электродермальном сиг-

налах; $\alpha = \frac{\beta}{\Delta}$; Δ – шаг дискретизации сигналов; β – настраиваемый параметр (2...6 с), определяемый длительностью ЭДО пациента для каждого стимула [17].

Результаты и их обсуждение

Для оценки клинической эффективности восстановительной реабилитации посредством предложенного метода реабилитации у больных с парезом нижних конечностей (НК) были проведены экспериментальные исследования. Цель эксперимента – оценить эффективность использования БТС пациентами и выяснить положительное влияние представленной БТС на возможное улучшение ФС пациентов с нарушением двигательных функций НК.

Исследование проводилось в соответствии с Международным стандартом качества научных исследований (Good

Clinical Practice). Все пациенты, участвующие в эксперименте, подписали информированное согласие. Экспериментальные исследования проводились в медицинском центре Юго-Западного государственного университета г. Курска с декабря 2023 г. по январь 2024 г. Экспериментальные исследования одобрены локальным этическим комитетом Юго-Западного государственного университета.

Для проведения эксперимента были сформированы экспериментальная группа и контрольная группа сравнения, в которые вошли по двадцать пациентов. Группы были сопоставимы по возрасту и полу. Критерия включения и не включения пациента в исследование соответствовали рекомендациям, приведенным в [8].

Рассмотрим клинико-демографические характеристики пациентов экспериментальной и контрольной групп (табл. 1).

Сравниваемые группы однородны по демографическим показателям, а также по степени выраженности неврологического дефицита на момент включения в исследование. Продолжительность курса составляла 12 недель. В неделю для каждого пациента проводилось от одного до трех сеансов реабилитации с продолжительностью сеанса в 15 минут. Пациенты группы сравнения получали только стандартную реабилитационную помощь без включения БТС в контур «пациент – оператор». С пациентами экспериментальной группы реабилитация проводилась с использованием БТС. В течение всего курса реабилитации в экспериментальной и контрольной группах проводилась оценка неврологического статуса по двигательной шкале баланса Берга (BBS), что обусловлено ее высокой чувствительностью [19]. Анализ данных выполняли с использованием программного обеспечения Excel 2013.

Таблица 1. Клинико-демографические характеристики пациентов экспериментальной и контрольной групп

Table 1. Clinical and demographic characteristics of patients in the experimental and control groups

Характеристики пациентов	Группа	
	экспериментальная	контрольная
Количество пациентов после ишемического инсульта	20	20
Мужчины / женщины	12/8	11/9
Средний возраст в группе (min-max) лет	61 (38-65)	64 (45-65)
Медиана давности, месяцы	4 [3;6]	4 [3;6]
Шкала BBS, баллы	18 [14;23]	17 [10;27]
Локализация очага – левое / правое полушарие, человек	13/7	11/9

В процессе эксперимента на монитор пациента последовательно подавались команды «Внимание», «Встать», «Сесть», а также результаты дешифрации этих команд. Длительность команды составляла 4 с, межстимульный интервалом был равен 10 с. На монитор оператора поступали рекомендательные команды, содержание которых зависело от выбранного компьютером режима. В процессе процедуры реабилитации классификатор БТС анализировал каждые 500 мс ЭЭГ, ЭМГ, ЭДО, а результаты распознавания ментальной задачи демонстрировались оператору на дисплее на спине пациента, а пациенту – на дисплее (см. рис. 8), установленном перед пациентом. Таким образом, была реализована БОС (визуальная обратная связь) как между стимулирующей программой и пациентом, так и между пациентом и оператором. При этом на дисплей оператора выводился режим, в котором БТС рекомендовала осуществлять реабилитацию, а также начала соответствующих фаз выполнения процедуры «встать – сесть». На терминал пациента выводился факт успешности соответствия поданной команды на терминал пациента и ее расшифровки компьютерным приложением.

Одной из основных задач процедуры реабилитации является синхронизация команд, поступающих пациенту, и их восприятие центральной нервной системой пациента в виде ответной реакции на поступающие стимулы. Реакция на стимул «внимание» наблюдалась в

виде маркера «намерение движения», который определялся на апертуре 4 с после маркера начала стимула. На рисунке 12 показана диаграмма успешности и не успешности формирования маркера «намерение движения» при выполнении процедуры «встать – сесть» в экспериментальной группе в ответ на стимул «внимание». Анализ этой диаграммы показывает, что по мере накопления сеансов реабилитации процент успешности реакции на стимул «внимание» растет, что объясняется накоплением у пациентов навыков общения с терминалом пациента и определенной роли в этом БОС.

На рисунке 13 представлена диаграмма соотношений режимов реабилитации в экспериментальной группе на апертуре курса реабилитации с шагом в одну неделю. Она отражает динамику соотношения режимов на протяжении курса реабилитации. Отметим, что желтые столбики на диаграмме, соответствующие режиму 4, практически повторяют зеленые столбики на диаграмме рисунок 13, которые соответствуют неудаче при идентификации команды «внимание».

На рисунке 14 представлено соотношение показателей шкалы баланса Берга до и после реабилитации в экспериментальной и контрольной группах. На рисунке 15 представлена иллюстрация динамики шкалы Берга.

В качестве статистических методов оценки выборок на предмет их однородности использовался t -критерий

Стьюдента и критерий Вилкоксона-Манна-Уитни. Для проверки нормальности выборок использовался критерий Шапиро-Уилка. В течение четырех недель реабилитации статистически значимых различий между экспериментальной и контрольной группами не

наблюдалось. Достоверные статистические различия в экспериментальной и контрольных группах возникли уже к началу пятой недели ($p = 0,03$) (рис. 15). В дальнейшем положительный вектор изменений сохранялся до конца курса реабилитации.




Рис. 12. Диаграмма успешности реакции на стимул «внимание» в экспериментальной группе

Fig. 12. Diagram showing the success rate of responses to the 'attention' stimulus in the experimental group




Рис. 13. Диаграмма динамики соотношения режимов реабилитации в экспериментальной группе

Fig. 13. Diagram showing the dynamics of the ratio of rehabilitation modes in the experimental group




Рис. 14. Показатели шкалы Берга до и после реабилитации в экспериментальной и контрольной группах

Fig. 14. Berg Scale scores before and after rehabilitation in the experimental and control groups




Рис. 15. Динамика показателей шкалы Берга по неделям курса реабилитации в экспериментальной и контрольной группах

Fig. 15. Dynamics of Berg scale indicators by week of rehabilitation course in the experimental and control groups

Выводы

Полученные в результате исследования данные демонстрируют эффективность использования персонифицированной БТС для восстановления двигательных функций нижних конечностей у пациентов, перенесших ишемический инсульт. Дальнейшим развитием персонифицированных БТС реабилитационного типа будет совершенствование систем машинного обучения для классификаторов моторных электрофизиологических сигналов, позволяющих синхронизировать ассистирующую помощь экзоскелета с намерениями движения пациента. Направление развития таких систем должно быть направлено как на повышение показателей точности классификации моторных сигналов, так и на повышение скорости реакции системы управления экзоскелетом на экзогенные стимулы и эндогенные реакции. Первым этапом развития этого процесса должно является успешность реакции системы управления экзоскелетом на стимулы виртуальной реальности, поступающие на органы чувств пациента.

1. Предложена биотехническая система реабилитации больных с нарушенной двигательной активностью нижних конечностей, позволяющая посредством дешифраторов реальных и воображаемых движений, построенных на анализе электроэнцефалографиче-

ских сигналов и электромиографических сигналов, управлять режимами реабилитации, определяемыми текущим функциональным состоянием пациента.

2. Предложен метод формирования маркера «Намерения движения», основанный на комплексном анализе трех электрофизиологических сигналов, формируемых в качестве реакции на стимул, включенный в биологическую обратную связь, и позволяющий синхронизировать управление экзоскелетом с воображаемыми и реальными сокращениями мышц пациента посредством биотехнических и биологических обратных связей.

3. Проведена оценка эффективности использования персонифицированного метода реабилитации на экспериментальной и контрольной группе. В качестве оценки эффективности реабилитации выбрана шкала баланса Берга. Статистический анализ динамики баллов в экспериментальной и контрольной группах, выполненный по результатам курса реабилитации, показал, что динамика балла по шкале Берга имеет достаточно высокое статистическое различие при сравнении двух групп исследования: 22 балла в экспериментальной группе против 12 баллов в контрольной группе при 95-процентных доверительных интервалах [12;27] и [12;27], соответственно ($p < 0,05$).

Список литературы

1. Кодовые образы сигналов электроэнцефалограммы для управления робототехническими устройствами посредством интерфейса мозг – компьютер / С. А. Филист,

Е. В. Петрунина, А. А. Трифонов, А. В. Серебровский // Моделирование, оптимизация и информационные технологии. Научный журнал. 2019. Т. 7, № 1. С. 67-79. <https://doi.org/10.26102/2310-6018/2019.24.1.025>

2. Двухуровневая нейросетевая модель дешифратора электромиосигнала в системе управления вертикализацией экзоскелета / А. А. Трифонов, С. А. Филист, А. А. Кузьмин, В. В. Жилин, Е. В. Петрунина // Прикаспийский журнал: управление и высокие технологии. 2020. № 4 (52). С. 99-111.

3. Яцун А. С., Савин С. И., Турлапов Р. Н. Адаптивная система управления экзоскелета, осуществляющая вертикализацию человека // Известия Юго-Западного государственного университета. 2015. № 3. С. 26-32.

4. Real-Time EEG_EMG Human_Machine Interface-Based Control System for a Lower-Limb Exoskeleton / S. Yu. Gordleeva, S. A. Lobov, N. A. Grigorev, A. O. Savosenkov, M. O. Shamshin, M. V. Lukoyanov, M. A. Khoruzhko, V. B. Kazantsev // IEEE Access. 2020. Vol. 8. P. 84070-84081. <https://doi.org/10.1109/ACCESS.2020.2991812>

5. Kaplan A. Y. Neurophysiological foundations and practical realizations of the brain-machine interfaces in the technology in neurological rehabilitation // Human Physiol. 2016. Vol. 42, N 1. P. 103-110. <https://doi.org/10.1134/S0362119716010102>

6. Primary motor and sensory cortex activation during motor performance and motor imagery: A functional magnetic resonance imaging study / C. A. Porro, M. P. Francescato, V. Cettolo, M. E. Diamond, P. Baraldi, C. Zuiani, M. Bazzocchi, P. E. di Prampero J. // The Journal of Neuroscience: The Official Journal of the Society for Neuroscience. 1997. Vol. 16, N 23. P. 7688-7698. <https://doi.org/10.1523/JNEUROSCI.16-23-07688.1996>

7. Pfurtscheller G., Neuperb C. Motor imagery activates primary sensorimotor area in humans // Neurosci. Lett. 1997. Vol. 239, N 2-3. P. 65-68. [https://doi.org/10.1016/S0304-3940\(97\)00889-6](https://doi.org/10.1016/S0304-3940(97)00889-6)

8. A closed-loop brain-computer interface triggering an active ankle-foot orthosis for inducing cortical neural plasticity / R. Xu, N. Jiang, N. Mrachacz-Kersting, C. Lin, G. A. Prieto, J. C. Moreno, J. L. Pons, K. Dremstrup, D. Farina // IEEE Trans. Biomed. Eng. 2014. Vol. 61, N 7. P. 2092-2101. <https://doi.org/10.1109/TBME.2014.2313867>

9. Freriks B., Hermens H. European recommendations for surface electromyography // Roessingh Res. Develop. 1999. Vol. 8, N. 2. P. 13-54.

10. Development of recommendations for SEMG sensors and sensor placement procedures / H. J. Hermens, B. Freriks, C. Disselhorst-Klug, G. Rau // J. Electromyogr. Kinesiol. 2000. Vol. 10, N 5. P. 361-374. [https://doi.org/10.1016/S1050-6411\(00\)00027-4](https://doi.org/10.1016/S1050-6411(00)00027-4)

11. Кодовые образы сигналов электроэнцефалограммы для управления робототехническими устройствами посредством интерфейса мозг-компьютер / С. А. Филист, Е. В. Петрунина, А. А. Трифонов, А. В. Серебровский // Моделирование, оптимизация и информационные технологии. Научный журнал. 2019. Т. 7, № 1. С. 67-79. <https://doi.org/10.26102/2310-6018/2019.24.1.025>

12. Двухуровневая нейросетевая модель дешифратора электромиосигнала в системе управления вертикализацией экзоскелета / А. А. Трифонов, С. А. Филист, А. А. Кузьмин, В. В. Жилин, Е. В. Петрунина // Прикаспийский журнал: управление и высокие технологии. 2020. № 4 (52). С. 99–111.
13. Коробова С. Ю., Грязева-Добшинская В. Г., Чипеева Н. А. Особенности взаимосвязи двусторонней электродермальной активности с показателями спектральной мощности ЭЭГ // Психология. Психофизиология. 2021. Т. 14, № 3. С. 108–118. <https://doi.org/10.14529/jpps210311>
14. Столбков Ю. К., Герасименко Ю. П. Когнитивная двигательная реабилитация: воображение и наблюдение моторных действий // Физиология человека. 2021. Т. 47, № 1. С. 123–132.
15. Autonomic Nervous System Correlates in Movement Observation and Motor Imagery / C. Collet, F. Di Rienzo, N. El. Hoyek, A. Guillot // *Frontiers in Human Neuroscience*. 2013. Vol. 7. P. 1–17.
16. Using Sympathetic Skin Responses in Individuals with Spinal Cord Injury as a Quantitative Evaluation of Motor Imagery Abilities / M. Grangeon, K. Charvier, A. Guillot, G. Rode, Ch. Collet // *Physical Therapy*. 2012. Vol. 92, is. 6. P. 831–840.
17. Метод формирования персонифицированного контента клипов виртуальной реальности для реабилитации пациентов с нарушением двигательной активности / Е. В. Петрунина, С. А. Филист, А. Е. Пшеничный, Д. А. Ермаков, М. Ю. Ефремов // Системный анализ и управление в биомедицинских системах. 2024. Т. 23, № 4. С. 183–194. <https://doi.org/10.36622/1682-6523.2024.23.4.023>
18. Предварительные результаты исследования эффективности использования методики виртуальной реальности для восстановления двигательной функции нижних конечностей у пациентов в остром периоде инсульта / И. Е. Повереннова, А. В. Захаров, Е. В. Хивинцева, В. Ф. Пятин, А. В. Колсанов, С. С. Чаплыгин, Е. А. Осминина, А. С. Лахов // Саратовский научно-медицинский журнал. 2019. Т. 15, № 1. С. 172–176.
19. Валидация Шкалы баланса Берг в России / Н. А. Супонева, Д. Г. Юсупова, А. А. Зимин [и др.] // Неврология, нейропсихиатрия, психосоматика. 2021. № 13(3). С. 12–18. <https://doi.org/10.14412/2074-2711-2021-3-12-18>

References

1. Filist S.A., Petrynina E.V., Trifonov A.A., Serebrovsky A.V. Code images of electroencephalogram signals for controlling robotic devices via a brain-computer interface. *Modelirovanie, optimizatsiya i informatsionnye tekhnologii. Nauchnyi zhurnal = Modeling, Optimization and Information Technology. Scientific Journal*. 2019;7(1):67–79. (In Russ.) <https://doi.org/10.26102/2310-6018/2019.24.1.025>
2. Trifonov A.A., Filist S.A., Kuzmin A.A., Zhilin V.V., Petrunina E.V. A two-level neural network model of an electromyographic signal decoder in an exoskeleton verticaliza-

tion control system. *Prikaspiyskiy Zhurnal: Upravlenie i Vysokie Tekhnologii = Caspian Journal: Management and High Technologies*. 2020;(4):99–111. (In Russ.)

3. Yatsun A.S., Savin S.I., Turlapov R.N. Adaptive control system of an exoskeleton for human verticalization. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2015;(3):26–32. (In Russ.)

4. Gordleeva S.Yu., Lobov S.A., Grigorev N.A., Savosenkov A.O., Shamshin M.O., Lukoyanov M.V., Khoruzhko M.A., Kazantsev V.B. Real-Time EEG_EMG Human_Machine Interface-Based Control System for a Lower-Limb Exoskeleton. *IEEE Access*. 2020;8:84070-84081. <https://doi.org/10.1109/ACCESS.2020.2991812>

5. Kaplan A.Y. Neurophysiological foundations and practical realizations of the brain-machine interfaces in the technology in neurological rehabilitation. *Human Physiol.* 2016;42(1):103-110. <https://doi.org/10.1134/S0362119716010102>

6. Porro C.A., Francescato M.P., Cettolo V., Diamond M.E., Baraldi P., Zuiani C., Bazzocchi M., di Prampero P.E. Primary motor and sensory cortex activation during motor performance and motor imagery: A functional magnetic resonance imaging study. *The Journal of Neuroscience: The Official Journal of the Society for Neuroscience*. 1997;16(23):7688-7698. <https://doi.org/10.1523/JNEUROSCI.16-23-07688.1996>

7. Pfurtscheller G., Neuperb C. Motor imagery activates primary sensorimotor area in humans. *Neurosci. Lett.* 1997;239(2-3):65-68. [https://doi.org/10.1016/S0304-3940\(97\)00889-6](https://doi.org/10.1016/S0304-3940(97)00889-6)

8. Xu R., Jiang N., Mrachacz-Kersting N., Lin C., Prieto G.A., Moreno J.C., Pons J.L., Dremstrup K., Farina D. A closed-loop brain-computer interface triggering an active ankle-foot orthosis for inducing cortical neural plasticity. *IEEE Trans. Biomed. Eng.* 2014;61(7):2092-2101. <https://doi.org/10.1109/TBME.2014.2313867>

9. Freriks B., Hermens H. European recommendations for surface electromyography. *Roessingh Res. Develop.* 1999;8(2):13-54.

10. Hermens H.J., Freriks B., Disselhorst-Klug C., Rau G. Development of recommendations for SEMG sensors and sensor placement procedures. *J. Electromyogr. Kinesiol.* 2000;10(5):361-374. [https://doi.org/10.1016/S1050-6411\(00\)00027-4](https://doi.org/10.1016/S1050-6411(00)00027-4)

11. Filist S.A., Petrynina E.V., Trifonov A.A., Serebrovsky A.V. Code images of electroencephalogram signals for controlling robotic devices via a brain-computer interface. *Modelirovanie, Optimizatsiya i Informatsionnye Tekhnologii = Modeling, Optimization and Information Technology. Scientific Journal*. 2019;7(1):67-79. (In Russ.) <https://doi.org/10.26102/2310-6018/2019.24.1.025>

12. Trifonov A.A., Filist S.A., Kuzmin A.A., Zhilin V.V., Petrunina E.V. A two-level neural network model of an electromyographic signal decoder in an exoskeleton verticalization control system. *Prikaspiyskiy Zhurnal: Upravlenie i Vysokie Tekhnologii = Caspian Journal: Management and High Technologies*. 2020;(4):99–111. (In Russ.)

13. Korobova S.Yu., Gryazeva-Dobshinskaya V.G., Chipeeva N.A. Features of the relationship between bilateral electrodermal activity and EEG spectral power indicators. *Psikhologiya. Psikhofiziologiya = Psychology. Psychophysiology*. 2021;14(3):108–118. (In Russ.) <https://doi.org/10.14529/jpps210311>
14. Stolbkov Yu.K., Gerasimenko Yu.P. Cognitive motor rehabilitation: Imagination and observation of motor actions. *Fiziologiya Cheloveka = Human Physiology*. 2021;47(1):123–132. (In Russ.)
15. Collet C., Di Rienzo F., Hoyek N.El., Guillot A. Autonomic Nervous System Correlates in Movement Observation and Motor Imagery. *Frontiers in Human Neuroscience*. 2013;7:1-17.
16. Grangeon M., Charvier K., Guillot A., Rode G., Collet Ch. Using Sympathetic Skin Responses in Individuals with Spinal Cord Injury as a Quantitative Evaluation of Motor Imagery Abilities. *Physical Therapy*. 2012;92:831-840.
17. Petrunina E.V., Filist S.A., Pshenichny A.E., Ermakov D.A., Efremov M.Yu. Method of forming personalized content of virtual reality clips for rehabilitation of patients with impaired motor activity. *Sistemnyi analiz i upravlenie v biomeditsinskikh sistemakh = Systems Analysis and Control in Biomedical Systems*. 2024;23(4):183-194. (In Russ.) <https://doi.org/10.36622/1682-6523.2024.23.4.023>
18. Poverennova I.E., Zakharov A.V., Khivintseva E.V., Pyatin V.F., Kolsanov A.V., Chaplygin S.S., Osminina E.A., Lahov A.S. Preliminary results of study on efficacy of a virtual reality technique for restoration of lower extremity motor function in patients in acute stage of stroke. *Saratovskii nauchno-meditsinskii zhurnal = Saratov Journal of Medical Scientific Research*. 2019;15(1):172–176. (In Russ.)
19. Suponeva N.A., Yusupova D.G., Zimin A.A., et al. Validation of a Russian version of the Berg Balance Scale. *Nevrologiya, neiropsikhiatriya, psikhosomatika = Neurology, Neuropsychiatry, Psychosomatics*. 2021;(13):12–18. (In Russ.) <https://doi.org/10.14412/2074-2711-2021-3-12-18>

Информация об авторе / Information about the Author

Петрунина Елена Валерьевна, кандидат технических наук, доцент, Московский политехнический университет, г. Москва, Российская Федерация, e-mail: isu@mospolytech.ru, ORCID: 0000-0003-3661-0778

Elena V. Petrunina, Candidate of Sciences (Engineering), Associate Professor, Moscow Polytechnic University, Moscow, Russian Federation, e-mail: isu@mospolytech.ru, ORCID: 0000-0003-3661-0778

<https://doi.org/10.21869/2223-1536-2026-16-1-132-147>



УДК 004.891.2

Разработка многоуровневой системы для прогнозирования стоимости акций компаний в условиях высоковолатильного рынка России

А. А. Положенцев¹, А. В. Малышев¹✉, А. В. Брежнев²

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

² Российский экономический университет имени Г. В. Плеханова
Стремянный пер., д. 36, г. Москва 115054, Российская Федерация

✉ e-mail: alta76@yandex.ru

Резюме

Цель исследования – разработка гибридной модели прогнозирования стоимости акций на Московской бирже, учитывающая специфику русскоязычных новостей и интеграцию сигналов временных рядов с семантическим анализом текстов. Модель направлена на повышение точности предсказаний в условиях высокой волатильности российского финансового рынка и структурных изменений после 2022 года.

Методы. Разработана трёхуровневая модель предсказания стоимости акций. На каждом уровне предусмотрен выбор инструмента с учётом горизонта прогнозирования. Краткосрочный уровень основан на реализации рекуррентной сети GRU, показывающий высокую эффективность в период низкой волатильности. Среднечастотный уровень использует регрессионную модель с функцией потерь Хьюбера и модифицированные метрики тональности CIS для перевода новостного влияния в денежный эквивалент. Это позволяет совместить краткосрочные и фундаментальные индикаторы, повышает адаптивность модели в периоды высокой волатильности. Редкочастотный уровень объединяет статистическую модель ARIMAX, нейросетевую LSTM, а также индикаторы среднечастотного уровня для оценки долгосрочных тенденций и коррекции ошибок нижних уровней. Интеграция уровней реализована через механизм динамического перераспределения весов и межуровневую коррекцию доверительных коэффициентов.

Результаты. Разработана многоуровневая система для прогнозирования фондового рынка, реализующего гибридную архитектуру, объединяющую анализ временных рядов, фундаментальных показателей и новостного контекста с использованием языка программирования Python. Проведённая симуляция показала устойчивую точность прогнозов: в условиях рыночной турбулентности уровни L2 и L3 демонстрируют среднюю абсолютную ошибку не более 0,5 руб., что существенно ниже показателей технического уровня L1. Динамический механизм перераспределения весов между уровнями обеспечил адаптацию модели к резким изменениям рыночной конъюнктуры.

Заключение. Предложенная модель позволяет учитывать специфику российского рынка и снижает влияние рыночных шоков. Система пригодна для применения в инвестиционной аналитике и автоматизированных торговых решениях, открывая перспективы для дальнейшей адаптации под другие развивающиеся рынки.

Ключевые слова: прогнозирование фондового рынка; гибридная модель; временные ряды; нейросетевые модели; анализ новостей.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Положенцев А. А., Малышев А. В., Брежнев А. В. Разработка многоуровневой системы для прогнозирования стоимости акций компаний в условиях высоковолатильного рынка России // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 132–147. [https://doi.org/ 10.21869/2223-1536-2026-16-1-132-147](https://doi.org/10.21869/2223-1536-2026-16-1-132-147)

Поступила в редакцию 15.01.2026

Подписана в печать 12.01.2026

Опубликована 31.03.2026

Development of a multi-level system for forecasting stock prices of companies in the conditions of the highly volatile russian market

Alexey A. Polozhentsev¹, Alexander V. Malyshev¹ ✉, Alexey V. Brezhnev²

¹ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

² Plekhanov Russian University of Economics
36 Stremyanny side-street, Moscow 115054, Russian Federation

✉ e-mail: alta76@yandex.ru

Abstract

The purpose of the research is to develop and formalize a hybrid model for forecasting stock prices on the Moscow Exchange, which takes into account the specifics of linguistic analysis of Russian-language news and the integration of time series signals with semantic text analysis. The model is aimed at improving prediction accuracy in the conditions of high volatility of the Russian financial market and structural changes after 2022.

Methods. A three-level model for stock price prediction has been developed. Each level implies the use of a more suitable tool considering the forecasting horizon. Thus, the short-term level is based on a GRU recurrent network and uses a sliding window, which shows high efficiency during periods of low volatility. The medium-frequency level uses a regression model with a Huber loss function and modified CIS tone metrics to translate news influence into a monetary equivalent, which allows combining short-term and fundamental indicators; the use of the latter increases the model's adaptability during periods of high volatility. The low-frequency level combines the ARIMAX statistical model, the LSTM neural network, as well as medium-frequency level indicators to assess long-term trends and correct errors of the lower levels. The integration of the levels is implemented through a mechanism of dynamic weight redistribution and inter-level adjustment of confidence coefficients.

Results. A software complex for stock market forecasting was developed based on the Python programming language, implementing a hybrid architecture that integrates time series analysis, fundamental indicators, and news context. The simulation demonstrated sustained forecasting accuracy: under market turbulence conditions, levels L2 and L3 showed a mean absolute error not exceeding 0.5 rubles, which is significantly lower than the metrics of the technical level L1. The dynamic weight redistribution mechanism between levels ensured the model's adaptation to sharp changes in market conditions.

Conclusion. The proposed hybrid forecasting architecture combines machine learning, NLP, and econometric methods, ensuring a balance between sensitivity to short-term changes and the robustness of long-term forecasts. The integration of news analysis, time series, and macroeconomic factors allows for considering the specifics of the Russian market and reduces the impact of market shocks. The system is suitable for use in investment analytics and automated trading solutions, opening prospects for further adaptation to other emerging markets.

Keywords: stock market forecasting; hybrid model; time series; neural network models; news analysis.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Polozhentsev A.A., Malyshev A.V., Brezhnev A.V. Development of a multi-level system for forecasting stock prices of companies in the conditions of the highly volatile russian market. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(1):132–147. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-132-147>

Received 15.01.2026

Accepted 12.01.2026

Published 31.03.2026

Введение

Точное прогнозирование цен на акции критически важно в условиях нестабильности финансовых рынков, особенно в развивающихся экономиках, подобных России. Перспективным направлением является создание гибридных моделей, сочетающих анализ временных рядов и методов естественно-языковых вычислений (NLP) [1].

Целью работы является формализация и реализация гибридной модели прогноза для МОЕХ, учитывающей специфику лингвистического анализа русскоязычных новостей, интеграцию сигналов временных рядов с семантическим анализом текстов, разработку весовых метрик влияния информационных сообщений.

Задачи включают: модификацию моделей тонального анализа для русского языка, построение мультифакторной модели и оценку её эффективности на исторических данных.

Новизна предлагаемого подхода заключается в построении многоуровневой системы оценки новостей, основанной на адаптированной для русско-

го языка модели тональности, автоматическом выделении финансовых событий с классификацией по весу, учете индустриальной релевантности и временного затухания влияния информации.

Актуальность работы подчеркивается структурными изменениями российского рынка после 2022 г., такими как снижение ликвидности, рост роли господдержки и высокая волатильность.

Материалы и методы

Система прогнозирования фондовых акций реализована в виде трёхуровневой гибридной архитектуры, где каждый уровень отвечает за свой временной горизонт и тип данных – от высокочастотных рыночных сигналов до долгосрочных макроэкономических факторов (рис. 1). Такой подход обеспечивает сочетание реактивности, стабильности и интерпретируемости итоговых прогнозов [2].

Уровень L1 – высокочастотный технический прогноз. Реагирует на мгновенные колебания рынка, используя котировки, объёмы торгов, техниче-

ские индикаторы (RSI, MACD, SMA, ATR) и волатильность. Обновляет прогноз каждую минуту, обеспечивая адаптацию к изменениям ликвидности и настроений инвесторов [3].

Математическая архитектура. В основе уровня [4] – рекуррентная нейронная сеть GRU со скользящим окном [5]. Каждый новый бар данных x_t нормализуется локально по окну длиной W :

$$u_t^{(norm)} = \frac{u_t - \mu_{t-1}^{(W)}(u)}{\sigma_{t-1}^{(W)}(u) + \varepsilon}, \mu_{t-1}^{(W)}(u) = \frac{1}{W} \sum_{k=t-W}^{t-1} u_k, \sigma_{t-1}^{(W)}(u) = \sqrt{\frac{1}{W} \sum_{k=t-W}^{t-1} (u_k - \mu_{t-1}^{(W)}(u))^2}. \quad (1)$$

	 Уровень L1: Высокочастотный	 Уровень L2: Фундаментально-новостной	 Уровень L3: Стратегический-макро
Цель	Реагировать на колебания рынка	Захватывать среднесрочные тренды	Установить долгосрочную ценовую траекторию
Используемые данные	Котировки, объёмы, технические индикаторы	Экономические сектора, новостной сентимент, рыночные индикаторы	Макро тренды, ошибки предыдущего уровня
Временной горизонт	Минуты	Минуты до часов	Часы до дней
Математическая архитектура	Рекуррентная нейронная сеть GRU	Регрессия с потерей Хубера	Компоненты ARIMAX, LSTM, EXOG
Тип прогноза	Относительное изменение цены	Цена на основе признаков	Долгосрочный прогноз цены
Взвешивание	Адаптивное на основе корреляции	Адаптивное на основе саморегуляции	Веса комбинированной модели
Влияние новостей	—	Индекс новостей СНГ	Индекс новостей СНГ

Рис. 1. Устройство и основные характеристики каждого уровня гибридной модели

Fig. 1. Structure and main characteristics of each level of the hybrid model

Входной вектор включает в себя различные нормализованные индикаторы [6], такие как доходность, объём, спред, волатильность:

$$x_t = \begin{bmatrix} r_t^{(norm)} \\ v_t^{(norm)} \\ s_t^{(norm)} \\ \sigma_t^{(norm)} \end{bmatrix}, \quad (2)$$

где r – доходность; v – объём; s – спред; σ – волатильность.

Математическая модель процесса обновления внутреннего состояния GRU на каждом временном шаге t описывается следующей системой уравнений:

$$\begin{aligned} z_t &= \sigma(W_z x_t + U_z h_{t-1} + b_z), \\ r_t &= \sigma(W_r x_t + U_r h_{t-1} + b_r), \\ \tilde{h}_t &= \tan h(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h), \\ h_t &= (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t. \end{aligned} \quad (3)$$

Для трансформации конечного скрытого состояния h_t в непосредственно прогнозируемое значение используется полносвязный выходной слой:

$$\begin{aligned} \Delta p_t^{(fast)} &= W_y h_t + b_y, P_t^{fast} = \\ &= P_{t-1} \left(1 + \Delta p_t^{(fast)} \right). \end{aligned} \quad (4)$$

Для динамической оценки надежности прогнозов краткосрочного уровня в условиях меняющейся рыночной во-

латильности введен адаптивный вес доверия ω_t^{L1} , который рекуррентно обновляется по формуле экспоненциального сглаживания:

$$\omega_t^{L1} = \lambda \omega_{t-1}^{L1} + (1 - \lambda) \text{corr}(P_{t-\tau:t-1}^{fast}, P_{t-\tau:t-1}^{obs}), \quad (5)$$

где $\lambda \in (0,1)$ – коэффициент сглаживания; $\text{corr}(\cdot)$ – корреляция Пирсона.

Уровень L2 – фундаментально-новостной прогноз. Отвечает за среднесрочные тенденции, объединяя экономические сектора, новостную тональность и рыночные индикаторы. L2 связывает микро- и макрофакторы, оценивая, как события влияют на цену актива.

Математическая архитектура. Регрессионная модель с устойчивой функцией потерь Хубера, обновляемая методом адаптивного градиентного шага [7]:

$$\hat{P}_t = \varphi_t^T \theta_{t-1} + \beta_{t-1} g(CIS_t), \quad (6)$$

где $\varphi_t \in \mathbb{R}^p$ – вектор признаков (по секторам экономики (рис. 2)); θ_{t-1} – параметры модели; β – чувствительность к новостному индексу CIS.

Для обеспечения устойчивости модели к выбросам, характерным для периодов высокой волатильности, минимизируется функция потерь Хубера [8]:

$$\ell_\delta(e_t) = \begin{cases} \frac{1}{2} e_t^2, & |e_t| \leq \delta, \\ \delta \left(|e_t| - \frac{1}{2} \delta \right), & |e_t| > \delta, e_t = P_t^{obs} - \hat{P}_t. \end{cases} \quad (7)$$



Рис. 2. Предлагаемые фундаментальные индикаторы и мультипликаторы по секторам экономики

Fig. 2. Proposed fundamental indicators and multipliers by economic sector

Обновление параметров модели θ осуществляется методом адаптивного градиентного спуска:

$$\begin{aligned} g_t &= -\nabla_{\theta} \ell_{\delta}(e_t), \\ s_t &= \rho s_{t-1} + (1 - \rho) g_t^{\odot 2}, \\ \theta_t &= \theta_{t-1} + \eta \frac{g_t}{\sqrt{s_t + \varepsilon}}, \end{aligned} \quad (8)$$

где $\eta = 0,001$ может меняться моделью; $\rho = 0,9$ (может меняться моделью).

Для перевода семантической информации в количественную метрику ценового воздействия разработан новостной индекс CIS (Currency Impact Score):

$$CIS_{RUB} = \kappa \cdot Impact_{cluster} \cdot \frac{\sigma \cdot P}{\sqrt{L}}, \quad (9)$$

где σ – волатильность; P – цена; L – ликвидность; $\kappa = 0,5-1,5$.

Воздействие новостного кластера вычисляется по следующим формулам:

$$\begin{aligned} Tonicity &= \\ &= w_{pos} Score_{pos} - w_{neg} Score_{neg}, \\ Impact_{cluster} &= \\ &= Tonicity \sum_i Weight_{source,i}. \end{aligned} \quad (10)$$

Таким образом, уровень L2 обеспечивает интеграцию экономических признаков, семантического анализа новостей и рыночной ликвидности в единую прогнозную систему, адаптивно корректирующую параметры в условиях изменяющейся волатильности.

Уровень L3 – стратегический и макроэкономический прогноз. Формирует долгосрочную траекторию цен. L3 оценивает макротенденции [9], корректирует ошибки предыдущих уровней и выполняет роль регулятора системы.

Математическая архитектура. Комбинированная модель, включающая статистические (ARIMAX) [10] и нейросетевые (LSTM) [11] компоненты:

$$\begin{aligned} P_t^{L3} &= w_{AR,t} P_t^{ARIMAX} + \\ &+ w_{LSTM,t} P_t^{LSTM} + w_{CIS,t} CIS_t^{RUB} + \\ &+ w_{EX,t} P_t^{EXOG}, \sum w_i = 1, \end{aligned} \quad (11)$$

где

$$\begin{aligned} P_t^{ARIMAX} &= \mu + \sum_{i=1}^p \varphi_i (P_{t-i} - \mu) + \\ &+ \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \sum_{k=1}^m \beta_k X_{t,k}^{(exo)}, \end{aligned} \quad (12)$$

$$P_t^{LSTM} = f_{\theta} (P_{t-l:t-1}, X_{t-l:t}^{(exo)}). \quad (13)$$

$$\begin{aligned} P_t^{EXOG} &= \delta_{DCF} P_t^{DCF} + \\ &+ \delta_{MUL} P_t^{MUL} + \delta_{MACRO} P_t^{MACRO} + \\ &+ \delta_{CIS} CIS_t^{RUB}. \end{aligned} \quad (14)$$

EXOG-блок агрегирует фундаментальные, мультипликативные и макроэкономические оценки. Разберём компоненты этого блока подробнее. Новостной индекс CIS_t^{RUB} рассчитывается по модифицированной формуле (9) с увеличенным временным горизонтом для учета долгосрочного влияния информационного фона.

Модифицированная модель дисконтированных денежных потоков (DCF) учитывает отклонения [12] от базовых прогнозов через гиперболические трансформации фундаментальных показателей:

$$\begin{aligned} P_t^{DCF,adj} &= \\ &= \frac{\sum_{k=1}^n \frac{FCF_{t+k}^{base} (1 + \sum_j \omega_j \tan h(\alpha_j z_{j,t}))}{(1+r)^k} + \frac{FCF_{t+n}^{base} (1+g)}{(r-g)} (1 + \sum_j \varphi_j z_{j,t}^{(exit)})}{N_{shares}}, \end{aligned} \quad (15)$$

где $z_{j,t}$ – нормализованный фундаментальный показатель по сектору.

Оценка на основе сравнительного анализа мультипликаторов:

$$P_t^{MUL} = \frac{1}{m} \sum_{j=1}^m \frac{M_j^{sector}}{M_j^{company}} \cdot P_t, \quad (16)$$

где M_j – мультипликатор согласно сектору экономики (рис. 2).

Модель макроэкономической чувствительности:

$$P_t^{MACRO} = P_{t-1} \cdot \left(1 + \sum_{i=1}^n \beta_i ind_i \right), \quad (17)$$

где β_i – чувствительность акции к этим факторам (оценивается регрессией по историческим данным); ind_i – внешний фактор, имеющий значительный вес согласно сектору экономики.

Уровень L3 реализует адаптивную систему перераспределения весов между компонентами модели на основе ретроспективного анализа ошибок прогнозирования.

$$k_{bias,t} = 1 - \eta \frac{P_t^{L2} - P_t^{obs}}{P_t^{obs}},$$

$$k_{trust,t} = \tan h \left(\rho \text{corr}(P_{t-\tau:t}^{L1}, P_{t-\tau:t}^{obs}) \right), \quad (18)$$

где $k_{bias,t}$ – коэффициент коррекции смещения уровня L2; $k_{trust,t}$ – коэффициент доверия к уровню L1; η – скорость адаптации ($0 < \eta < 1$); ρ – параметр масштабирования корреляции.

Динамическое перераспределение весов осуществляется по следующим формулам:

$$w_{i,t+1} = \frac{k_{bias,t} w_{i,t}}{\sum_j k_{bias,t} w_{j,t}},$$

$$\alpha_{1,t+1} = \frac{k_{trust,t} \alpha_{1,t}}{k_{trust,t} (\alpha_{1,t} + \alpha_{2,t} + \alpha_{3,t})}, \quad (19)$$

где $w_{i,t}$ – весовые коэффициенты компонент EXOG-блока; $\alpha_{1,t}$ – веса уровней прогнозирования.

Многоуровневая архитектура системы обеспечивает постоянное взаимодействие между компонентами [13]. Уровень L2 поставляет на уровень L3 фундаментальные показатели и новостные индикаторы, формируя основу для стратегической оценки. В ответ уровень L3 динамически корректирует весовые коэффициенты уровней L2 и L1, учитывая рыночные тренды и ошибки прогнозирования. Завершающим этапом становится интеграция всех факторов на уровне L3, где объединяются стратегические, фундаментальные и технические компоненты. Такой механизм позволяет инвестору получать сбалансированную оценку, одновременно учитывающую краткосрочные рыночные колебания и долгосрочную фундаментальную устойчивость компании, что особенно ценно в условиях высокой волатильности российского рынка. Так инвестор получает оценку, учитывающую как текущие колебания [14], так и долгосрочную устойчивость компании [15].

Теоретическое обоснование многоуровневой архитектуры требует моделирования для подтверждения ранее выдвинутых гипотез. Для демонстрации реальной эффективности предложенного подхода рассмотрим поведение уровней L1, L2 и L3 в контролируемом сценарии, имитирующем переход от стабильного рынка к периоду высокой

волатильности на МОЕХ¹. Такой эксперимент позволяет наглядно проанализировать, как разные временные горизонты прогнозирования реагируют на резкие изменения рыночной ситуации.

Сценарий эксперимента:

1. Фаза 1 (0-60 минут): спокойный рынок с типичными флуктуациями и стабильным трендом.

2. Фаза 2 (60-120 минут): рыночный шок – резкое изменение цен с повышенной волатильностью.

Ожидаемое поведение уровней. В таких условиях уровни L2 и L3 должны демонстрировать принципиальное преимущество перед быстрым L1. Уровень L1, ориентированный на краткосрочные паттерны, в фазе шока обязан начать «преследовать» цену, генерируя запаз-

дывающие прогнозы с нарастающей ошибкой. В то же время L2, учитывающий фундаментальные факторы и новостной фон, должен быстрее адаптироваться к новым условиям, а уровень L3 обеспечивать стабилизацию за счет долгосрочных ориентиров.

Допущения и методика:

– L1 – высокочастотный уровень, поток рыночных данных;

– L2 – среднесрочный уровень, регрессионная модель с минимизацией потерь;

– L3 – стратегический (ARIMAX/LSTM + долгосрочный EXOG/CIS).

Рассмотрим сводные результаты эксперимента по прогнозу стоимости акции в условиях низкой и высокой волатильности (табл. 1).

Таблица 1. Сводные результаты эксперимента по прогнозу стоимости акции в условиях низкой и высокой волатильности

Table 1. Summary of experimental results on stock price forecasting under low and high volatility conditions

Мин	L1 (P)	L2 (P)	L3 (P)	P^{obs} (P)	MAE_{L1}	MAE_{L2}	MAE_{L3}	$corr_{L1}^{Pearson}$	$corr_{L1}^{Win 5}$
0	—	—	—	293,000	—	—	—	—	—
1	292,663	—	—	292,700	0,037	—	—	—	—
2	292,524	—	—	292,500	0,024	—	—	—	—
3	292,666	—	—	292,700	0,034	—	—	0,688	0,688
4	293,109	—	—	293,100	0,009	—	—	0,499	0,499
5	293,301	—	—	293,300	0,001	—	—	0,787	0,787
15	293,900	294,12	—	293,900	0,000	0,220	—	0,891	0,120
30	294,500	294,41	—	294,500	0,000	0,090	—	0,964	0,050
45	294,950	294,92	—	294,950	0,000	0,030	—	0,984	0,020
60	295,400	295,16	295,689	295,400	0,000	0,240	0,289	0,992	0,010
75	295,800	291,00	—	289,000	6,800	2,000	—	0,900	–0,80
90	295,500	287,50	—	287,000	8,500	0,500	—	0,870	–0,95
105	295,000	286,00	—	286,000	9,000	0,000	—	0,880	–0,98
120	294,000	285,20	285,505	285,000	9,000	0,200	0,505	0,910	–0,60

Примечание. MAE_* – модуль ошибки модели в этой точке ($|P_{L*} - P_{obs}|$); $corr_{L1}^{Pearson}$ – корреляция Пирсона между всеми парами (P^{fast}, P^{obs}) от 0 до $t - 1$. Она остаётся высокой после шока, потому что содержит много предшествующих «спокойных» точек, где L1 идеально соответствовал; $corr_{L1}^{Win 5}$ – корреляция по локальному окну размером в 5 предыдущих значений.

¹ Московская биржа. URL: [https:// www.moex.com/](https://www.moex.com/) (дата обращения: 17.12.2025).

Для демонстрации работы многоуровневой модели рассмотрим последовательность расчётов на временном интервале $t = 0,60$.

На первом уровне (L1) выполняется высокочастотный прогноз на основе нормализованных рыночных признаков: доходности (ret_{norm}), волатильности (vol_{norm}) и спреда ($spread_{norm}$).

Первый временной шаг:

$$(t = 0 \rightarrow t = 1).$$

На основе нормализованных признаков:

$$ret_{norm} = -0,78, vol_{norm} = 0,62, \\ spread_{norm} = 0,71$$

рассчитывается относительное изменение цены:

$$\Delta p_{L1,1} = 0,0020 \cdot (-0,78) + \\ + 0,0010 \cdot 0,62 - 0,0010 \cdot 0,71 + \\ + 0,0005 = -0,00115.$$

Перевод в рубли:

$$\Delta P_0 = 293,00 \cdot (-0,00115) = \\ = -0,337 \text{ руб.}$$

Новое предсказание:

$$P_1^{fast} = 293,00 - 0,337 = \\ = 292,663 \text{ руб.} \approx 292,66.$$

Второй временной шаг:

$$(t = 1 \rightarrow t = 2)$$

отражает адаптацию модели при изменении рыночных признаков:

$$ret_{norm} = -0,45, vol_{norm} = 0,30, \\ spread_{norm} = 0,50.$$

Расчёт:

$$\Delta p_{L1,2} = 0,0020 \cdot (-0,45) + \\ + 0,0010 \cdot 0,30 - 0,0010 \cdot 0,50 + \\ + 0,0005 = -0,00060,$$

$$\Delta P_1 = 292,70 \times \\ \times (-0,00060) = -0,1756 \text{ руб.}, \\ P_2^{fast} = 292,70 - 0,176 = 292,524 \text{ руб.}$$

На втором уровне (L2) применяется регрессионная модель с функцией потерь Хубера, использующая фундаментальные признаки и индекс новостной тональности (CIS).

Для $t = 15$:

$$\theta_0 = \left[P_{t-1}^{obs}, \omega_{ROE}, \omega_{BVPS}, \dots, \omega_{\frac{P}{Deposits}} \right] = \\ = [293,85, 0,001, 0,001, \dots, 0,001],$$

$$\beta_0 = 0,05, \varphi_0 = \\ = [1, 0,010, 0,008, \dots, 0,100], CIS_0 = \\ = 0, s_0 = 10^{-6}.$$

$$\hat{P}^t = 293,85 + 0,001 \cdot 0,01 + \\ + \dots + 0,001 \cdot 0,1 + \\ + 0,05 \cdot 0 \approx 294,12 \text{ руб.},$$

$$e_t = y - \hat{P}^t = \\ = 293,90 - 294,12 = 0,22 \text{ руб.}$$

Так как $|e_t| < \delta = 0,5$, используется квадратичная часть потери Хьюбера:

$$g_t = e_t \cdot \varphi_t = \\ = 0,22 \cdot [1, 0,010, 0,008, \dots, 0,100] = \\ = [0,22, 0,0022, 0,00176, \dots, 0,022]. \\ s_t = \rho s_{t-1} + (1 - \rho) g_t^{\odot 2},$$

$$g_t^{\odot 2} \approx [0,0484, 4,84 \cdot 10^{-6}, 3,10 \cdot 10^{-6}, \dots, 0,000484], \\ s_t \approx 0,9 \cdot 10^{-6} + 0,1 \cdot [0,0484, \dots] = [0,0048409, 5,74 \cdot 10^{-6}, \dots, 4,849 \cdot 10^{-4}].$$

Формула обновления параметров:

$$\theta_t = \theta_{t-1} + \eta \frac{g_t}{\sqrt{s_t + \varepsilon}}.$$

После вычисления $\sqrt{s_t}$ и нормализации

$$\frac{g_t}{\sqrt{s_t}} \approx [3,162, 3,162, 3,162, 3,162, 3,162],$$

$$\Delta\theta = 0,001 \cdot \frac{g_t}{\sqrt{s_t}} = [0,003162, \dots],$$

$$\theta_t = \theta_{t-1} +$$

$$+ \Delta\theta \approx [293,853162, 0,013162, \dots].$$

На третьем уровне (L3) объединяются результаты ARIMAX-, LSTM-, CIS- и EXOG-блоков для построения интегрированного прогноза:

$$P_{60}^{DCF} = 295 \cdot 1 + 0,3 \cdot 0 + 0,25 \cdot 0 + 0,2 \cdot 0 - 0,25 \cdot 0 = 295.$$

$$P_{60}^{MACRO} = 295 \cdot 1 + 0,4 \cdot \Delta \text{ставка} - 0,3 \cdot \Delta \text{ликвидность} = 295,00 \text{ руб.}$$

$$P_{60}^{EXOG} = 0,4 \cdot 295 + 0,3 \cdot 295 + 0,2 \cdot 295 + 0,1 \cdot 295,6 = 295,06 \text{ руб.}$$

$$MAE_{AR} = 0,015, MAE_{LSTM} = 0,010, MAE_{CIS} = 0,080, MAE_{EXOG} = 0,030.$$

$$P_{60}^{ARIMAX} = 295,90, P_{60}^{LSTM} = 295,90.$$

$$\tilde{w}_i = e^{-\beta \cdot MAE_i} \Rightarrow \tilde{w}_{AR} = 0,687, \tilde{w}_{LSTM} = 0,778, \tilde{w}_{CIS} = 0,135, \tilde{w}_{EXOG} = 0,472.$$

$$\sum \tilde{w} = 2,072 \Rightarrow w_{AR} = 0,332, w_{LSTM} = 0,375, w_{CIS} = 0,065, w_{EXOG} = 0,228.$$

$$P_{60}^{L3} = 0,332 \cdot 295,9 + 0,375 \cdot 295,9 + 0,065 \cdot 295,6 + 0,228 \cdot 295,06.$$

$$P_{60}^{L3} = 98,27 + 110,85 + 19,50 + 67,38 = 295,69 \text{ руб.}$$

Итоговый прогноз уровня L3 стабилизирует результат нижних уровней и отражает совокупное влияние макро- и фундаментальных факторов.

Результаты и их обсуждение

1. Поведение уровней в момент рыночного шока. В момент информационного шока на 75-й минуте наблюдалось резкое падение наблюдаемой цены P_{obs} с 295,4 до 289,0 руб. Уровень L1, основанный на технических индикаторах, продемонстрировал инерционное поведение и выдал прогноз 295,8 руб. ($MAE = 6,8$ руб.), в то время как L2, интегрирующий новостные и ордерные данные, быстро скорректировал значение до 291,0 руб. ($MAE = 2,0$ руб.). Это подтверждает, что L2 способен быстрее

адаптироваться к новым рыночным условиям, тогда как L1 имеет лаг из-за ориентации на краткосрочные паттерны без учёта контекста.

2. Изменение корреляционных метрик. После возникновения шока глобальная корреляция L1 оставалась высокой ($\sim 0,9$), но оконная корреляция снизилась до $-0,8$. Такое расхождение показывает, что традиционные метрики могут вводить в заблуждение в периоды нестабильности. Анализ локальных метрик позволяет своевременно фиксировать деградацию модели [16] и инициировать перераспределение доверительных весов между уровнями, что является важным элементом адаптивной архитектуры системы [17].

3. Динамика ошибок на интервале 90–120 минут. При дальнейшем снижении цены с 287 до 285 руб. уровень L1 медленно снижал прогноз, сохраняя высокие ошибки ($MAE = 8,5\text{--}9,0$ руб.). В то же время уровень L2 обеспечил точность до $MAE \leq 0,5$ руб., а стратегический уровень L3 после пересчёта выдал прогноз 285,5 руб. с $MAE = 0,5$ руб. Это подтверждает, что L3 выполняет стабилизирующую функцию, компенсируя ошибки нижних уровней и обеспечивая устойчивость модели при волатильных изменениях рынка.

4. Подтверждение гипотез о распределении функций уровней. Полученные данные подтвердили все выдвинутые гипотезы. Уровень L1 обеспечивает чувствительность и мгновенную реакцию, L2 – быструю адаптацию к новостным и поведенческим изменениям рынка, а L3 – долгосрочную стабилизацию и контроль распределения весов. Такое распределение ролей обеспечивает баланс между реактивностью и устойчивостью, делая систему надёжной как в спокойных, так и в стрессовых рыночных условиях [18].

5. Практическая интерпретация результатов. Реализация механизма динамического перераспределения доверительных коэффициентов между уровнями позволила повысить устойчивость прогноза и снизить совокупную ошибку системы. В практическом применении это означает, что архитектура способна не только реагировать на рыночные аномалии, но и самостоятельно коррек-

тировать стратегию прогнозирования в реальном времени, что делает её перспективной для использования в системах инвестиционной аналитики и алгоритмической торговли.

Выводы

В ходе проведённого эксперимента, направленного на проверку эффективности трёхуровневой гибридной архитектуры прогнозирования цен акций на MOEX, были получены результаты, подтверждающие высокую адаптивность, устойчивость и точность предложенной модели.

1. Высокая точность и адаптивность: на интервалах рыночных шоков уровни L2 и L3 продемонстрировали среднюю абсолютную ошибку (MAE) менее 1 руб., что значительно ниже, чем у базового уровня L1 (до 9 руб.). Это подтверждает способность гибридной архитектуры динамически перестраиваться под изменяющиеся рыночные условия и эффективно обрабатывать как рыночные, так и новостные сигналы.

2. Интеллектуальная интеграция сигналов: результаты показали, что комбинация временных рядов, лингвистического анализа новостей и макроэкономических индикаторов обеспечивает синергетический эффект, повышающий устойчивость прогноза [19]. В частности, L2 эффективно реагирует на новостные импульсы, а L3 корректирует стратегический тренд, снижая влияние краткосрочных искажений.

3. Стабильность и интерпретируемость: уровень L3 доказал свою роль в стабилизации итоговых прогнозов, выступая регулятором весов между подсистемами. Механизм адаптивного перераспределения доверительных коэффициентов обеспечивает сбалансированную реакцию всей модели при колебаниях рынка.

4. Практическая применимость: предложенная архитектура может быть использована в системах инвестиционной аналитики и алгоритмической торговли, где требуется высокая скорость реакции и устойчивость к информационным шокам. Структура модели, построенная на принципах распределённости и микросервисной интеграции,

также открывает возможности масштабирования для анализа различных секторов экономики.

Таким образом, результаты проведённого исследования подтверждают перспективность гибридного подхода к прогнозированию фондового рынка. Он сочетает преимущества нейросетевых, статистических и лингвистических методов, обеспечивая баланс между чувствительностью к краткосрочным изменениям и устойчивостью долгосрочных прогнозов. Дальнейшее развитие данного направления позволит повысить точность финансовых прогнозов и создать интеллектуальные системы поддержки инвестиционных решений нового поколения.

Список литературы

1. Kingma D. P., Ba J. L. Adam: A Method for Stochastic Optimization // Proceedings of the 3rd International Conference for Learning Representations (ICLR). URL: <https://arxiv.org/abs/1412.6980> (дата обращения: 17.12.2025).
2. Time Series Analysis: Forecasting and Control / G. E. P. Box, G. M. Jenkins, G. C. Reinsel, G. M. Ljung. 5th ed. Hoboken: John Wiley & Sons, 2015. 712 p.
3. Fama E. F., French K. R. A Five-Factor Asset Pricing Model // Journal of Financial Economics. 2015. Vol. 116, N 1. P. 1–22.
4. Hinton G. E., Srivastava N., Krizhevsky A., Sutskever I., Salakhutdinov R. Improving Neural Networks by Preventing Co-adaptation of Feature Detectors // Neural and Evolutionary Computing. URL: <https://arxiv.org/abs/1207.0580v1> (дата обращения: 17.12.2025).
5. Белоусов А. В. Методы анализа временных рядов в экономике. М.: Финансы и статистика, 2018. 312 с.
6. Шамраева В. В. Математические методы прогнозирования изменения цены акций и их реализация методами машинного обучения // Фундаментальные исследования. 2024. № 11. С. 88–96.
7. Васильев А., Смирнов И. Применение машинного обучения для прогнозирования фондового рынка России // Computational Economics and Finance Journal. 2023. Т. 5, № 2. С. 34–45.

8. Huber P. J. Robust Estimation of a Location Parameter // *The Annals of Mathematical Statistics*. 1964. Vol. 35, N 1. P. 73–101.
9. Сентимент частных инвесторов и его влияние на доходность российских акций / Т. В. Теплова, Т. В. Соколова, А. Ф. Томтосов [и др.] // *Журнал Новой экономической ассоциации*. 2022. № 1 (53). С. 53–84.
10. Hochreiter S., Schmidhuber J. Long Short-Term Memory // *Neural Computation*. 1997. Vol. 9, N 8. P. 1735–1780.
11. Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation / K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, Y. Bengio // *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Doha, 2014. P. 1724–1734.
12. Пятибратов Д. В., Логинов А. В., Болотов Т. А. Сравнительный анализ алгоритмов машинного обучения в задачах исследования фондового рынка // *Вестник науки*. 2025. Т. 3, вып. 10 (91). С. 644–650.
13. Глебова А. Г., Ковалева А. А. Прогнозирование волатильности российского биржевого рынка акций в условиях международных санкций // *Финансы: теория и практика*. 2024. № 1. С. 20–29.
14. Tetlock P. C. Giving Content to Investor Sentiment: The Role of Media in the Stock Market // *The Journal of Finance*. 2007. Vol. 62, N 3. P. 1139–1168.
15. Damodaran A. Investment Valuation: Tools and Techniques for Determining the Value of Any Asset. 3rd ed. Hoboken: John Wiley & Sons, 2012. 992 p.
16. PyTorch: An Imperative Style, High-Performance Deep Learning Library / A. Paszke, S. Gross, F. Massa, A. Lerer, J. Bradbury [et al.] // *Machine Learning*. URL: <https://arxiv.org/abs/1207.0580v1> (дата обращения: 17.12.2025).
17. Scikit-learn: Machine Learning in Python / F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion [et al.] // *Journal of Machine Learning Research*. 2011. Vol. 12. P. 2825–2830.
18. Минкин В. А., Кулешов Д. А. Применение методов машинного обучения для прогнозирования фондового рынка // *Вестник Финансового университета*. 2022. № 3. С. 55–66.
19. Першина А. А., Арутюнян А. Г., Косников С. Н. Применение нейросетей в прогнозировании экономических тенденций // *Региональная и отраслевая экономика*. 2023. № 5. С. 164–171. https://doi.org/10.47576/2949-1916_2023_5_164

References

1. Kingma D.P., Ba J.L. Adam: A Method for Stochastic Optimization. In: *Proceedings of the 3rd International Conference for Learning Representations (ICLR)*. Available at: <https://arxiv.org/abs/1412.6980> (accessed 17.12.2025).

2. Box G.E.P., Jenkins G.M., Reinsel G.C., Ljung G.M. Time Series Analysis: Forecasting and Control. 5th ed. Hoboken: John Wiley & Sons; 2015. 712 p.
3. Fama E.F., French K.R. A Five-Factor Asset Pricing Model. *Journal of Financial Economics*. 2015;116(1):1–22.
4. Hinton G.E., Srivastava N., Krizhevsky A., Sutskever I., Salakhutdinov R. Improving Neural Networks by Preventing Co-adaptation of Feature Detectors. In: Neural and Evolutionary Computing. Available at: <https://arxiv.org/abs/1207.0580v1> (accessed 17.12.2025).
5. Belousov A.V. Methods of Time Series Analysis in Economics. Moscow: Finansy i statistika; 2018. 312 p. (In Russ.)
6. Shamraeva V.V. Mathematical Methods for Forecasting Stock Price Changes and Their Implementation Using Machine Learning. *Fundamental'nye issledovaniya = Fundamental Research*. 2024;(11):88-96. (In Russ.)
7. Vasiliev A., Smirnov I. Application of Machine Learning for Forecasting the Russian Stock Market. *Computational Economics and Finance Journal*. 2023;5(2):34–45. (In Russ.)
8. Huber P.J. Robust Estimation of a Location Parameter. *The Annals of Mathematical Statistics*. 1964;35(1):73–101.
9. Teplova T.V., Sokolova T.V., Tomtosov A.F., et al. Sentiment of Private Investors and Its Impact on the Returns of Russian Stocks. *Zhurnal Novoi ekonomicheskoi assotsiatsii = Journal of the New Economic Association*. 2022;(1):53–84. (In Russ.)
10. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997;9(8):1735–1780.
11. Cho K., van Merriënboer B., Gulcehre C., Bahdanau D., Bougares F., Schwenk H., Bengio Y. Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation. In: *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Doha; 2014. P. 1724–1734.
12. Pyatibratov D.V., Loginov A.V., Bolotov T.A. Comparative Analysis of Machine Learning Algorithms in Stock Market Research Tasks. *Vestnik nauki = Science Bulletin*. 2025;3:644-650. (In Russ.)
14. Tetlock P. C. Giving Content to Investor Sentiment: The Role of Media in the Stock Market. *The Journal of Finance*. 2007;62(3):1139–1168.
13. Glebova A.G., Kovaleva A.A. Forecasting the Volatility of the Russian Stock Market under International Sanctions. *Finansy: teoriya i praktika = Finance: Theory and Practice*. 2024;(1):20–29. (In Russ.)
15. Damodaran A. Investment Valuation: Tools and Techniques for Determining the Value of Any Asset. 3rd ed. Hoboken: John Wiley & Sons; 2012. 992 p.
16. Paszke A., Gross S., Massa F., Lerer A., Bradbury J. et al. PyTorch: An Imperative Style, High-Performance Deep Learning Library. In: Machine Learning. Available at: <https://arxiv.org/abs/1207.0580v1> (accessed 17.12.2025).

17. Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., et al. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*. 2011;12:2825–2830.

18. Minkin V.A., Kuleshov D.A. Application of Machine Learning Methods for Stock Market Forecasting. *Vestnik Finansovogo universiteta = Bulletin of the Financial University*. 2022;(3):55–66. (In Russ.)

19. Pershina A.A., Arutyunyan A.G., Kosnikov S.N. Application of neural networks in forecasting economic trends. *Regional'naya i otraslevaya ekonomika = Regional and Sectoral Economics*. 2023;(5):164-171. (In Russ.) https://doi.org/10.47576/2949-1916_2023_5_164

Информация об авторах / Information about the Authors

Положенцев Алексей Анатольевич, магистрант кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: polojencev135@mail.ru, ORCID: 0009-0004-6824-1019

Alexey A. Polozhentsev, Undergraduate at the Department of Software Engineering, Southwest State University, Kursk, Russian Federation, e-mail: polojencev135@mail.ru, ORCID: 0009-0004-6824-1019

Малышев Александр Васильевич, кандидат технических наук, доцент кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: alta76@yandex.ru, ORCID: 0000-0002-9938-3456

Alexander V. Malyshev, Candidate of Sciences (Engineering), Associate Professor at the Department of Software Engineering, Southwest State University, Kursk, Russian Federation, e-mail: alta76@yandex.ru, ORCID: 0000-0002-9938-3456

Брежнев Алексей Викторович, кандидат технических наук, доцент, Российский экономический университет имени Г. В. Плеханова, г. Москва, Российская Федерация, e-mail: brezhnev.av@rea.ru, ORCID: 0000-0002-3679-7379

Alexey V. Brezhnev, Candidate of Sciences (Engineering), Associate Professor, Plekhanov Russian University of Economics, Moscow, Russian Federation, e-mail: brezhnev.av@rea.ru, ORCID: 0000-0002-3679-7379

Диагностика подагры на основе градиентного анализа

М. В. Бобырь¹✉, О. Г. Супрунова¹

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: maxbobyry@gmail.com

Резюме

Цель исследования – разработка и анализ метода распознавания подагры на ранних стадиях за счёт автоматизированного выявления второго контура на рентгеновских снимках с использованием модифицированного алгоритма Канни и градиентного анализа изображения.

Метод. Предложенный подход сочетает классические методы обработки изображений и современные техники компьютерного зрения. Изображение переводится в оттенки серого, фильтруется по Гауссу, после чего вычисляются горизонтальный и вертикальный градиенты. На их основе определяются модуль и направление общего градиента; нормализация позволяет выделить контрастные участки, а анализ угла градиента позволяет обнаружить характерные для отложений моноурата натрия изменения яркости. Пороговая сегментация, основанная на величине и направлении градиента, используется для классификации зон – субхондральной кости и патологических изменений.

Результаты. Экспериментальные исследования показали, что выделенная зелёная область на распознанном изображении соответствует стабильному градиенту субхондральной кости, тогда как красная область на изображении соответствует хаотичным и резким изменениям, указывающим на кристаллические отложения. Предложенный метод обнаружения подагры в статье продемонстрировал высокую чувствительность даже при слабо выраженных признаках заболевания. Разработана программная модель, обеспечивающая автоматическую обработку и визуализацию результатов диагностики подагры.

Заключение. Предложенный метод эффективно выявляет вторые контуры, характерные для подагры, и позволяет интерпретировать как интенсивность, так и направление градиентов. Это открывает перспективы для ранней диагностики, когда традиционные подходы недостаточно информативны. В дальнейшем планируется автоматизация пороговой настройки и интеграция метода в системы машинного обучения.

Ключевые слова: подагра; градиентный анализ; второй контур; компьютерное зрение; медицинская визуализация; автоматическая диагностика.

Финансирование: Статья подготовлена в рамках государственного задания № 075-03-2025-526.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Бобырь М. В., Супрунова О. Г. Диагностика подагры на основе градиентного анализа // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 148–163. [https://doi.org/ 10.21869/2223-1536-2026-16-1-148-163](https://doi.org/10.21869/2223-1536-2026-16-1-148-163)

Поступила в редакцию 12.01.2026

Подписана в печать 11.02.2026

Опубликована 31.03.2026

Gout diagnosis based on gradient analysis

Maxim V. Bobyr¹✉, Olga G. Suprunova¹

¹ Southwest State University

50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: maxbobyry@gmail.com

Abstract

The purpose of the research is development and analysis of a method for early-stage gout recognition through automated detection of the second contour in radiographic images using a modified Canny algorithm and gradient-based image analysis.

Methods. The proposed approach integrates classical image processing techniques with modern computer vision methods. The input image is converted to grayscale and smoothed using a Gaussian filter. Horizontal and vertical gradients are then computed, enabling the calculation of the gradient magnitude and direction. Normalization enhances contrast in salient regions, while angular gradient analysis reveals brightness variations characteristic of monosodium urate crystal deposits. Threshold-based segmentation, guided by both gradient magnitude and orientation, is employed to classify regions into subchondral bone and pathological alterations.

Results. Experimental studies demonstrated that the green-highlighted region in the processed image corresponds to the stable gradient of subchondral bone, whereas the red-highlighted region reflects abrupt and chaotic gradient changes indicative of crystal deposits. The proposed gout detection method exhibited high sensitivity even in cases with subtle clinical manifestations. A software model was developed to enable fully automated image processing and visualization of diagnostic results.

Conclusion. The method effectively identifies second contours associated with gout and enables simultaneous interpretation of both gradient intensity and orientation. This capability offers significant promise for early diagnosis when conventional approaches lack sufficient informativeness. Future work will focus on automating threshold selection and integrating the technique into machine learning frameworks.

Keywords: gout; gradient analysis; second contour; computer vision; medical imaging; automated diagnosis.

Funding: The article was prepared within the framework of the state assignment No. 075-03-2025-526.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Bobyr M.V., Suprunova O.G. Gout diagnosis based on gradient analysis. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(1):148–163. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-148-163>

Received 12.01.2026

Accepted 11.02.2026

Published 31.03.2026

Введение

Подагра – хроническое заболевание, связанное с нарушением обмена пуринов и накоплением кристаллов мочевой кислоты в суставах, что приводит к воспалению и болевому синдрому. Традиционные методы диагностики подагры включают клинический осмотр, лабораторные анализы (например, определение уровня мочевой кислоты в крови) и рентгенографию. Однако эти подходы могут быть недостаточно точными на ранних стадиях или требуют значительных временных и финансовых затрат. В последние годы методы компьютерного зрения активно применяются для автоматизации диагностики заболеваний, включая подагру, благодаря их способности анализировать медицинские изображения с высокой точностью и скоростью.

Существующие исследования в области распознавания и классификации подагры с использованием компьютерного зрения сосредоточены на обработке рентгеновских снимков, ультразвуковых изображений и фотографий пораженных суставов. Одним из первых подходов было использование традиционных алгоритмов обработки изображений, таких как выделение контуров и анализ текстур. Например, в работе [1] предложен метод сегментации изображений на основе нейронных сетей. Однако такие методы ограничены в точности диагностики подагры из-за сложности структуры тканей и шумов на изображениях.

С развитием глубокого обучения (deep learning) подходы к диагностике медицинских диагнозов значительно эволюционировали. В исследовании [2] применялись сверточные нейронные сети (CNN) для классификации рентгеновских снимков на наличие медицинских диагнозов. Авторы использовали архитектуры, такие как ResNet и VGG [3], обученные на наборах данных медицинских изображений, что позволило достичь точности классификации до 85%. Аналогичный подход описан в [4], где CNN применялась для анализа ультразвуковых изображений, выявляя гиперэхогенные включения, характерные для отложений кристаллов.

Другие исследования сосредоточились на мультимодальном анализе. Например, в работе [5] предложено сочетание рентгеновских и ультразвуковых данных с использованием сетей типа U-Net для сегментации и последующей классификации биожидкостной поверхности, что улучшило распознавание и выставление диагноза. В [6] исследовалась возможность интеграции клинических данных (уровень мочевой кислоты) с визуальными признаками, что повысило точность диагностики до 90%.

Методы, основанные на трансформерах (Vision Transformers, ViT), также начали применяться в этой области. В [7] описан подход с использованием ViT для анализа рентгеновских изображений суставов, демонстрирующий устойчивость к шумам и вариациям качества данных. В то же время альтерна-

тивные подходы, основанные на нечёткой логике, позволяют обеспечить интерпретируемость решений и устойчивость при работе с неполными или зашумлёнными данными, что особенно актуально в условиях ограниченных вычислительных ресурсов [8].

Для повышения точности распознавания подагры активно исследуются методы предобработки изображений. В [9] предложено применение гауссова размытия и нормализации для устранения шумов в фильтре Канни [10], что улучшило качество последующей сегментации. Аналогичный подход с адаптивной фильтрацией описан в [11]. В [12] исследовалась роль выделения градиентов для анализа скорости изменения яркости, что позволило точнее определять границы отложений кристаллов.

Несмотря на прогресс, существующие методы сталкиваются с рядом проблем: недостаток больших размеченных наборов данных, сложность интерпретации результатов и высокие вычислительные затраты. В работе [13] подчеркивается необходимость разработки стандартизированных баз данных медицинских изображений. Аналогичный вывод содержится в исследованиях [14] и [15]. Авторы [16] отмечают важность оптимизации моделей для работы на устройствах с ограниченными ресурсами, таких как мобильные системы диагностики. Схожая задача обсуждается также в работе [17].

Перспективным направлением является использование генеративных

моделей, таких как GAN (Generative Adversarial Networks), для синтеза данных. В [18] предложен метод генерации синтетических снимков для задач линейной регрессии, что позволяет увеличить объем тренировочных данных. Аналогичный подход с применением диффузионных моделей описан в [19]. Кроме того, в [20] и [21] исследовалась возможность медицинской диагностики в реальном времени с использованием Edge AI.

Настоящая работа предлагает новый подход к распознаванию подагры на основе анализа второго контура с использованием градиентных методов и углов градиента. Предложенная методика сочетает традиционные алгоритмы обработки изображений с современными достижениями глубокого обучения, что позволяет повысить точность и автоматизировать процесс диагностики. В отличие от предыдущих исследований наш метод фокусируется на интерпретации скорости изменения яркости и направления градиентов, что может улучшить выявление патологических изменений на ранних стадиях.

Материалы и методы

Метод вычисления углов градиента состоит из последовательного выполнения следующих восьми шагов:

1. *Загрузка изображения.* Исходное цветное изображение представлено как трёхмерный массив:

$$I(x, y) = [R(x, y), G(x, y), B(x, y)],$$

где $R(x, y)$ – значение красного канала; $G(x, y)$ – значение зелёного канала; $B(x, y)$ – значение синего канала; x, y – координаты пикселя. Этот массив задаёт интенсивность цвета в каждой точке изображения.

2. *Преобразование в градации серого*. Цветное изображение преобразуется в оттенки серого по формуле

$$I_{gray}(x, y) = 0,299 \cdot R(x, y) + 0,587 \cdot G(x, y) + 0,114 \cdot B(x, y),$$

$$I_{blurred}(x, y) = \sum_{i=-2}^2 \sum_{j=-2}^2 I_{gray}(x + i, y + j) \cdot K_{gauss}(i + 2, j + 2),$$

где $I_{blurred}(x, y)$ – значение пикселя после размытия; K_{gauss} – нормализованная матрица размером 5×5 , заданная как

$$K_{gauss} = \frac{1}{159} \begin{bmatrix} 2 & 4 & 5 & 4 & 2 \\ 4 & 9 & 12 & 9 & 4 \\ 5 & 12 & 15 & 12 & 5 \\ 4 & 9 & 12 & 9 & 4 \\ 2 & 4 & 5 & 4 & 2 \end{bmatrix}.$$

$$g_y(x, y) = \sum_{i=-1}^1 \sum_{j=-1}^1 I_{blurred}(x + i, y + j) \cdot K_{vertical}(i + 1, j + 1),$$

где $g_y(x, y)$ – значение вертикального градиента. Этот градиент показывает скорость изменения яркости по вертикали: большие значения указывают на резкие переходы, например, от светлого к тёмному.

$$g_x(x, y) = \sum_{i=-1}^1 \sum_{j=-1}^1 I_{blurred}(x + i, y + j) \cdot K_{horizontal}(i + 1, j + 1),$$

где $I_{gray}(x, y)$ – значение яркости пикселя в градациях серого. Коэффициенты отражают восприятие человеческим глазом различных цветов: зелёный имеет наибольший вес, так как глаз наиболее чувствителен к нему.

3. *Размытие с использованием ядра Гаусса*. Для размытия применяется свёртка изображения $I_{gray}(x, y)$ с нормализованным ядром Гаусса K_{gauss} размером 5×5 :

Размытие уменьшает шум и мелкие детали, что упрощает последующее выделение контуров.

4. *Вычисление вертикального градиента (g_y)*. Вертикальный градиент вычисляется с помощью свёртки с ядром:

$$K_{vertical} = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}.$$

Формула для вертикального градиента:

5. *Вычисление горизонтального градиента (g_x)*. Горизонтальный градиент вычисляется с помощью свёртки с ядром:

$$K_{horizontal} = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}.$$

Формула для горизонтального градиента:

где $g_x(x, y)$ – значение горизонтального градиента. Он отражает скорость изменения яркости по горизонтали.

6. *Вычисление общего градиента (g)*. Общий градиент вычисляется как модуль вектора градиента:

$$g(x, y) = \sqrt{g_x(x, y)^2 + g_y(x, y)^2}.$$

Общий градиент $g(x, y)$ объединяет информацию о горизонтальных и вертикальных изменениях, показывая общую интенсивность перехода в данной точке изображения.

7. *Нормализация общего градиента*. Для отображения общего градиента его значения нормализуются в диапазон $[0, 255]$:

$$g_{normalized}(x, y) = \frac{g(x, y) - g_{\min}}{g_{\max} - g_{\min}} \cdot 255,$$

где $g_{\min}$ и $g_{\max}$ – минимальное и максимальное значения $g(x, y)$ на изобра-

жении; $g_{normalized}(x, y)$ – нормализованное значение градиента. Нормализация позволяет визуализировать градиент в привычном диапазоне яркости.

8. *Вычисление угла градиента (θ)*. Для анализа направления изменений яркости вычисляется угол градиента по формуле

$$\theta(x, y) = \text{round} \left(\arctan \left(\frac{g_y(x, y)}{g_x(x, y)} \right) \right),$$

где $\theta(x, y)$ – угол градиента в радианах, округлённый до ближайшего целого числа после преобразования; $\arctan$ – функция арктангенса, определяющая угол между горизонтальной осью и вектором градиента; $g_y(x, y)$ и $g_x(x, y)$ – вертикальный и горизонтальный градиенты соответственно. Чтобы избежать деления на ноль, используется модификация:

$$\theta(x, y) = \begin{cases} \text{round} \left(\arctan \left(\frac{g_y(x, y)}{g_x(x, y)} \right) \right), & \text{если } g_x(x, y) \neq 0, \\ \text{round} \left(\frac{\pi}{2} \right), & \text{если } g_x(x, y) = 0 \text{ и } g_y(x, y) > 0, \\ \text{round} \left(-\frac{\pi}{2} \right), & \text{если } g_x(x, y) = 0 \text{ и } g_y(x, y) < 0. \end{cases}$$

Угол θ интерпретируется следующим образом:

- 0: стрелка вправо ($\rightarrow$);
- 1: стрелка вверх-вправо ($\leftrightarrow$);
- 2: стрелка вверх ($\uparrow$);
- 3: стрелка вверх-влево ($\nwarrow$);
- 4: стрелка влево ($\leftarrow$);
- 1: стрелка вниз-вправо ($\searrow$);
- 2: стрелка вниз ($\downarrow$);
- 3: стрелка вниз-влево ($\swarrow$).

Угол градиента показывает направление максимального изменения яркости. Например, если $\theta = 0$, изменение происходит горизонтально вправо, что может указывать на вертикальный контур.

Скорость изменения яркости связана с величиной градиента $g(x, y)$. Если значения яркости в соседних пикселях, например $I_{gray} = [255, 255, 255, 255]$, то

g_x и g_y близки к нулю, а $g(x, y) \approx 0$, что означает отсутствие изменений (например, белая область, интерпретируемая как кость). Если же наблюдается резкий скачок, например $I_{gray} = [255, 255, 30, 30]$, то g_x или g_y будут иметь большие значения, а $g(x, y)$ укажет на высокую скорость изменения. В сочетании с анализом θ это может выявить второй контур, указывающий на возможное наличие подагры: резкий переход в яркости и смена направления градиента могут соответствовать воспалённым тканям или отложениям.

Результаты и их обсуждение

В рамках эксперимента было использовано исходное изображение `original.jpg`, представляющее собой рентгеновский снимок сустава, на котором предполагается наличие признаков подагры. Целью анализа является выделение контуров и углов градиента для выявления субхондральной кости и возможных отложений кристаллов моноурата натрия, характерных для подагры. Обработка изображения выполнялась в соответствии с описанной математической моделью и реализованным алгоритмом.

Ниже представлен псевдокод алгоритма обработки изображений для выявления признаков подагры:

Algorithm ImageProcessingForGoutDetection

Input: `original_image` (RGB изображение)

Output: `gradient_directionP` (изображение с выделенными зонами)

1. Load `original_image` as $I(x, y) = [R(x, y), G(x, y), B(x, y)]$.
2. For each pixel (x, y) :

$$\text{gray_image}(x, y) = 0.299 \times R(x, y) + 0.587 \times G(x, y) + 0.114 \times B(x, y).$$
3. Define `gaussian_kernel` = $(1/159) \times [[2, 4, 5, 4, 2], [4, 9, 12, 9, 4], [5, 12, 15, 12, 5], [4, 9, 12, 9, 4], [2, 4, 5, 4, 2]]$ and

$$\text{blurred_image} = \text{Convolve}(\text{gray_image}, \text{gaussian_kernel}).$$
4. Define `horizontal_kernel` = $[[-1, -2, -1], [0, 0, 0], [1, 2, 1]]$ and

$$\text{gradient_x} = \text{Convolve}(\text{blurred_image}, \text{horizontal_kernel}).$$
5. Define `vertical_kernel` = $[[-1, 0, 1], [-2, 0, 2], [-1, 0, 1]]$ and

$$\text{gradient_y} = \text{Convolve}(\text{blurred_image}, \text{vertical_kernel}).$$
6. For each pixel (x, y) :

$$\text{gradient_magnitude}(x, y) = \sqrt{\text{gradient_x}(x, y)^2 + \text{gradient_y}(x, y)^2}$$
 and
 Normalize `gradient_magnitude` to $[0, 255]$
7. For each pixel (x, y) :
 If `gradient_x(x, y) ≠ 0`:

$$\text{gradient_direction}(x, y) = \text{round}(\arctan(\text{gradient_y}(x, y) / \text{gradient_x}(x, y)))$$
 Else: If `gradient_y(x, y) > 0`:

$$\text{gradient_direction}(x, y) = \text{round}(\pi / 2)$$

Else:

$\text{gradient_direction}(x, y) = \text{round}(-\pi / 2)$

8. $\text{gradient_directionP} = \text{gradient_direction}$

For each pixel (x, y) :

If region is subchondral bone: Color pixel green

Else If region has sharp gradient change: Color pixel red.

Return: $\text{gradient_directionP}$.

End Algorithm

В ходе обработки изображения были получены следующие промежуточные и итоговые результаты:

- во-первых, изображение преобразовано в оттенки серого, что позволило унифицировать цветовые каналы и упростить дальнейшую обработку. При этом яркость пикселей варьировалась от 0 (чёрный) до 255 (белый);

- во-вторых, применение ядра Гаусса сгладило мелкие детали и шумы, выделяя основные структуры, такие как кости и ткани;

- в-третьих, выявлены изменения яркости по горизонтали, при этом светлые области соответствуют резким переходам слева направо, тёмные – справа налево;

- в-четвертых, показаны изменения яркости по вертикали. Аналогично, светлые и тёмные области отражали направление переходов;

- в-пятых, комбинация горизонтального и вертикального градиентов подчеркнула интенсивность контуров, при этом значения, близкие к 255, указывали на резкие изменения яркости;

- в-шестых, направление изменений яркости визуализировано через углы (θ), где, например, $\theta = 0$ соответствует горизонтальному переходу вправо ($\rightarrow$);

- в-седьмых, на итоговом изображении были выделены две зоны: зелёная область соответствовала субхондральной кости (равномерные значения градиента); красная область – возможному второму контуру (резкие изменения градиента), что могло указывать на отложения кристаллов моноурата натрия.

Полученные в ходе эксперимента изображения представлены ниже (рис. 1).

Анализ контуров и углов градиента позволил выявить ключевые особенности изображения:

- в зелёной зоне (субхондральная кость, см. рис. 1, з) значения градиента $g(x, y)$ близки к нулю, а углы θ стабильны, что соответствует однородной структуре кости с минимальными изменениями яркости;

- в красной зоне (см. рис. 1, з) наблюдаются резкие скачки градиента (например, переход от 255 к 30), сопровождаемые сменой углов θ , что указывает на наличие второго контура. Это может быть связано с отложениями кристаллов моноурата натрия, характерными для подагры, так как такие переходы не типичны для нормальной костной ткани;

– сравнение направлений градиента (θ) между зонами подтверждает наличие аномалий: в крас-

ной зоне углы более хаотичны, что соответствует неоднородности тканей.




Рис. 1. Интерпертации обработки изображения: а – исходное изображение; б – преобразование в градации серого; в – размытие изображения; з – вычисление горизонтального градиента

Fig. 1. Image processing pipeline interpretation: а – original image; б – grayscale conversion, в – image blurring (smoothing); з – horizontal gradient computation




Рис. 1. Интерпертации обработки изображения: δ – вычисление вертикального градиента; e – вычисление общего градиента; $ж$ – вычисление угла градиента; $з$ – нахождение двойного контура (подагра)

Fig. 1. Image processing pipeline interpretation: δ – vertical gradient computation; e – total gradient magnitude calculation; $ж$ – gradient angle (orientation) computation; $з$ – double edge detection (gout)

Таким образом, сочетание величины градиента и его направления позволяет

дифференцировать нормальные структуры от патологических изменений.

Выводы

В ходе исследования был разработан и реализован алгоритм обработки рентгеновских изображений суставов, направленный на автоматизированное выявление признаков подагры на основе анализа градиентов и их направлений. Предложенный подход позволяет выделять субхондральную кость и вторые контуры, которые могут свидетельствовать о наличии отложений кристаллов моноурата натрия – характерного признака подагры. Метод включает этапы преобразования изображения в градации серого, фильтрации с использованием ядра Гаусса, вычисления горизонтального и вертикального градиентов, определения модуля и направления общего градиента, а также классификации зон по интенсивности и ориентации изменений яркости.

Экспериментальная часть подтвердила работоспособность метода: на тестовом изображении были успешно выделены две ключевые зоны — зелёная область, соответствующая стабильной костной ткани с равномерным градиентом и устойчивыми углами, и красная область, характеризующаяся резкими скачками градиента и хаотичностью его направления, что может указывать на патологические изменения, связанные с подагрой.

Предложенный метод демонстрирует высокую чувствительность к мелким изменениям структуры тканей и позволяет интерпретировать не только величину, но и направление градиентов, что особенно важно для дифференциальной диагностики. По сравнению с существующими подходами, основанными на глубоком обучении, данный метод не требует больших объемов размеченных данных и обеспечивает более прозрачную логику принятия решений, что делает его перспективным для использования в составе комплексной системы диагностики подагры.

В дальнейшем планируется усовершенствовать алгоритм за счет автоматической адаптации пороговых значений градиента, расширения набора диагностических признаков и интеграции с медицинскими информационными системами. Также предполагается проведение клинической верификации результатов на большем массиве рентгеновских снимков с подтвержденными диагнозами. Полученные результаты открывают возможности для создания программного обеспечения, предназначенного для поддержки врачебных решений и повышения точности диагностики подагры на ранних стадиях.

Список литературы

1. Емельянов А. В. Анализ методов семантической сегментации изображений на основе нейронных сетей // Математические методы в технике и технологиях – ММТТ. 2019. Т. 12-1. С. 195-201. EDN GCGRLL

2. Брянская Е. О. Возможности применения сверточных нейронных сетей для классификации состояний верхнечелюстных пазух при цифровой диафаноскопии // Фундаментальные и прикладные проблемы техники и технологии. 2022. № 6(356). С. 106-111. <https://doi.org/10.33979/2073-7408-2022-356-6-106-111>. EDN MBAOAV
3. Щетинин Е. Ю. Обнаружение коронавирусной инфекции COVID-19 на основе анализа рентгеновских снимков грудной клетки методами глубокого обучения // Компьютерная оптика. 2022. Т. 46, № 6. С. 963-970. <https://doi.org/10.18287/2412-6179-CO-1077>. EDN SJAPDT
4. Нгуен Т. К., Сырямкин В. И., Нгуен Ч. Х. Т. Модель метода распознавания объектов на изображениях с использованием «сверточной нейронной сети – CNN» // Современные наукоемкие технологии. 2020. № 12-2. С. 269-280. <https://doi.org/10.17513/snt.38445>
5. Семенов М. Е., Заблоцкая Т. Ю. Выбор модели биологической нейронной сети для сегментации изображения биожидкостной поверхности // Вестник КРАУНЦ. Физико-математические науки. 2019. Т. 26, № 1. С. 78-93. <https://doi.org/10.26117/2079-6641-2019-26-1-78-93>
6. Осмоловский И. С., Зарубина Т. В. Разработка и апробация прототипа экспертной системы для диагностики подагры // Социальные аспекты здоровья населения. 2023. Т. 69, № 4. <https://doi.org/10.21045/2071-5021-2023-69-4-15>. EDN OFVRSI
7. Суставной синдром у больного с подагрой и субклинической иерсиниозной инфекцией: сложности диагностики и лечения / Н. В. Воронина, В. Ю. Булкина, М. А. Ситников [и др.] // Дальневосточный медицинский журнал. 2024. № 3. С. 96-99. <https://doi.org/10.35177/1994-5191-2024-3-16>. EDN DVSLCT
8. Бобырь М. В., Кулабухов С. А. Моделирование процесса управления температурным режимом в зоне резания на основе нечеткой логики // Проблемы машиностроения и надежности машин. 2017. № 3. С. 76-82.
9. Маннаа А. С. Алгоритм обработки рентгеновских изображений с использованием нечеткой логики // Advanced Engineering Research (Rostov-on-Don). 2024. Т. 24, № 3. С. 293-300. <https://doi.org/10.23947/2687-1653-2024-24-3-293-300>
10. Разработка алгоритмов обработки изображений интеллектуальными мобильными роботами на основе нечеткой логики и нейронных сетей / Ч. Х. Аунг, З. П. Тант, А. Р. Федоров, П. А. Федоров // Современные проблемы науки и образования. 2014. № 6. С. 53.
11. Voskoboinikov Yu. E. A locally adaptive wavelet filtering algorithm for images // Analysis and Data Processing Systems. 2023. N 1(89). P. 25-36. <https://doi.org/10.17212/2782-2001-2023-1-25-36>
12. Баталов В. Г., Васильев А. Ю. Анализ яркости отраженного света для определения структурных изменений в потоке жидкости от распыливающего устройства //

Вестник Пермского университета. Физика. 2024. № 4. С. 72-77. <https://doi.org/10.17072/1994-3598-2024-4-72-77>. EDN NENIHN

13. Аннотированный анализ данных трехмерной оптической когерентной томографии сетчатки для создания интеллектуальной базы данных / Е. Ю. Малахова, Д. С. Мальцев, А. Н. Куликов, А. А. Казак // Оптический журнал. 2019. Т. 86, № 11. С. 59-65. <https://doi.org/10.17586/1023-5086-2019-86-11-59-65>. EDN DAEEX

14. Еремеев А. П., Ивлиев С. А. Разработка базы данных и конвертера для извлечения и анализа специализированных данных, получаемых с медицинского аппарата // Программные продукты и системы. 2019. № 3. С. 512-517. EDN GFELXG

15. Краснов Ф. В. Выявление ошибок разметки данных с помощью моделей классификации для небольших наборов данных // International Journal of Open Information Technologies. 2023. Vol. 11, N 5. P. 54-62. EDN KFACTJ

16. Петров Н. В., Смородин Д. А., Иванов Е. Р. Разработка прототипа мобильного приложения для выявления и анализа злокачественных новообразований кожи на основе компьютерного зрения // Chronos: мультидисциплинарные науки. 2022. Т. 7, № 11(73). С. 97-100.

17. Булыгина О. В., Кулясов Н. С., Ярцев Д. Д. Направления модификации алгоритма искусственной пчелиной семьи для оптимизации параметров управления сложными системами // Журнал прикладной информатики. 2024. Т. 19, № 1(109). С. 28-37. <https://doi.org/10.37791/2687-0649-2024-19-1-28-37>

18. Дергачев К. О. Генерация синтетических данных для задач линейной регрессии // Modern Economy Success. 2024. № 6. С. 383-388. <https://doi.org/10.58224/2500-3747-2024-6-383-388>. EDN MSNIJY

19. Родзин С. И., Родзина О. Н., Эль-Хатиб С. А. Гибридный муравьиный алгоритм сегментации медицинских изображений // Вестник Чувашского университета. 2017. № 3. С. 262-272.

20. Pinto-Coelho L. How Artificial Intelligence Is Shaping Medical Imaging Technology: A Survey of Innovations and Applications // Bioengineering. 2023. N 10(12). P. 1435. <https://doi.org/10.3390/bioengineering10121435>

21. Combined Edge Loss UNet for Optimized Segmentation in Total Knee Arthroplasty Preoperative Planning / L. Marsilio, A. Moglia, M. Rossi, A. Manzotti, L. Mainardi, P. Cerver // Bioengineering. 2023. N 10(12). P. 1433. <https://doi.org/10.3390/bioengineering1012143>

References

1. Yemelyanov A.V. Analysis of semantic image segmentation methods based on neural networks. *Matematicheskie metody v tekhnike i tekhnologiyakh – MMTT = Mathematical Methods in Engineering and Technology – MMTT*. 2019;12-1:195-201. (In Russ.) EDN GCGRLL

2. Bryanskaya E. O. Possibilities of using convolutional neural networks for classifying the states of the maxillary sinuses in digital diaphanoscopy. *Fundamental'nye i prikladnye problemy tekhniki i tekhnologii = Fundamental and Applied Problems of Engineering and Technology*. 2022;(6):106-111. (In Russ.) <https://doi.org/10.33979/2073-7408-2022-356-6-106-111>. EDN MBAOAV
3. Shchetinin E.Y. Detection of coronavirus infection COVID-19 based on the analysis of chest X-rays using deep learning methods. *Komp'yuternaya optika = Computer Optics*. 2022;46(6):963-970. (In Russ.) <https://doi.org/10.18287/2412-6179-CO-1077>. EDN SJAPDT
4. Nguyen T.K., Syryamkin V.I., Nguyen C.H.T. A model of the object recognition method in images using a «convolutional neural network – CNN». *Sovremennye naukoemkie tekhnologii = Modern High-Tech Technologies*. 2020;(12-2):269-280. (In Russ.) <https://doi.org/10.17513/snt.38445>
5. Semenov M.E., Zablotskaya T.Y. The choice of a biological neural network model for image segmentation of a biofluidic surface. *Vestnik KRAUNTS. Fiziko-Matematicheskie nauki = Bulletin of KRAUNTS. Physical and Mathematical Sciences*. 2019;26(1):78-93. (In Russ.) <https://doi.org/10.26117/2079-6641-2019-26-1-78-93>
6. Osmolovsky I.S., Zarubina T.V. Development and testing of a prototype expert system for the diagnosis of gout. *Sotsial'nye aspekty zdorov'ya naseleniya = Social Aspects of Public Health*. 2023;69(4). (In Russ.) <https://doi.org/10.21045/2071-5021-2023-69-4-15>. EDN OFVRSI
7. Voronina N.V., Bulkina V.Y., Sitnikov M.A., et al. Joint syndrome in a patient with gout and subclinical yersiniosis infection: difficulties of diagnosis and treatment. *Dal'nevostochnyi meditsinskii zhurnal = Far Eastern Medical Journal*. 2024;(3):96-99. (In Russ.) <https://doi.org/10.35177/1994-5191-2024-3-16>. EDN DVSLCT
8. Bobyr M.V., Kulabukhov S.A. Modeling the process of controlling the temperature regime in the cutting zone based on fuzzy logic. *Problemy mashinostroeniya i nadezhnosti mashin = Problems of Mechanical Engineering and Machine Reliability*. 2017;(3):76–82. (In Russ.)
9. Mannaa A.S. Algorithm for processing X-ray images using fuzzy logic. *Advanced Engineering Research (Rostov-on-Don)*. 2024;24(3):293-300. (In Russ.) <https://doi.org/10.23947/2687-1653-2024-24-3-293-300>
10. Aung C.H., Tant Z.P., Fedorov A.R., Fedorov P.A. Development of image processing algorithms by intelligent mobile robots based on fuzzy logic and neural networks. *Sovremennye problemy nauki i obrazovaniya = Modern Problems of Science and Education*. 2014;(6):53. (In Russ.)
11. Voskoboinikov Yu.E. A locally adaptive wavelet filtering algorithm for images. *Analysis and Data Processing Systems*. 2023;(1):25-36. <https://doi.org/10.17212/2782-2001-2023-1-25-36>

12. Batalov V.G., Vasiliev A.Y. Reflected light brightness analysis to determine structural changes in the flow of liquid from a spraying device. *Vestnik Permskogo universiteta. Fizika = Bulletin of the Perm University. Physics*. 2024;(4):72-77. (In Russ.) <https://doi.org/10.17072/1994-3598-2024-4-72-77>. EDN NENIHN
13. Malakhova E.Y., Maltsev D.S., Kulikov A.N., Kazak A.A. Annotated data analysis of three-dimensional optical coherence tomography of the retina for creating an intelligent database. *Opticheskii zhurnal = Optical Journal*. 2019;86(11):59-65. (In Russ.) <https://doi.org/10.17586/1023-5086-2019-86-11-59-65>. EDN DAEEX
14. Ereemeev A.P., Ivliev S.A. Development of a database and converter for extracting and analyzing specialized data obtained from a medical device. *Programmnye produkty i sistemy = Software Products and Systems*. 2019;(3):512-517. (In Russ.) EDN GFELXG
15. Krasnov F.V. Identification of data markup errors using classification models for small datasets. *International Journal of Open Information Technologies = International Journal of Open Information Technologies*. 2023;11(5):54-62. (In Russ.) EDN KFACTJ
16. Petrov N.V., Smorodin D.A., Ivanov E.R. Development of a prototype of a mobile application for the detection and analysis of skin malignancies based on computer vision. *Chronos: mul'tidistsiplinarnye nnauki = Chronos: Multidisciplinary Sciences*. 2022;7(11):97-100. (In Russ.)
17. Bulygina O.V., Kulyasov N.S., Yartsev D.D. Directions for modifying the artificial bee colony algorithm to optimize control parameters for complex systems. *Zhurnal prikladnoi informatiki = Journal of Applied Informatics*. 2024;19(1):28-37. (In Russ.) <https://doi.org/10.37791/2687-0649-2024-19-1-28-37>
18. Dergachev K.O. Generation of synthetic data for linear regression problems. *Modern Economy Success*. 2024;(6):383-388. (In Russ.) <https://doi.org/10.58224/2500-3747-2024-6-383-388>. EDN MSNIJY
19. Rodzin S.I., Rodzina O.N., El-Hatib S.A. Hybrid segmentation ant algorithms of medical images. *Vestnik Chuvashskogo universiteta = Bulletin of the Chuvash State University*. 2017;(3):262-272. (In Russ.)
20. Pinto-Coelho L. How Artificial Intelligence Is Shaping Medical Imaging Technology: A Survey of Innovations and Applications. *Bioengineering*. 2023;(10):1435. <https://doi.org/10.3390/bioengineering10121435>
21. Marsilio L., Moglia A., Rossi M., Manzotti A., Mainardi L., Cerver P. Combined Edge Loss UNet for Optimized Segmentation in Total Knee Arthroplasty Preoperative Planning. *Bioengineering*. 2023;(10):1433. <https://doi.org/10.3390/bioengineering1012143>

Информация об авторах / Information about the Authors

Бобырь Максим Владимирович, доктор технических наук, профессор кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: fregat_mn@rambler.ru,
Researcher ID: G-2604-2013,
ORCID: 0000-0002-5400-6817

Maxim V. Bobyr, Doctor of Sciences (Engineering), Professor of the Software Engineering Department, Southwest State University, Kursk, Russian Federation,
e-mail: fregat_mn@rambler.ru,
Researcher ID: G-2604-2013,
ORCID: 0000-0002-5400-6817

Супрунова Ольга Геннадьевна, аспирант кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: dlya.dela2010@yandex.ru,
ORCID: 0009-0005-8340-0919

Olga G. Suprunova, Postgraduate at the Department of Software Engineering, Southwest State University, Kursk, Russian Federation,
e-mail: dlya.dela2010@yandex.ru,
ORCID: 0009-0005-8340-0919

<https://doi.org/10.21869/2223-1536-2026-16-1-164-173>

УДК 615.47

Анализ и разработка вязкоупругой модели биотканей для оценки их нелинейных свойств

М. В. Лагута¹✉, Д. А. Кравчук¹¹ Южный федеральный университет

ул. Шевченко, д. 2/Е, Ростовская область, г. Таганрог 347922, Российская Федерация

✉ e-mail: laguta@sfedu.ru

Резюме

Целью исследования является анализ существующих вязкоупругих моделей биологических тканей, учитывающих как физическую, так и геометрическую нелинейности процессов деформации при распространении поперечных акустических волн.

Методы. Акустическая эластография представляет собой группу методов, основанных на анализе процессов взаимодействия низкочастотных поперечных акустических волн с биологическими тканями. Физической основой таких методов являются вязкоупругие модели биотканей, учитывающие изменение параметров их деформации при воздействии на них силы с переменной амплитудой и направлением. Учет нелинейности процессов деформации биологических тканей при распространении поперечных акустических волн позволит ввести новую информативную характеристику для анализа процессов их структурных изменений – нелинейный параметр. Одновременный учет линейных и нелинейных свойств биотканей позволит повысить качество диагностики заболеваний, протекающих в организме человека, в том числе на ранних стадиях. В рамках исследования были проведен анализ двухэлементной вязкоупругой модели биотканей, позволяющих учитывать как физическую нелинейность, так и линейные характеристики. Также рассмотрены модель, позволяющая учитывать геометрическую нелинейность процессов деформации и процессы деформации моделей при изменении параметров воздействующей силы.

Результаты. Предложена вязкоупругая модель биологических тканей, позволяющая учитывать как физическую, так и геометрическую нелинейность. Выведены основные математические выражения, описывающие данную модель. Получены результаты математического моделирования процессов деформации разработанной вязкоупругой модели при изменении воздействующей силы и модели, учитывающей только физическую нелинейность.

Заключение. Предложенная математическая модель позволяет учитывать отклонении процессов деформации биотканей от линейных законов как за счет физической, так и геометрической нелинейности. Применение такой модели позволит повысить точность оценки процессов взаимодействия низкочастотного акустического излучения с биологическими тканями, что может быть использовано для разработки новых высокоточных методов оценки процессов их изменения при протекающих заболеваниях, в том числе на ранних стадиях.

Ключевые слова: эластография; акустический нелинейный параметр; свойства биоткани.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Лагута М. В., Кравчук Д. А. Анализ и разработка вязкоупругой модели биотканей для оценки их нелинейных свойств // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 164–173. <https://doi.org/10.21869/2223-1536-2026-16-1-164-173>

Поступила в редакцию 21.01.2026

Подписана в печать 20.02.2026

Опубликована 31.03.2026

Analysis and development of a viscoelastic model of biological tissues to assess their nonlinear properties

Margarita V. Laguta¹✉, Denis A. Kravchuk¹

¹ Southern Federal University

2/E Shevchenko Str., Rostov region, Taganrog 347922, Russian Federation

✉ e-mail:

Abstract

The purpose of the research is to analyze existing viscoelastic models of biological tissues to develop a model that takes into account the nonlinearity of deformation processes during the propagation of transverse acoustic waves.

Methods. Acoustic elastography is a group of methods based on the analysis of the interaction of low-frequency transverse acoustic waves with biological tissues. The physical basis of such methods are viscoelastic models of biological fabrics that take into account changes in their deformation parameters when they are subjected to forces with variable amplitude and direction. Taking into account the nonlinearity of the processes of deformation of biological tissues during the propagation of transverse acoustic waves will allow us to introduce a new informative characteristic for analyzing the processes of their structural changes – a nonlinear parameter. Simultaneous consideration of linear and nonlinear properties of biological tissues will improve the quality of diagnosis of diseases occurring in the human body, including in the early stages. As part of the study, a two-element viscoelastic model of biological tissues was analyzed, allowing for both physical nonlinearity and linear characteristics. A model is also considered that allows taking into account the geometric nonlinearity of the deformation processes and the deformation processes of the models when changing the parameters of the acting force.

Results. We have proposed a viscoelastic model of biological tissues that accounts for both physical and geometric nonlinearity. The key mathematical expressions describing this model have been derived. Results have been obtained from mathematical modeling of deformation processes for the developed viscoelastic model under varying applied forces and for a model that accounts only for physical nonlinearity.

Conclusion. The proposed mathematical model allows for the deviation of biological tissue deformation processes from linear laws due to both physical and geometric nonlinearity. Application of this model will improve the accuracy of assessing the interaction of low-frequency acoustic radiation with biological tissue, which can be used to develop new, high-precision methods for assessing tissue changes during ongoing diseases, including in the early stages.

Keywords: elastography; acoustic nonlinear parameter; properties of biological tissue.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Laguta M.V., Kravchuk D.A. Analysis and development of a viscoelastic model of biological tissues to assess their nonlinear properties. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(1):164–173. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-164-173>

Received 21.01.2026

Accepted 20.02.2026

Published 31.03.2026

Введение

Большое количество заболеваний, протекающих в организме человека, сопровождаются структурными изменениями органов и тканей. Чаще всего происходит замещение функциональных клеток фиброзной или жировой тканью [1]. Возникающие при этом новообразования (даже доброкачественного характера) могут со временем переходить в злокачественную форму [2]. Наиболее точным способом оценки типа изменений биотканей является биопсия, которая предполагает забор пробы с выбранного участка тела человека. Однако ввиду небезопасности метода важной задачей является разработка неинвазивных высокоточных методов диагностики, позволяющих диагностировать эти изменения на ранних стадиях заболеваний [3]. Акустическая эластография может стать путем решения данной проблемы, однако ввиду того, что большинство существующих методов ограничиваются принципами линейной акустики, их точность ограничена [4].

В основе данной группы методов лежат физические модели биотканей, позволяющие оценивать изменение процессов их деформации при воздействии механических сил с различными параметрами, в зависимости от их вязкоупругих свойств [5]. Повышение информативности и точности методов эластографии возможно за счет введения в линейные вязкоупругие модели нелинейных поправок, позволяющих получать новые информационные ха-

рактеристики биотканей, такие как нелинейный параметр [6].

Материалы и методы

Ранее проведенный анализ линейных вязкоупругих моделей показал, что при разработке метода исследования вязкоупругих свойств биотканей на основе распространения упругой низкочастотной акустической волны наибольший интерес представляет собой модель, в которой деформация больше всего зависит от величины жесткости упругого элемента по сравнению с текучестью [7]. Связано это в первую очередь с тем, что к таким тканям относятся злокачественные опухоли [8]. Также стоит отметить, что для учета физической нелинейности достаточно остановиться на двухэлементной модели, так как повышение числа элементов в этом случае может привести к возникновению дополнительных ошибок при введении нелинейных поправок. Всем этим условиям удовлетворяет модель Кельвина – Фойгта (рис. 1).




Рис. 1. Модель Кельвина – Фойгта [9]

Fig. 1. Kelvin – Voigt model [9]

Далее мы будем говорить о нелинейных эффектах, возникающих при распространении низкочастотных поперечных волн в биотканях. В модели, отражающей зависимость деформации от

напряжений, необходимо учесть ее нелинейность [10].

Согласно этому модель Кельвина – Фойгта с учетом физической нелинейности будет описываться выражением [11]:

$$F_k = \left(K (l - l_0) - K\Gamma (l - l_0)^2 \right) + H \frac{dl}{dt} = (k\varepsilon - k\Gamma \varepsilon^2) + \eta \frac{d\varepsilon}{dt}, \quad (1)$$

где $K\Gamma (l - l_0)^2$ – член, отражающий нелинейность деформации упругого элемента; Γ – нелинейный параметр среды, обусловленный физической нелинейностью [12].

При этом важно понимать, что в нелинейность процессов распространения низкочастотных акустических волн также вносят вклад особенности геометрического строения клеток, что приводит к возникновению так называемой геометрической нелинейности [13].

Для учета поправки, вносимой геометрической нелинейностью, нами была предложена модель, представленная ниже (рис. 2).




Рис. 2. Вязкоупругая модель с учетом геометрической и физической нелинейности

Fig. 2. Viscoelastic model taking into account geometric and physical nonlinearity

Учет геометрической нелинейности в системе, представленной на рисунке 1, происходит за счет введения двух

упругих элементов с разной жесткостью, соединенных двумя жесткими пластинами под разными углами [14].

Такое дополнение системы позволяет также учитывать нелинейность деформации в различных направлениях [15]. Это приводит к тому, что при горизонтальном смещении изменение длины пружины, соединенной с пластиной под углом α_i , равно [16]:

$$\Delta l_i = x \cos(\alpha_i). \quad (2)$$

При этом горизонтальная проекция силы в пружине находится согласно выражению

$$F_{i,x} = F_i \cos(\alpha_i) = K_i x \cos^2(\alpha_i). \quad (3)$$

Эквивалентная жесткость для двух пружин, соединенных под разными углами, определяется согласно выражению

$$K_{\text{экв}} = K_1 \cos^2(\alpha_1) + K_2 \cos^2(\alpha_2), \quad (4)$$

где α_1 и α_2 – углы, под которыми соединены первая и вторая пружины соответственно.

В этом случае уравнение, описывающее модель, выглядит следующим образом:

$$F_k = (K_1 \cos^2(\alpha_1) + K_2 \cos^2(\alpha_2)) \times ((l - l_0) - \Gamma (l - l_0)^2) + H \frac{dl}{dt} = (k_1 \cos^2(\alpha_1) + k_2 \cos^2(\alpha_2))(\varepsilon - \Gamma \varepsilon^2) + \eta \frac{d\varepsilon}{dt}. \quad (5)$$

Полученные соотношения позволяют оценить нелинейность изменения деформации при изменении параметров воздействующей силы [17].

Результаты и их обсуждение

Из уравнений (2) и (5) можно отметить, что учет нелинейности, связанной с физическими и геометрическими особенностями биотканей, происходит в члене уравнения, отражающем деформацию упругого элемента [18]. Поэтому для сравнения процессов деформации с учетом нелинейных эффектов и без целесообразно рассмотреть процесс деформации именно упругого элемента [19].

На рисунке 3 представлены результаты математического моделирования изменения величины деформации упругого элемента в зависимости от величины воздействующей силы F для случая с учетом только физической нелинейности, с физической и геометрической нелинейностью и без учета нелинейности процесса, при следующих параметрах системы: $K_1 = 2$, $K_2 = 3$, $\alpha_1 = 45/\pi$, $\alpha_2 = 50/\pi$, $\Gamma = 5$ [20].

Согласно полученным результатам для линейной модели с заданными выше параметрами деформация увеличивается в 2 раза при увеличении амплитуды воздействующей силы в 4 раза, для нелинейных моделей наблюдается значительная меньшая деформация. Так для модели с физической нелинейностью это изменение составило около 10%, а для модели, также учитывающей геометрическую нелинейность, – 8%. Это говорит о том, что в реальных случаях, где присутствует нелинейность, деформация будет нарастать значительно медленнее по сравнению с увеличением прикладываемой силы, что важно

учитывать при оценке процессов распространения поперечных низкочастотных волн.




Рис. 3. Изменение величины деформации при изменении величины воздействующей силы: 1 – деформация упругого элемента без учета нелинейности; 2 – с учетом физической нелинейности; 3 – с учетом физической и геометрической нелинейности процесса

Fig. 3. Change in deformation value when the applied force changes: 1 – deformation of the elastic element without taking into account the nonlinearity; 2 – taking into account the physical nonlinearity, 3 – taking into account the physical and geometric nonlinearity of the process

Выводы

Полученные результаты показали, что введение, кроме нелинейного параметра Γ , поправки, отражающей геометрическую нелинейность в уравнение (1), позволяет оценивать, помимо временной задержки деформации (что учитывается вязким элементом), также более точно учитывать нелинейность изменения ее амплитуды при изменении амплитуды силы воздействия.

Как результат – такое описание модели Кельвина – Фойгта позволяет более точно оценивать изменения вязкоупругих свойств биотканей по сравнению с линейной моделью.

Список литературы

1. Диагностика фиброза печени: акцент на эластографию / И. И. Жирков, А. В. Гордиенко, И. М. Павлович, Б. А. Чумак, В. В. Яковлев // Экспериментальная и клиническая гастроэнтерология. 2021. № 194 (10). С. 72-81.
2. Беляева А. В., Беляева О. А., Розинов В. М. Диагностический потенциал ультразвуковой эластографии у пациентов с хирургическими заболеваниями и травмами // Российский вестник детской хирургии, анестезиологии и реаниматологии. 2023. Т. 13, № 3. С. 373–384. <https://doi.org/10.17816/psaic1523>
3. Эффективность эластографии сдвиговой волной в оценке поражения печени у пациентов с постковидным синдромом / В. Н. Диомидова, Е. А. Разбанина, О. Н. Валеева, Л. Н. Васильева // Acta medica eurasica. 2022. № 3. С. 99–113.
4. Кравчук Д. А., Чернов Н. Н., Михралиева А. И. Аналитическое моделирование эластографии молочной железы // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 1. С. 104-113.
5. King's College London. New research explores non-invasive MR elastography as an alternative to liver biopsy in obese patients // Medical Xpress. 2023. P. 104-113. <https://doi.org/10.21869/2223-1536-2024-14-1-104-113>. EDN SHBQKL
6. Шевкина С. П., Жестовская С. И., Лебедева Е. В. Двумерная эластография сдвиговой волны: рациональное значение в системе bi-rads // Кремлевская медицина. Клинический вестник. 2024. № 2. С. 54-57.
7. Park S. Y., Kang B. J. Combination of shear-wave elastography with ultrasonography for detection of breast cancer and reduction of unnecessary biopsies: a systematic review and meta-analysis // Ultrasonography. 2021. N 40 (3). P. 318–332.
8. Двумерная эластография сдвиговой волной в оценке наличия и степени выраженности фиброза печени в сравнении с данными транзистентной эластографии / О. М. Процык, С. Л. Швырев, М. Д. Митькова, В. В. Капустин // Ультразвуковая и функциональная диагностика. 2022. № 4. С. 10-22.
9. Звягин А. В. О существовании слабых решений дробной модели Кельвина-Фойгта // Математические заметки. 2024. Т. 116, № 1. С. 152–157.
10. Экспериментальные исследования акустического поля поперечных волн в модели биологической ткани / Д. А. Кравчук, Н. Н. Чернов, С. А. Переселков, А. И. Михралиева // Радиотехника. Наносистемы. Информационные технологии. 2024. Т. 16, № 3. С. 381-386. <https://doi.org/10.17725/rensit.2024.16.381>. EDN HJAPTZ

11. Лагута М. В., Кравчук Д. А., Чернов Н. Н. Исследование нелинейного взаимодействия акустической волны с биотканями для целей акустической эластографии // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2025. Т. 15, № 1. С. 131–143.
12. Турбин М. В., Устюжанинова А. С. Solvability of an Initial–Boundary Value Problem for the Modified Kelvin–Voigt Model with Memory along Fluid Motion Trajectories // Differential Equations. 2024. Vol. 60, N 2. P. 180–203. <https://doi.org/10.1134/S0012266124020046>
13. Брацун Д. А., Красняков И. В., Брацун А. Д. Биомеханические модели живой ткани // Российский журнал биомеханики. 2023. № 4. <https://doi.org/10.15593/RZhBiomeh/2023.4.04>
14. Зависимости между напряжениями и деформациями в нелинейнодеформируемом теле. Часть 1. Основные принципы и соотношения механики деформируемого твердого тела / В. М. Круглов, С. В. Бакушев, А. И. Шеин, В. Т. Ерофеев, Аль Дулайми Салман Давуд Салман, А. А. Томилов // Эксперт: теория и практика. 2023. № 4 (23). С. 154–163.
15. Чернов Н. Н., Вареникова А. Ю., Лагута М. В. Использование относительного нелинейного параметра для создания систем – ультразвуковой визуализации биотканей // Моделирование, оптимизация и информационные технологии. 2022. Т. 10, № 1(36).
16. Шамаев А. С., Шумилова В. В. Усреднение уравнений движения среды, состоящей из упругого материала и несжимаемой жидкости Кельвина-Фойгта // Уфимский математический журнал. 2024. № 1. С. 98–110.
17. Concretization of nonlinear constitutive relations by results of uniaxial compression and indentation experiments / Y. Astapov, A. Markin, M. Sokolova, D. Khristich // Journal of Physics: Conference Series. 2021. N 1902(1). P. 012002.
18. Ахметшин Л. Р., Смолин И. Ю. Программируемое поведение метаматериала при изменении способа соединения элементарных ячеек // Вестник ПНИПУ. Механика. 2023. № 1. С. 26–32.
19. Mizzi L., Spaggiari A. Novel chiral honeycombs based on octahedral and dodecahedral Euclidean polygonal tessellations // International Journal of Solids and Structures. 2022. Vol. 238. P. 111428. <https://doi.org/10.1016/j.ijsolstr.2022.111428>
20. Аспекты численного моделирования процессов разрушения упруго-хрупких тел / В. Э. Вильдеман, Е. В. Феклистова, А. И. Мугатаров, М. Н. Муллахметов, А. М. Кучуков // Вычислительная механика сплошных сред. 2023. Т. 16, № 4. С. 420–429. <https://doi.org/10.7242/1999-6691/2023.16.4.35>

References

1. Zhirkov I.I., Gordienko A.V., Pavlovich I.M., Chumak B.A., Yakovlev V.V. Diagnosis of liver fibrosis: emphasis on elastography. *E`ksperimental'naya i klinicheskaya gastroe`nterologiya = Experimental and Clinical Gastroenterology*. 2020;(194):72-81. (In Russ.)
2. Belyaeva A.V., Belyaeva O.A., Rozinov V.M. Diagnostic potential of ultrasound elastography in patients with surgical diseases and injuries. *Rossijskij vestnik detskoj xirurgii, anesteziologii i reanimatologii = Russian Bulletin of Pediatric Surgery, Anesthesiology and Intensive Care*. 2023;13(3):373-384. (In Russ.) <https://doi.org/10.17816/psaic1523>
3. Diomidova V.N., Razbinina E.A., Valeeva O.N., Vasilyeva L.N. The effectiveness of shear wave elastography in assessing liver damage in patients with postcovid syndrome. *Acta Medica Eurasica*. 2022;(3):99-113. (In Russ.)
4. Kravchuk D.A., Chernov N.N., Mikhralieva A.I. Analytical modeling of breast elastography. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2024;14(1). (In Russ.)
5. King's College London. New research explores non-invasive MR elastography as an alternative to liver biopsy in obese patients. *Medical Xpress*. 2023:104-113. <https://doi.org/10.21869/2223-1536-2024-14-1-104-113>. EDN SHBQKL
6. Shevkina S.P., Zhestovskaya S.I., Lebedeva E.V. Two-dimensional shear wave elastography: rational value in the bi-rads system. *Kremlevskaya medicina. Klinicheskij vestnik = Kremlin Medicine. Clinical Bulletin*. 2024;(2):54-57 (In Russ.)
7. Park S.Y., Kang B.J. Combination of shear-wave elastography with ultrasonography for detection of breast cancer and reduction of unnecessary biopsies: a systematic review and meta-analysis. *Ultrasonography*. 2021;(40):318–332.
8. Protsyk O.M., Shvyrev S.L., Mitkova M.D., Kapustin V.V. Two-dimensional shear wave elastography in assessing the presence and severity of liver fibrosis in comparison with transient elastography data. *Ul'trazvukovaya i funkcional'naya diagnostika = Ultrasound and Functional Diagnostics*. 2022;(4):10-22. (In Russ.)
9. Zvyagin A.V. On the existence of weak solutions of the fractional Kelvin-Voigt model. *Matematicheskie zametki = Mathematical Notes*. 2024;116(1):152-157. (In Russ.)
10. Kravchuk D.A., Chernov N.N., Perestelkov S.A., Mikhralieva A.I. Experimental studies of the acoustic field of transverse waves in a biological tissue model. *Radi-oe`lektronika. Nanosistemy`. Informacionny'e texnologii = Radioelectronics. Nanosystems. Information Technology*. 2024;16(3):381-386. (In Russ.) <https://doi.org/10.17725/rensit.2024.16.381>. EDN HJAPTZ

11. Laguta M.V., Kravchuk D.A., Chernov N.N. Study of nonlinear interaction of an acoustic wave with biological tissues for the purposes of acoustic elastography. *Izvestiya Yu-go-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2025;15(1):131-143. (In Russ.)
12. Turbin M.V., Ustyuzhaninova A.S. Solvability of an Initial–Boundary Value Problem for the Modified Kelvin–Voigt Model with Memory along Fluid Motion Trajectories. *Differential Equations*. 2024;60(2):180–203. (In Russ.) <https://doi.org/10.1134/S0012266124020046>
13. Bratsun D.A., Krasnyakov I.V., Bratsun A.D. Biomechanical models of living tissue. *Rossiiskij zhurnal biomexaniki = Russian Journal of Biomechanics*. 2023;(4). (In Russ.) <https://doi.org/10.15593/RZhBiomeh/2023.4.04>
14. Kruglov V.M., Bakushev S.V., Shein A.I., Erofeev V.T., Al Dulaimi Salman, Dawud Salman, Tomilov A.A. Dependencies between stresses and deformations in a nonlinearly deformable body. Part 1. Basic principles and relations of deformable solid mechanics. *E`kspert: teoriya i praktika = Expert: Theory and Practice*. 2023;(4):154-163. (In Russ.)
15. Chernov N.N., Varenikova A.Yu., Laguta M.V. Using a relative nonlinear parameter to create systems for ultrasound imaging of biological tissues. *Modelirovanie, optimizatsiya i informacionny`e texnologii = Modeling, Optimization and Information Technology*. 2022;10(1). (In Russ.)
16. Shamaev A.S., Shumilova V.V. Averaging the equations of motion of a medium consisting of an elastic material and an incompressible Kelvin-Voigt fluid. *Ufimskij matematicheskij zhurnal = Ufa Mathematical Journal*. 2024;(1):98-110. (In Russ.)
17. Astapov Y., Markin A., Sokolova M., Khristich D. Concretization of nonlinear constitutive relations by results of uniaxial compression and indentation experiments. *Journal of Physics: Conference Series*. 2021;(1902):012002.
18. Akhmetshin L.R., Smolin I.Yu. Programmable behavior of a metamaterial when changing the method of connecting elementary cells. *Vestnik PNIPU. Mexanika = PNIPU Mechanics Bulletin*. 2023;(1):26-32. (In Russ.)
19. Mizzi L., Spaggiari A. Novel chiral honeycombs based on octahedral and dodecahedral Euclidean polygonal tessellations. *International Journal of Solids and Structures*. 2022;238:111428. <https://doi.org/10.1016/j.ijsolstr.2022.111428>
20. Wildeman V.E., Feklistova E.V., Mugatarov A.I., Mullakhmetov M.N., Kuchukov A.M. Aspects of numerical modeling of fracture processes in elastic-brittle bodies. *Vy`chislitel'naya mexanika sploshny`x sred = Computational Continuum Mechanics*. 2023;16(4):420–429. (In Russ.) <https://doi.org/10.7242/1999-6691/2023.16.4.35>

Информация об авторах / Information about the Authors

Лагута Маргарита Владимировна, ассистент, Южный федеральный университет, Институт нанотехнологий, электроники и приборостроения, г. Таганрог, Российская Федерация,
e-mail: laguta@sfnedu.ru,
ORCID: 0000-0001-7833-6055

Margarita V. Laguta, Assistant, Southern Federal University, Institute of Nanotechnology, Electronics and Instrumentation, Taganrog, Russian Federation,
e-mail: laguta@sfnedu.ru,
ORCID: 0000-0001-7833-6055

Кравчук Денис Александрович, доктор технических наук, профессор, Южный федеральный университет, Институт нанотехнологий, электроники и приборостроения, г. Таганрог, Российская Федерация,
e-mail: kravchukda@sfnedu.ru,
ORCID: 0000-0002-4220-3928

Denis A. Kravchuk, Doctor of Sciences (Engineering), Professor, Southern Federal University, Institute of Nanotechnology, Electronics and Instrumentation, Taganrog, Russian Federation,
e-mail: kravchukda@sfnedu.ru,
ORCID: 0000-0002-4220-3928

Система поддержки принятия врачебных решений по выбору конструкции дентального имплантата с использованием машинного обучения

А. А. Кийко¹✉, А. Н. Николаенко¹, М. А. Постников¹, Н. В. Попов¹,
А. Д. Лысов², А. Е. Пономарев¹, Е. В. Заров¹

¹ Самарский государственный медицинский университет Министерства здравоохранения
Российской Федерации
ул. Чапаевская, д. 89, г. Самара 443099, Российская Федерация

² Медицинский университет «Реавиз»
ул. Чапаевская, д. 227, г. Самара 443001, Российская Федерация

✉ e-mail: pavlova_163@mail.ru

Резюме

Цель исследования. Актуальной задачей цифровой дентальной имплантации является выбор и проектирование конструкции параметризованного имплантата с учетом объема и качества костной ткани в зоне имплантации, плотности и строения кости, планируемой протезной конструкции и других факторов. Цель исследования – разработка системы поддержки принятия врачебных решений с элементами искусственного интеллекта для выбора и проектирования конструкции параметризованного дентального имплантата.

Методы. В результате анализа особенностей установки имплантата и логики поддержки принятия решений в состав соответствующего программного комплекса были включены компоненты базы знаний и машинного обучения. Реализация базы знаний выполнена в виде компьютерной онтологии и содержит правила, выстроенные в типовой последовательности обработки данных. Технология искусственного интеллекта использована на этапе определения плотности трабекулярной кости и классификации по типу костной ткани путем анализа снимков конусно-лучевой компьютерной томографии пациента с помощью нейронной сети.

Результаты. В эксперименте в качестве исходных изображений были использованы снимки компьютерной томографии нижней челюсти с различным разрешением, размеченные предварительно по группам плотности костной ткани, по 30 снимков в каждой группе (всего 120 случаев). Наилучшие результаты показала модель остаточной нейронной сети ResNet 34. Модель достигла 0,875 точности на валидационной выборке и 0,75 точности на тестовой выборке при значении функции потерь около 0,72. Таким образом, можно сделать вывод о положительной возможности применения технологии машинного обучения.

Заключение. Основным научным результатом исследования является обобщение в рамках единого комплекса технологий визуализации технических решений совместно с базой знаний в виде компьютерной онтологии и модуля машинного обучения в соответствии с принципами персонализированной медицины. Предложенный гибридный подход, сочетающий экспертные правила с методами машинного обучения, позволяет объединить достоинства двух парадигм: формализованного клинического опыта и адаптивного выявления скрытых закономерностей.

Ключевые слова: цифровая стоматология; поддержка принятия врачебных решений; онтология; персонализированная медицина.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Система поддержки принятия врачебных решений по выбору конструкции дентального имплантата с использованием машинного обучения / А. А. Кийко, А. Н. Николаенко, М. А. Постников, Н. В. Попов, А. Д. Лысов, А. Е. Пономарев, Е. В. Заров // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 174–188. <https://doi.org/10.21869/2223-1536-2026-16-1-174-188>

Поступила в редакцию 29.01.2026

Подписана в печать 28.02.2026

Опубликована 31.03.2026

Clinical decision-making support system for dental implant design using machine learning

Anastasia A. Kijko¹ ✉, Andrey N. Nikolaenko¹, Mikhail A. Postnikov¹,
Nikolay V. Popov¹, Alexander D. Lysov², Artem E. Ponomarev¹, Evgeniy V. Zarov¹

¹ Samara State Medical University of the Ministry of Health of the Russian Federation
89 Chapayevskaya Str., Samara 443099, Russian Federation

² Medical University "REAVIZ"
227 Chapayevskaya Str., Samara 443001, Russian Federation

✉ e-mail: pavlova_163@mail.ru

Abstract

Purpose of research. A current challenge in digital dental implantation is the selection and design of a parametric implant, taking into account the volume and quality of bone tissue in the implantation area, bone density and structure, the planned prosthetic structure, and a number of other factors. The purpose of the study is to develop a medical decision-making support system with Artificial Intelligence for selection and design of a parametric dental implant.

Methods. As a result of the analysis of the features of the implant installation and decision support logic, knowledge base and machine learning components were included in the corresponding software package. The implementation of the knowledge base is made in the form of a computer ontology and contains rules arranged in a typical sequence of data processing. Artificial intelligence technology is used at the stage of determining the density of the trabecular bone and classifying it by bone type by analyzing the patient's cone beam computed tomography images using a neural network.

Results. In the experiment, computed tomography images of the lower jaw with different resolutions were used as initial images, pre-marked by bone density groups, 30 images in each group (120 cases in total). The best results were shown by the residual neural network model ResNet 34. The model achieved 0.875 accuracy on the validation sample and 0.75 accuracy on the test sample with a loss function value of about 0.72. Thus, we can conclude about the positive possibility of using machine learning technology.

Conclusion. The main scientific result of the study is the generalization of technical solutions within a unified set of visualization technologies, combined with a knowledge base in the form of computer ontology and a machine learning module, in accordance with the principles of personalized medicine. The proposed hybrid approach, combining expert rules with machine learning methods, combines the advantages of two paradigms: formalized clinical experience and adaptive detection of hidden patterns.

Keywords: digital dentistry; clinical decision-making support; ontology; personalized medicine.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Kijko A.A., Nikolaenko A.N., Postnikov M.A., Popov N.V., Lysov A.D., Ponomarev A.E., Zarov E.V. Clinical decision-making support system for dental implant design using machine learning. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(1):174–188. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-174-188>

Received 29.01.2026

Accepted 28.02.2026

Published 31.03.2026

Введение

Развитие дентальной имплантации в настоящее время тесно связано с внедрением технологий цифровой стоматологии, трехмерного моделирования и компьютерного зрения. Новые возможности в этой области могут быть обеспечены путем внедрения искусственного интеллекта [1] применительно к отрасли здравоохранения [2]. Данное направление исследований требует междисциплинарного подхода, приобретающего в настоящее время высокую актуальность [3]; однако остаются открытыми вопросы в этой области на уровне формирования клинических рекомендаций [4] и необходимого регулирования [5].

Внедрение искусственного интеллекта в стоматологию также имеет хорошие перспективы [6]. Индивидуальный подход к построению дентальных имплантатов с учетом особенностей строения зубочелюстного аппарата пациентов позволяет реализовать современные принципы персонализированной медицины [7] и повысить качество реабилитации пациентов с потерей зубов.

Одной из частных задач цифровой дентальной имплантации является выбор и проектирование конструкции параметризованного имплантата [8] с учетом различных параметров изготовле-

ния [9]. Решение этой задачи зависит от объема и качества костной ткани в зоне имплантации, характера дефектов зубного ряда, плотности и строения кости, планируемой протезной конструкции и ряда других факторов. На основании всестороннего анализа этих параметров совместно врач-хирург и врач-ортопед должны выбрать тип имплантата, диаметр, длину и разработать план хирургического вмешательства и ортопедического лечения.

С целью повышения качества решения этой задачи, сокращения ее трудоемкости и устранения влияния человеческого фактора была разработана система поддержки принятия врачебных решений с элементами искусственного интеллекта, автоматизирующая выбор и расчет параметров дентальных имплантатов по индивидуальным данным пациента, включая результаты компьютерной томографии (КТ), сведения о сложной анатомии и сопутствующих патологиях.

Реализация технологий искусственного интеллекта в данном случае позволила обеспечить идентификацию характеристик кости и мягких тканей по снимкам КТ и классифицировать дефицит костной ткани с использованием машинного обучения, в также формализовать логику выбора имплантатов

с помощью базы знаний, реализованной в формате компьютерной онтологии [10] посредством формально-логических правил.

Известен успешный опыт применения онтологий в цифровой стоматологии. В работе [11] онтология используется для формального описания процесса удаления зубов. Исследование [12] посвящено стандартизации терминов в области имплантологии и обеспечению их семантической совместимости. В работе использовано программное обеспечение Protégé. Построение онтологической основы в имплантологии позволяет реализовать базу знаний для профессионального стоматолога при принятии решений о выборе типа зубного имплантата, который будет установлен в каждом конкретном случае.

В работе [13] предлагается концептуальная модель знаний и логического вывода для поддержки процесса имплантации зубов. Здесь же дополнительно отмечается актуальность применения компьютерных методов моделирования и диагностики для определения параметров процесса имплантации. В статье [14] на базе онтологии построена система поддержки принятия врачебных решений по проектированию dentальных съемных частичных протезов. Здесь онтология представляет собой парадигму для представления знаний о состоянии полости рта пациента и компонентах протеза.

Несмотря на позитивную оценку онтологии как инструмента построения

базы знаний в стоматологии, в реальных системах поддержки принятия врачебных решений по конструированию имплантата она не применена. Однако результаты исследований позволили обеспечить цифровую трансформацию процесса диагностики и планирования хирургического и ортопедического лечения, что более детально представлено далее в статье.

Материалы и методы

Основная задача поддержки принятия врачебных решений заключается в автоматизированной обработке больших объемов информации, описывающей состояние здоровья пациента, их обобщения и визуального представления врачу в лаконичной и достоверной форме. В контексте решаемой задачи такой подход сводится к последовательному выполнению трех этапов:

- 1) выбор типа имплантата и его параметризация;
- 2) определение размеров и расположения имплантата относительно костей нижней челюсти и зубов пациента с учетом его индивидуальных особенностей;
- 3) планирование хирургического вмешательства в особых случаях.

Традиционно для этих целей врач использует данные КТ. При этом он выбирает необходимые проекции вручную, что требует достаточно больших временных затрат на работу с трехмерными изображениями. Для снижения трудоемкости этого процесса предлага-

ется реализовать дополнительную информационную обработку снимков КТ, результатом которой является выбор и параметризация модели зубного имплантата.

Данные КТ позволяют определить относительное место расположения имплантата и условия его установки, включая возможные динамические нагрузки. Основная жевательная нагрузка передается по его оси и зависит от угла установки. Это необходимо учитывать при выборе типа и размера имплантата. Определить и визуализировать векторы жевательной нагрузки, таким образом, можно в проекциях плоскости нижней челюсти и перпендикулярной ей плоскости. Такой метод позволяет перейти от трехмерной модели к группе двумерных изображений.

Далее при выборе имплантата необходимо руководствоваться следующими входными параметрами:

- размер костного блока;
- плотность трабекулярной кости;
- пиковая жевательная нагрузка;
- наличие остеопении, остеопороза.

Шаг и глубина резьбы выбираются для достижения необходимой площади поверхности имплантата и максимально близкими к средним параметрам шага и глубины. Глубина и форма резьбы плавно меняется по мере перехода имплантата из одной плотности кости в другую.

В результате системного анализа особенностей установки имплантата и логики поддержки принятия врачебных

решений в состав соответствующего программного комплекса были включены следующие компоненты. Это компонент реализации базы знаний для задания и обеспечения базовых алгоритмов и расчетов и компонент машинного обучения, решающий частную задачу идентификации плотности кости и классификации по типу костной ткани с использованием искусственной нейронной сети. Ниже данные компоненты раскрыты подробнее.

Реализация базы знаний

Реализация базы знаний выполнена в виде компьютерной онтологии и содержит правила, выстроенные в типовой последовательности обработки данных. При этом данные правила могут применяться в другой последовательности или совместно для корректировки решения врача в рамках информационной поддержки принятия врачебных решений.

В ходе исследования была разработана следующая система формальных правил:

1. Выбор проекции:

- *исходные данные*: КТ пациента;
- *вывод*: плоскость челюсти (продольная и поперечная проекция).

2. Расчет диаметра имплантата в продольной челюсти проекции:

- *исходные данные*: h_1 – размер кости челюсти в месте установки имплантата в продольной проекции; d_3 и d_4 – минимальные расстояния от проектируемого имплантата до соседнего зуба = 1,6 мм / имплантата = 2,8 мм. Диаметр

имплантата выбирается наименьшим значением среди d_1 и d_2 ;

– вывод: $d_1 = h_1 - d_3 - d_4$;

– единица измерения: мм.

3. Расчет диаметра имплантата в поперечной челюсти проекции:

– исходные данные: h_2 – размер кости челюсти в месте установки имплантата в поперечной проекции;

– вывод: $d_2 = h_2 - 3,8$;

– единица измерения: мм.

4. Расчет диаметра имплантата:

– исходные данные: d_1, d_2 ;

– вывод: $d_i = \min(d_1, d_2)$;

– единица измерения: мм.

5. Выбор проекции:

– исходные данные: КТ пациента;

– вывод: проекция фронтальная, перпендикулярная плоскости нижней челюсти.

6. Определение длины имплантата

– исходные данные: L_i – размер кости челюсти в месте и направлении установки имплантата;

– вывод: $l_i = L_i - 1,8$;

– единица измерения: мм.

7. Определение плотности трабекулярной кости ρ и типа костной ткани:

– исходные данные: снимки конусно-лучевой КТ пациента, опросный лист;

– вывод: с использованием ИИ (как показано ниже);

– единица измерения: по шкале Хаунсфилда, HU.

8. Оценка индивидуальной жевательной нагрузки:

– исходные данные: пол (мужской/женский), или по тестам индивидуально;

– вывод: $M \rightarrow 820$; $J \rightarrow 700$;

– единица измерения: кгс.

9. Определение предельного напряжения костной ткани (пиковой жевательной силы):

– исходные данные: плотность костной ткани трабекулярной кости (в HU);

– вывод:

кортикальная кость $\rightarrow 14,8$;

губчатая кость $\rightarrow 8,2$;

губчатая кость 830 HU $\rightarrow 6,46$;

губчатая кость 800 HU $\rightarrow 5,42$;

губчатая кость 760 HU $\rightarrow 4,64$;

губчатая кость 720 HU $\rightarrow 4,18$;

губчатая кость 680 HU $\rightarrow 3,83$;

губчатая кость 600 HU $\rightarrow 3,27$;

губчатая кость 510 HU $\rightarrow 2,79$;

губчатая кость 425 HU $\rightarrow 2,34$;

губчатая кость 340 HU $\rightarrow 1,9$;

губчатая кость 250 HU $\rightarrow 1,48$

– единица измерения: кг/мм².

10. Корректировка предельного напряжения костной ткани:

– исходные данные: опросный лист;

– вывод: остеопороз, менопауза $\rightarrow$

$P_i = 0,75 \cdot P_i^*$; сахарный диабет, печеночная и почечная недостаточность $\rightarrow$

$P_i = 0,85 \cdot P_i^*$; прочие критерии;

– единица измерения: кг/мм².

11. Расчет плоскости поверхности резьбы:

– исходные данные: жевательная нагрузка F_i ; пиковая жевательная сила P_i ;

– вывод: $S_i = F_i / P_i$;

– единица измерения: мм².

12. Выбор формы резьбы

– *исходные данные*: плотность костной ткани D;

– *вывод*: D1 → квадратная;

D2 → трапециевидная;

D3, D4 → V-образная;

13. Выбор параметров резьбы

– *исходные данные*: плотность костной ткани D;

– *вывод*:

кость D1 → шаг резьбы 0,2...0,5;

глубина резьбы 0,1-0,3;

кость D2 → шаг резьбы 0,4...0,8;

глубина резьбы 0,2-0,4;

кость D3 → шаг резьбы 0,7...1,2;

глубина резьбы 0,3-0,6;

кость D4 → шаг резьбы 1,0...1,6;

глубина резьбы 0,5-0,8;

– *единица измерения*: мм.

База знаний была реализована в составе системы поддержки принятия врачебных решений на языке Python.

Реализация машинного обучения

Технология искусственного интеллекта в рамках решаемой задачи может быть эффективно использована на этапе определения плотности трабекулярной кости и типа костной ткани путем анализа снимков конусно-лучевой КТ пациента. Данная задача достаточно успешно решается с помощью современных искусственных нейронных сетей [15], реализующих машинное зрение по данным КТ [16]. Достаточно хорошо удается распознавать плотность кости по снимкам высокого разрешения [17] и проводить последующую медицинскую диагностику [18].

Применительно к решаемой задаче известен опыт применения искусственных нейронных сетей в анализе конусно-лучевой КТ при планировании операций [19] и оценке осложнений [20]. В частности, в работе [21] отражен успешный опыт применения сверточной нейронной сети для обнаружения краевой потери костной ткани на периапикальных рентгенограммах. В связи с этим для решения поставленной задачи логично реализовать нейросетевой алгоритм распознавания плотности костной ткани и классификации случаев по типу предельного напряжения костной ткани.

В качестве исходных изображений были использованы снимки КТ нижней челюсти с различным разрешением (рис. 1), размеченные предварительно по группам плотности костной ткани, по 30 снимков в каждой группе.



Рис. 1. Исходный снимок КТ нижней челюсти (пример)

Fig. 1. Input CT scan of the lower jaw (example)

В рамках реализованной системы поддержки принятия врачебных реше-

ний была выбрана модель остаточной нейронной сети ResNet 34 с 34 слоями [22], которая показала наилучшие результаты по сравнению с аналогами (рис. 2–4).




Рис. 2. Функция потерь

Fig. 2. Loss function




Рис. 3. Точность распознавания

Fig. 3. Accuracy

Наилучшие результаты показала модель resnet34_gray_w_seed2. Модель достигла 0,875 точности на валидационной выборке и 0,75 точности на тестовой выборке при значении test loss около 0,72. Таким образом, можно сделать вывод о положительной возможности применения технологии машинного обучения на данном этапе алгоритма.




Рис. 4. Распределение ошибок

Fig. 4. Confusion matrix

Результаты и их обсуждение

Предложенные технологии были реализованы в составе системы поддержки принятия врачебных решений (рис. 5). Функциональность программного обеспечения включает загрузку данных КТ с последующей обработкой, выбор типа имплантата и его параметризацию, определение размеров и расположения имплантата с учетом индивидуальных особенностей пациента.




Рис. 5. Фрагмент экрана СППВР

Fig. 5. Software screen fragment

Тестирование системы было произведено на нескольких реальных случаях. В результате на основании результатов исследований конусно-лучевой компьютерной томографии были выведены оптимальные габаритные размеры дентального имплантата: общая длина, длина внутрикостной части имплантата с двухзаходной мелкой резьбой, располагающейся в кортикальном слое кости, и диаметр внутрикостной части имплантата. Предложенные системой параметры были согласованы лечащим врачом.

Результаты рассматриваемого случая (до и после имплантации) представлены ниже (рис. 6 и 7).



Рис. 6. Исходная ортопантограмма челюстей пациента

Fig. 6. Initial orthopantomogram of the patient's jaws




Рис. 7. Результат имплантации

Fig. 7. Implantation result

Полученные результаты подтверждают возможность и практическую полезность реализации системы поддержки принятия врачебных решений по проектированию дентальных имплантатов.

Выводы

Проведенное исследование позволило реализовать систему поддержки принятия врачебных решений для выбора и параметризации дентальных имплантатов в соответствии с современными принципами персонализированной медицины. Основным научным результатом исследования является обобщение в рамках единого комплекса технологий визуализации технических решений совместно с базой знаний, построенной в виде компьютерной онтологии, и модуля машинного обучения для идентификации плотности кости и классификации по типу костной ткани с использованием искусственной нейронной сети.

Предложенный гибридный подход, сочетающий экспертные правила с методами машинного обучения, позволяет объединить достоинства двух парадигм: формализованного клинического опыта и адаптивного выявления скрытых закономерностей в данных. Гибридная интеллектуальная система может обучаться на реальных клинических кейсах, уточняя рекомендации на основе статистиче-

ских корреляций, и одновременно опираться на проверенные правила, обеспечивая клиническую интерпретируемость и соответствие стандартам лечения.

Практическая реализация и проведенные эксперименты подтвердили широкие возможности применения разработанной системы на практике в цифровой стоматологии.

Список литературы

1. Алексеева М. Г., Зубов А. И., Новиков М. Ю. Искусственный интеллект в медицине // Международный научно-исследовательский журнал. 2022. № 7 (121). С. 10–13. <https://doi.org/10.23670/IRJ.2022.121.7.038>
2. Итоги внедрения искусственного интеллекта в здравоохранении России / В. В. Ваньков, О. Р. Артемова, О. Э. Карпов, А. В. Матвиенко, А. В. Гусев, И. М. Еникеев, Е. В. Костина // Врач и информационные технологии. 2024. № 3. С. 32-43. https://doi.org/10.25881/18110193_2024_3_32
3. Искусственный интеллект в медицине: обзор текущей ситуации и тенденции / Я. Г. Купатенко, А. К. Мирук, А. В. Ломоносова, А. А. Козлова // Cifra. Медико-биологические науки. 2024. № 2 (2). С.1-13. <https://doi.org/10.60797/BMED.2024.2.4>
4. Морозов Д. Ю., Омеляновский В. В., Федяева В. К. Искусственный интеллект в системе здравоохранения. Клинические рекомендации // Менеджер здравоохранения. 2025. № 9. С. 58-67. <https://doi.org/10.21045/1811-0185-2025-9-58-67>
5. Анализ мирового опыта в регулировании использования медицинских данных для целей создания систем искусственного интеллекта на основе машинного обучения / Д. Е. Шарова, А. А. Михайлова, А. В. Гусев, С. В. Гарбук, А. В. Владзимирский, Ю. А. Васильев // Врач и информационные технологии. 2022. № 4. С. 28–39. https://doi.org/10.25881/18110193_2022_4_28
6. Kukreja B., Kukreja P. Integration of Artificial Intelligence in dentistry: a systematic review of educational and clinical implications // Cureus. 2025. Vol. 17. <https://doi.org/10.7759/cureus.79350>
7. Персонализированная медицина: современное состояние и перспективы / И. И. Дедов, А. Н. Тюльпаков, В. П. Чехонин, В. П. Баклаушев, А. И. Арчаков, С. А. Мошковский // Вестник Российской академии медицинских наук. 2012. Т. 67, № 12. С. 4–12.
8. Bensmain W., Benlebna M., Serier B., Abbes B., Bouiadjra B. A. Parametric optimization of dental implants // Mechanics and Mechanical Engineering. 2018. Vol. 22. P. 1061-1076. <https://doi.org/10.2478/mme-2018-0084>
9. Rahmanivahid P., Heidari M. Design parameters of dental implants: a review // Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería. 2022. Vol. 38, N 1. P. 1-10. <https://doi.org/10.23967/j.rimni.2022.03.002>

10. Онтологический комплекс представления знаний для реабилитации травматолого-ортопедических пациентов / В. В. Грибова, Е. А. Шалфеева, Д. Б. Окунь, О. Н. Шевченко // Онтология проектирования. 2025. Т. 15, № 4(58). С. 509–522. <https://doi.org/10.18287/2223-9537-2025-15-4-509-522>
11. Vasanthapriyan S. An ontological approach for knowledge representation of dental extraction forceps // Artificial Intelligence: Second International Conference. Singapore: Springer, 2019. P. 147-160. https://doi.org/10.1007/978-981-13-9129-3_11
12. Formalization of a knowledge base applied to dental implant / V. Biasi, M. Rudek, A. Szejka, J. O. Canciglieri // Proceedings of the 8th International Conference on Information Society and Technology (ICIST 2018). Serbia: Kopaonik, 2018. P. 1-6.
13. A conceptual knowledge-link model for supporting dental implant process / A. Szejka, O. Canciglieri Junior, M. Rudek, H. Panetto // Advanced Materials Research. 2014. Vol. 945-949. P. 3424-3429. <https://doi.org/10.4028/www.scientific.net/AMR.945-949.3424>
14. An ontology-driven, case-based clinical decision support model for removable partial denture design / Q. Chen, J. Wu, S. Li, P. Lyu, Y. Wang, M. Li // Scientific Reports. 2016. Vol. 6. P. 27855. <https://doi.org/10.1038/srep27855>
15. Bida F., Naser H. Diagnostic of osteoporosis using backpropagation neural networks // Journal of Techniques. 2025. N 7. P. 10–20. <https://doi.org/10.51173/jt.v7i2.2597>
16. Optimized Hounsfield units transformation for explainable temporal stage-specific ischemic stroke classification in CT imaging / R. Qasrawi, S. Thwib, G. Issa, I. Qdaih, R. Abu Ghoush, H. Arjah // J. Imaging. 2025. N 11. P. 423. <https://doi.org/10.3390/jimaging11120423>
17. An automatic deep learning-based bone mineral density measurement method using X-ray images of children / H. Zhao, Yi Zhang, W. Zhang, L. Wang, K. Li, J. Geng, X. Cheng, T. Wu // Quantitative Imaging in Medicine and Surgery. 2025. N 15. P. 2481–2493. <https://doi.org/10.21037/qims-24-283>
18. Интеллектуальная диагностика межпозвонковых грыж поясничного отдела с телемедицинским доступом / А. В. Епифанов, Д. С. Жейков, А. В. Иващенко, Г. П. Герасимов, В. В. Авсиевич, А. Е. Пономарев, В. В. Панарин, А. В. Авсиевич, А. В. Колсанов // Менеджер здравоохранения. 2025. № 10. С. 90–96. <https://doi.org/10.21045/1811-0185-2025-10-90-96>
19. U-Net-based deep learning architecture for automated CBCT segmentation of the mandibular canal in dental implant treatment planning: A systematic review and meta-analysis / B. Palani, M. Rathee, S. Tomar, S. Singla // The Journal of Prosthetic Dentistry. 2025. N 25. P. 00955-2. <https://doi.org/10.1016/j.prosdent.2025.12.003>
20. A pilot study of a deep learning approach to detect marginal bone loss around implants / M. Liu, S. Wang, H. Chen [et al.] // BMC Oral Health. 2022. N 22. P. 11. <https://doi.org/10.1186/s12903-021-02035-8>

21. Peri-implant bone loss measurement using a region-based convolutional neural network on dental periapical radiographs / J.-Y. Cha, H.-I. Yoon, I.-S. Yeo, K.-H. Huh, J.-S. Han // *Journal of Clinical Medicine*. 2021. N 10. P. 1009. <https://doi.org/10.3390/jcm10051009>
22. Shafiq M., Gu Z. Deep residual learning for Image Recognition: A Survey // *Applied Sciences*. 2022. N 12(18). P. 8972. <https://doi.org/10.3390/app12188972>

References

1. Alekseeva M.G., Zubov A.I., Novikov M.Yu. Artificial intelligence in medicine. *Mezhdunarodnyi nauchno-issledovatel'skii zhurnal = International Scientific Research Journal*. 2022;(7):10-13. (In Russ.) <https://doi.org/10.23670/IRJ.2022.121.7.038>
2. Vankov V.V., Artemova O.R., Karpov O.E., Matvienko A.V., Gusev A.V., Enikeev I.M., Kostina E.V. Results of the introduction of artificial intelligence in Russian healthcare. *Vrach i informatsionnye tekhnologii = Doctor and Information Technologies*. 2024;(3):32-43. (In Russ.) https://doi.org/10.25881/18110193_2024_3_32
3. Kupatenko Ya.G., Miruk A.K., Lomonosova A.V., Kozlova A.A. Artificial intelligence in medicine: an overview of the current situation and trends. *Cifra. Mediko-biologicheskie nauki = Cifra. Medical and Biological Sciences*. 2024;(2):1-13. (In Russ.) <https://doi.org/10.60797/BMED.2024.2.4>
4. Morozov D.Yu., Omelyanovsky V.V., Fedyaeva V.K. Artificial intelligence in the healthcare system. Clinical recommendations. *Menedzher zdravookhraneniya = The Health Care Manager*. 2025;(9):58-67. (In Russ.) <https://doi.org/10.21045/1811-0185-2025-9-58-67>
5. Sharova D.E., Mikhailova A.A., Gusev A.V., Garbuk S.V., Vladzimirsky A.V., Vasiliev Yu.A. Analysis of world experience in regulating the use of medical data for the purpose of creating artificial intelligence systems based on machine learning. *Vrach i informatsionnye tekhnologii = Doctor and Information Technologies*. 2022;(4):28-39. (In Russ.) https://doi.org/10.25881/18110193_2022_4_28
6. Kukreja B., Kukreja P. Integration of Artificial Intelligence in dentistry: a systematic review of educational and clinical implications. *Cureus*. 2025. Vol. 17. <https://doi.org/10.7759/cureus.79350>
7. Dedov I.I., Tulpakov A.N., Chekhonin V.P., Baklaushev V.P., Archakov A.I., Moshkovsky S.A. Personalized medicine: current state and prospects. *Vestnik Rossiiskoi akademii meditsinskikh nauk = Bulletin of the Russian Academy of Medical Sciences*. 2012;67(12):4-12. (In Russ.)
8. Bensmain W., Benlebna M., Serier B., Abbes B., Bouiadjra B. A. Parametric optimization of dental implants. *Mechanics and Mechanical Engineering*. 2018;22:1061-1076. <https://doi.org/10.2478/mme-2018-0084>

9. Rahmanivahid P., Heidari M. Design parameters of dental implants: a review. *Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería*. 2022;38(1):1-10. <https://doi.org/10.23967/j.rimni.2022.03.002>
10. Gribova V.V., Shalfeeva E.A., Okun D.B., Shevchenko O.N. Ontological complex of knowledge representation for rehabilitation of traumatological and orthopedic patients. *Ontologiya proektirovaniya = The Ontology of Design*. 2025;15(4):509-522. (In Russ.) <https://doi.org/10.18287/2223-9537-2025-15-4-509-522>
11. Vasanthapriyan S. An ontological approach for knowledge representation of dental extraction forceps. In: *Artificial Intelligence: Second International Conference*. Singapore: Springer; 2019. P. 147-160. https://doi.org/10.1007/978-981-13-9129-3_11
12. Biasi V., Rudek M., Szejka A., Canciglieri J. O. Formalization of a knowledge base applied to dental implant. In: *Proceedings of the 8th International Conference on Information Society and Technology (ICIST 2018)*. Serbia: Kopaonik; 2018. P. 1-6.
13. Szejka A., Canciglieri Junior O., Rudek M., Panetto H. A conceptual knowledge-link model for supporting dental implant process. *Advanced Materials Research*. 2014;945-949:3424-3429. <https://doi.org/10.4028/www.scientific.net/AMR.945-949.3424>
14. Chen Q., Wu J., Li S., Lyu P., Wang Y., Li M. An ontology-driven, case-based clinical decision support model for removable partial denture design. *Scientific Reports*. 2016;6:27855. <https://doi.org/10.1038/srep27855>
15. Bida F., Naser H. Diagnostic of osteoporosis using backpropagation neural networks. *Journal of Techniques*. 2025;(7):10–20. <https://doi.org/10.51173/jt.v7i2.2597>
16. Qasrawi R., Thwib S., Issa G., Qdaih I., Abu Ghoush R., Arjah H. Optimized Hounsfield units transformation for explainable temporal stage-specific ischemic stroke classification in CT imaging. *J. Imaging*. 2025;(11):423. <https://doi.org/10.3390/jimaging11120423>
17. Zhao H., Zhang Yi, Zhang W., Wang L., Li K., Geng J., Cheng X., Wu T. An automatic deep learning-based bone mineral density measurement method using X-ray images of children. *Quantitative Imaging in Medicine and Surgery*. 2025;(15):2481–2493. <https://doi.org/10.21037/qims-24-283>
18. Epifanov A.V., Zheikov D.S., Ivashchenko A.V., Gerasimov G. P., Avsieich V.V., Ponomarev A.E., Panarin V.V., Avsieich A.V., Kolsanov A.V. Intelligent diagnostics of intervertebral hernias of the lumbar spine with telemedicine access. *Menedzher zdorovookhraneniya = The Health Care Manager*. 2025;(10):90-96. (In Russ.) <https://doi.org/10.21045/1811-0185-2025-10-90-96>
19. Palani B., Rathee M., Tomar S., Singla S. U-Net-based deep learning architecture for automated CBCT segmentation of the mandibular canal in dental implant treatment planning: A systematic review and meta-analysis. *The Journal of Prosthetic Dentistry*. 2025;(25):00955-2. <https://doi.org/10.1016/j.prosdent.2025.12.003>

20. Liu M., Wang S., Chen H., et al. A pilot study of a deep learning approach to detect marginal bone loss around implants. *BMC Oral Health*. 2022;(22):11. <https://doi.org/10.1186/s12903-021-02035-8>
21. Cha J.-Y., Yoon H.-I., Yeo I.-S., Huh K.-H., Han J.-S. Peri-implant bone loss measurement using a region-based convolutional neural network on dental periapical radiographs. *Journal of Clinical Medicine*. 2021;(10):1009. <https://doi.org/10.3390/jcm10051009>
22. Shafiq M., Gu Z. Deep residual learning for Image Recognition: A Survey. *Applied Sciences*. 2022;(12):8972. <https://doi.org/10.3390/app12188972>

Информация об авторах / Information about the Authors

Кийко Анастасия Алексеевна, аспирант, Научно-исследовательский институт бионики и персонифицированной медицины, Самарский государственный медицинский университет Министерства здравоохранения Российской Федерации, г. Самара, Российская Федерация, e-mail: pavlova_163@mail.ru, ORCID: 0000-0003-0685-507X

Anastasia A. Kijko, Postgraduate, Research Institute of Bionics and Personalized Medicine, Samara State Medical University of the Ministry of Health of the Russian Federation, Samara, Russian Federation, e-mail: pavlova_163@mail.ru, ORCID: 0000-0003-0685-507X

Николаенко Андрей Николаевич, доктор медицинских наук, доцент, директор Научно-исследовательского института бионики и персонифицированной медицины, Самарский государственный медицинский университет Министерства здравоохранения Российской Федерации, г. Самара, Российская Федерация, e-mail: nikolaenko.83@inbox.ru, ORCID: 0000-0003-3411-4172

Andrey N. Nikolaenko, Doctor of Sciences (Medical), Associate Professor, Director at the Research Institute of Bionics and Personalized Medicine, Samara State Medical University of the Ministry of Health of the Russian Federation, Samara, Russian Federation, e-mail: nikolaenko.83@inbox.ru, ORCID: 0000-0003-3411-4172

Постников Михаил Александрович, доктор медицинских наук, профессор, заведующий кафедрой терапевтической стоматологии с курсом остеопатии, Самарский государственный медицинский университет Министерства здравоохранения Российской Федерации, г. Самара, Российская Федерация, e-mail: postnikovortho@yandex.ru, ORCID: 0000-0002-2232-8870

Mikhail A. Postnikov, Doctor of Sciences (Medical), Professor, Head of the Department of Therapeutic Dentistry, Samara State Medical University of the Ministry of Health of the Russian Federation, Samara, Russian Federation, e-mail: postnikovortho@yandex.ru, ORCID: 0000-0002-2232-8870

Попов Николай Владимирович, доктор медицинских наук, доцент, директор института стоматологии, Самарский государственный медицинский университет Министерства здравоохранения Российской Федерации, г. Самара, Российская Федерация, e-mail: n.v.popov@samsmu.ru, ORCID: 0000-0003-4454-984X

Nikolay V. Popov, Doctor of Sciences (Medical), Associate Professor, Director of the Institute of Dentistry, Samara State Medical University of the Ministry of Health of the Russian Federation, Samara, Russian Federation, e-mail: n.v.popov@samsmu.ru, ORCID: 0000-0003-4454-984X

Лысов Александр Дмитриевич, кандидат медицинских наук, доцент кафедры стоматологии, Медицинский университет «Реавиз», г. Самара, Российская Федерация, e-mail: mail@reaviz.ru, ORCID: 0000-0003-3369-8030

Alexander D. Lysov, Candidate of Sciences (Medical), Associate Professor at the Department of Dentistry, Medical University “REAVIZ”, Samara, Russian Federation, e-mail: mail@reaviz.ru, ORCID: 0000-0003-3369-8030

Пономарев Артем Евгеньевич, магистрант, Передовая медицинская инженерная школа, Самарский государственный медицинский университет Министерства здравоохранения Российской Федерации, г. Самара, Российская Федерация, e-mail: a.e.ponomonarev@samsmu.ru, ORCID: 0009-0003-9759-9944

Artem E. Ponomarev, Undergraduate, Higher School of Medical Engineering, Samara State Medical University of the Ministry of Health of the Russian Federation, Samara, Russian Federation, e-mail: a.e.ponomonarev@samsmu.ru, ORCID: 0009-0003-9759-9944

Заров Евгений Владимирович, магистрант, Передовая медицинская инженерная школа, Самарский государственный медицинский университет Министерства здравоохранения Российской Федерации, г. Самара, Российская Федерация, e-mail: e.v.zarov@samsmu.ru, ORCID: 0009-0001-2151-6511

Evgeny V. Zarov, Undergraduate, Higher School of Medical Engineering, Samara State Medical University of the Ministry of Health of the Russian Federation, Samara, Russian Federation, e-mail: e.v.zarov@samsmu.ru, ORCID: 0009-0001-2151-6511

Влияние геометрических параметров насосов аппарата вспомогательного кровообращения на их напорно-расходные характеристики

К. В. Кротов¹✉, Г. Г. Боярский¹, А. И. Хаустов¹

¹ Московский авиационный институт (национальный исследовательский университет)
Волоколамское ш., д. 4, г. Москва 125993, Российская Федерация

✉ e-mail: Krotovkv@yandex.ru

Резюме

Цель исследования. Статья посвящена оценке влияния геометрических параметров насосов аппарата вспомогательного кровообращения на угол наклона напорно-расходной характеристики. Цель исследования обусловлена необходимостью разработки новых и модернизации известных насосов для аппаратов вспомогательного кровообращения.

Методы. Для оценки влияния геометрических параметров на наклон напорно-расходной характеристики разработан трехфакторный план численного эксперимента, состоящий из 21 насоса, имеющего разные геометрические параметры. Факторами являлись: диаметр втулки d , диаметр периферии D и угол диагональности втулки ϕ рабочего колеса насоса. Численное моделирование течения крови в насосах выполнялось методом конечных объемов в расчетном пакете OpenFOAM11. Для расчета использован метод SIMPLE, а для учета вращения применена технология MRF.

Результаты. В результате численного эксперимента получены относительные напорно-расходные характеристики каждого из насосов, показывающие влияние диаметров D , d и диагональности ϕ на наклон напорно-расходной характеристики, которые методом наименьших квадратов аппроксимированы полиномом 3-й степени. Полученные зависимости позволяют определять частоту вращения насоса для любого его режима работы. Из обобщения результатов численного моделирования течения крови в насосах получены трехмерные поверхности, представляющие множество зависимостей наклона напорно-расходной характеристики от геометрических параметров проточной части насосов.

Заключение. Установлено, что изменением диаметров втулки и периферии, угла диагональности можно добиться требуемого увеличения наклона напорно-расходной характеристики. Минимальный наклон достигается при средних значениях факторов D , d , ϕ численного эксперимента, а максимальный – при минимуме и при максимуме значений диаметров. Материалы статьи представляют практическую ценность при проектировании новых и модернизации осевых насосов аппаратов вспомогательного кровообращения.

Ключевые слова: осевой насос; аппарат вспомогательного кровообращения; вычислительная гидродинамика; планирование эксперимента; численное моделирование; метод конечных объемов.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Кротов К. В., Боярский Г. Г., Хаустов А. И. Влияние геометрических параметров насосов аппарата вспомогательного кровообращения на их напорно-расходные характеристики // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 189–205. <https://doi.org/10.21869/2223-1536-2026-16-1-189-205>

Поступила в редакцию 27.01.2026

Подписана в печать 25.02.2026

Опубликована 31.03.2026

The influence of the assisted blood circulation pumps geometry on their head-flow Characteristics

Kirill V. Krotov¹ ✉, Gleb G. Boyarsky¹, Alexander I. Khaustov¹

¹ Moscow Aviation Institute (National Research University)
4 Volokolamskoe highway, Moscow 125993, Russian Federation

✉ e-mail: Krotovkv@yandex.ru

Abstract

Purpose of research. The object of the article is to determine the influence of the assisted blood circulation pumps geometry on the head-flow characteristic slope. Reasoning for the research consists of necessity in new blood circulation assist pumps and demand for improving existing devices.

Methods. To assess the effect of geometric parameters on the slope of the head-flow characteristics, a three-factor numerical experiment plan has been developed, consisting of 21 pumps with different geometric parameters. The factors were: the diameter of the sleeve d , the diameter of the periphery D , and the diagonal angle of the sleeve φ of the pump impeller. Numerical simulation of blood flow in pumps was performed using the finite volume method in the OpenFOAM11 calculation package. The SIMPLE method was used for the calculation, and the MRF technology was used to account for rotation.

Results. As a result of the numerical experiment, relative head-flow characteristics for each pump were obtained, showing the influence of diameters D , d , and diagonality φ on the slope of the head-flow characteristic; these were approximated by a 3rd-degree polynomial using the least squares method. The obtained dependencies allow for determining the pump rotation speed for any of its operating regimes. From the generalization of the results of numerical modeling of blood flow in the pumps, 3D-surfaces were obtained, representing a set of dependencies of the head-flow characteristic slope on the geometric parameters of the pump flow path.

Conclusion. It was established that the required increase in head-flow characteristic slope can be achieved by changing the hub and shroud diameters and the angle of diagonality. The minimum slope is achieved at the average values of the numerical experiment factors. The maximum slope corresponds with minimum and maximum diameter values. The research results have a practical value for designing and improving axial pumps of the assisted blood circulation devices.

Keywords: axial pump; assisted blood circulation device; computational fluid dynamics; experiment planning; numerical simulation; finite volume method.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Krotov K.V., Boyarsky G.G., Khaustov A.I. The influence of the assisted blood circulation pumps geometry on their head-flow characteristics. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(1):189–205. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-189-205>

Received 27.01.2026

Accepted 25.02.2026

Published 31.03.2026

Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026;16(1):189–205

Введение

Заболевания сердечно-сосудистой системы [1] являются наиболее распространенной причиной смертности ежедневно, унося жизни более 10000 человек ежедневно¹. От самих заболеваний страдают более 523 млн человек². По всему миру наблюдается тенденция роста количества заболеваний сердца [2]. Количество первично-обнаруженных заболеваний также возросло [3], в том числе сердечной недостаточности [4]. При этом количество смертей, вызванных болезнями сердца, за последние 50 лет, по крайней мере в США, ежегодно повышается [5]. Однако количество донорских сердец с каждым годом растет значительно медленнее, а количество операций составляет порядка 2-3 тысяч ежегодно [6].

Для педиатрических пациентов ситуация значительно сложнее. Так, почти за 25 лет (с 1994 по 2018 гг.) проведено всего 7500 операций по пересадке

сердца [7]. В США, например, проводится всего около 200 операций ежегодно [8]. При этом, по крайней мере в США, наблюдается рост педиатрических пациентов с сердечно-сосудистыми заболеваниями на 36,3% [9].

В настоящее время для поддержки CCC пациентов различного возраста, в т. ч. педиатрических, применяют аппараты вспомогательного кровообращения (АВК), основным элементом которых является насос, компенсирующий насосную функцию сердца для поддержания необходимой циркуляции крови [10].

Успешное применение АВК в медицинской практике и накопленный опыт позволили повысить качество жизни, выживаемость и другие важнейшие эксплуатационные параметры [11]. Также отмечается, что современные системы могут помочь в реабилитации и реконструкции миокарда [12]. Следующий этап по совершенствованию этих систем – расширение диапазона их применения в нерасчетные для них диапазоны подач и напоров, что приведет к дальнейшему улучшению качества жизни.

Современная теория гидравлических машин выработала рекомендации для проектирования насосов из условия достижения максимума КПД, высоких кавитационных свойств. Такой подход хорошо зарекомендовал себя в машиностроении, авиации, космонавтике, нефтяной промышленности и т. п. Однако для насосов АВК обеспечение максимального КПД и/или высоких ка-

¹ В Европейском регионе ВОЗ сердечно-сосудистые заболевания ежедневно уносят жизни 10 000 человек, причем мужчины умирают чаще, чем женщины // Всемирная организация здравоохранения. URL: <https://www.who.int/europe/ru/news/item/15-05-2024-cardiovascular-diseases-kill-10-000-people-in-the-who-european-region-every-day--with-men-dying-more-frequently-than-women> (дата обращения: 11.12.2025).

² ВОЗ: каждый год в мире умирает от сердечно-сосудистых заболеваний 17,9 млн человек // Высшая школа организации и управления здравоохранением. URL: <https://www.vshouz.ru/news/analitika/wcs-19279> (дата обращения: 11.12.2025).

витационных свойств не является определяющими параметрами. Основным критерием оптимизации является обеспечение допустимого уровня травмы крови во всем диапазоне работы насоса АВК: от максимальной нагрузки на сердечную мышцу до положения покоя [13].

Обобщение результатов клинического применения АВК систем показало, что кроме допустимых гемолитиче-

ских свойств насосы АВК должны иметь наклон напорно-расходной характеристики (НРХ), близкий к показанной зеленой линии (рис. 1), чтобы обеспечить режимы работы насоса АВК, близкие к физиологическим режимам работы ССС. Как видно, применяемые в настоящее время насосы АВК имеют НРХ, существенно отличные от требуемых НРХ.




Рис. 1. НРХ насосов HeartMate 3 и «Стрим Кардио» [14]

Fig. 1. PFC of HearMate 3 and "Stream Cardio pumps" [14]

Целью работы является определение влияния геометрических параметров насосов на их напорно-расходные

характеристики для обеспечения физиологического режима его работы в ССС.

Материалы и методы

Наибольшее распространение в мировой клинической практике получила система *HeartMate 3*¹, а в России – система «Стрим Кардио»². В качестве нагнетательного элемента в *HeartMate 3* используется центробежный (рис. 2), в «Стрим Кардио» – осевой (рис. 3) насосы.



Рис. 2. Насос *HeartMate 3*

Fig. 2. *HeartMate 3* LVAD

На рисунке 1 **Рис. 1** представлены напорно-расходные характеристики (НРХ, *pressure-flow characteristics, PFC*) *HeartMate 3* и «Стрим Кардио».

¹ ФСЗ 2011/09288. Система *HeartMate*, для вспомогательного кровообращения и поддержания функции левого желудочка сердца для альтернативы трансплантации сердца (*HeartMate Left Ventricular Assist System*), с принадлежностями / заявитель ООО «Эбботт Лэбораториз». № 36473; опубл. 20.11.19.

² РЗН 2018/6908. Комплекс универсальный для механической поддержки насосной функции левого и правого желудочков сердца – «СТРИМ КАРДИО» по ТУ 32.50.50-000-74110342-2017 / заявитель Общество с ограниченной ответственностью «ДОНА-М». № 27569; опубл. 12.03.2018.

Как видно, насосы имеют плавно-падающие НРХ, особенно насос «Стрим Кардио», когда незначительное изменение давления в ССС приводит к существенному изменению подачи насоса.



Рис. 3. Насос Стрим Кардио

Fig. 3. *Stream Cardio* LVAD

Рассмотрим динамический осевой насос АВК «Стрим Кардио» (рис. 4). Кровь забирается из канюли (не показана на рис. 4), подключенной к левому желудочку через направляющий аппарат (НА, поз. 1). Вращающееся рабочее колесо (поз. 2) с профилированными лопатками (поз. 3) передает крови кинетическую энергию, которая в спрямляющем аппарате (поз. 4) преобразуется в потенциальную энергию, тем самым создавая давление, с которым кровь через подключенную к аорте канюли поступает в ССС.

В работах [15] и [16] показано, что основными параметрами, которые влияют на гемолитические и напорно-расходные параметры, являются геометрические размеры насоса: диаметры периферии D и втулки d , угол диагональности φ рабочего колеса насоса.

Для оценки влияния геометрических параметров на наклон НРХ разработан

трехфакторный план численного эксперимента с факторами: диаметр втулки d , диаметр периферии D , угол диагональности φ рабочего колеса, которые изменя-

лись дискретно: $d = [8, 9, 10]$ мм; $D = [12, 13, 14]$ мм; $\varphi = [20, 45, 60]^\circ$, который включает 21 насос с возможными комбинациями факторов (табл. 1).




Рис. 4. Геометрия проточной части осевого насоса

Fig. 4. Axial pump flow domain geometry

Таблица 1. Трехфакторный план численного моделирования

Table 1. Three-factor numerical experiment plan

№ насоса	D , мм	d , мм	φ , °	№ насоса	D , мм	d , мм	φ , °	№ насоса	D , мм	d , мм	φ , °
1	12	8	20	8	12	10	60	15	14	8	45
2	12	8	45	9	13	8	20	16	14	8	60
3	12	8	60	10	13	9	20	17	14	9	20
4	12	9	20	11	13	10	20	18	14	9	60
5	12	9	60	12	13	10	45	19	14	10	20
6	12	10	20	13	13	10	60	20	14	10	45
7	12	10	45	14	14	8	20	21	14	10	60

В работе выполнялось математическое моделирование течения вязкой несжимаемой жидкости в насосе. Уравнения математической модели решались методом конечных объемов, реализованным в ПО *OpenFOAM* 11 (*The OpenFOAM Foundation*, США), которое

применяется для математического моделирования течения жидкости [17], в том числе в осевых [18], в центробежных [19] и в других насосах. В расчетах принималось, что рабочее тело – это однокомпонентная однофазная несжимаемая неньютоновская жидкость с

вязкостью 3,5 мПа·с и плотностью 1035 кг/м³.

Для определения распределения скорости, давления и производных параметров течения в проточной части насосов использовался алгоритм *Semi-Implicit Method for Pressure-Linked Equations (SIMPLE)*. Для учета турбулентности выбрана модель турбулентности $k-\omega$ SST с низкорейнольдсовскими пристеночными функциями, которая применяется для расчета лопастных машин и АВК¹.

Для каждого из насосов строилась неструктурированная тетраэдрическая сетка, которая уточнялась в областях контакта или зазора между рабочим колесом и неподвижными частями насоса. Уточнение производилось, во-первых, для учета градиента скорости, во-вторых, для поддержания качества сетки по неортогональности и скошенности, однако все сетки имели приблизительно одинаковое количество элементов (около 6-7 млн); y^+ сеток меньше 2 и почти везде меньше 1; неортогональность ячеек была меньше 65°, скошенность – менее 4. Каждая из сеток проверена на сеточную независимость при помощи перерасчета с увеличенным количеством элементов (примерно до 10 млн). На рисунке 5 показан пример сетки для насоса № 14.

¹ Guerrero J. 18th OpenFOAM Workshop 2023 – Validation Challenge. URL: <https://doi.org/10.6084/M9.FIGSHARE.24080892.V2> (дата обращения: 18.12.2025).

Результаты и их обсуждение

На рисунке 6 в качестве примера представлены результаты численного моделирования насосов № 7, 8 для частот n от 6000 до 10000 об/мин, где Δp – повышение давления насосом, как разность осредненных по площади статических давлений между выходным и входным сечениями насоса; $\dot{V}$ – объемная подача насоса. Относительные зависимости $\Delta p / n^2 = f(\dot{V} / n)$ этих насосов представлены на рисунке 7, из которого следует, что относительные характеристики не зависят от частоты вращения и они могут быть аппроксимированы многочленом вида

$$\frac{\Delta p}{n^2} = a_3 \left(\frac{\dot{V}}{n} \right)^3 + a_2 \left(\frac{\dot{V}}{n} \right)^2 + a_1 \left(\frac{\dot{V}}{n} \right) + a_0, \quad (1)$$

где коэффициенты a_i определяются по методу наименьших квадратов по результатам численного эксперимента.

Коэффициенты аппроксимационных зависимостей для $\Delta p / n^2 = f(\dot{V} / n)$ насосов представлены ниже (табл. 2). Полученные зависимости позволяют определять частоту вращения насоса для любого его режима работы. В таблице 2 также представлены частоты вращения насоса $n_{\text{раб}}$, при которых обеспечиваются параметры рабочей точки: $\dot{V} = 1,8$ л/мин, и повышение давления $\Delta p = 77$ мм рт. ст., что соответствует рабочей точке для BSA (площадь поверхности тела, *body surface area*) от 0,8 до 1,5 м² с диапазоном изменения расхода от 0,3 до 3 л/мин [20].




Рис. 5. Сетка насоса №14

Fig. 5. Pump №14 Mesh




Рис. 6. НРХ насосов: а – № 7; б – № 8

Fig. 6. PFC of pumps: а – № 7; б – № 8




Рис. 7. Относительная НРХ насосов: а – № 7; б – № 8

Fig. 7. Normalized PFC of pumps: а – № 7; б – № 8

Таблица 2. Аппроксимационные коэффициенты НРХ для формулы (1)**Table 2.** Approximated coefficients of PCF equation (1)

№	a_0	a_1	a_2	a_3	$n_{\text{раб}}$, об/мин
1	8,02E-07	-1,22E-03	1,36	-340,14	11000
2	8,10E-07	-6,28E-04	0,01	289,97	10500
3	8,25E-07	-7,02E-04	0,15	171,99	10500
4	9,09E-07	-1,05E-03	0,77	-278,87	10000
5	8,85E-07	-9,05E-04	0,93	-719,47	10000
6	1,06E-06	-1,93E-03	1,7	-1592,58	10000
7	9,25E-07	-9,70E-04	0,34	-914,66	10000
8	2,57E-07	-2,61E-04	-0,83	-730,3	8500
9	1,06E-06	-1,01E-03	1,09	-669,92	9500
10	9,74E-07	-5,21E-04	-0,33	388,84	9500
11	1,09E-06	-6,29E-04	-0,59	678,32	9000
12	1,00E-06	-1,21E-03	2,75	-2555,96	9500
13	9,26E-07	-3,40E-04	-0,4	371,68	9500
14	1,26E-06	-1,47E-03	-0,09	1084	9000
15	1,03E-06	-1,17E-03	0,62	202,21	9500
16	1,34E-06	-4,25E-03	7,56	-4606,95	10000
17	1,16E-06	-6,36E-04	-0,65	841,63	8500
18	1,19E-06	-1,12E-03	0,35	377,73	9000
19	1,28E-06	-7,89E-04	-0,01	162,88	8500
20	1,23E-06	-6,92E-04	-0,43	858,45	8500
21	1,01E-06	-9,66E-04	0,4	364,21	9500

На рисунке 8 показано влияние диаметров D , d и диагональности ϕ на наклон НРХ. Как видно из рисунка 8, наклон НРХ для рабочей точки 1,8 л/мин и 75 мм рт. ст. в рабочем диапазоне от 0,3 до 3 л/мин может быть с достаточной точностью аппроксимирован прямой линией (отмечена как «ЛН» (линия наклона)). Тангенс угла α представляет собой наклон напорно-расходной характеристики насоса, т. е. $\text{tg}(\alpha) = d\Delta p / d\dot{V}$, или отношение по-

вышения давления насоса (изменение противодействия в ССС) к изменению подачи насоса (изменению количества крови, поступающей в аорту ССС).

Из обобщения результатов численного моделирования течения крови в насосах получены трехмерные поверхности (рис. 9–11), представляющие множество зависимостей наклона НРХ от геометрических параметров проточной части насосов. Серой плоскостью показан желаемый тангенс угла наклона (см. рис. 1).




Рис. 8. НРХ насосов

Fig. 8. PFC of pumps




Рис. 9. Зависимость наклона НРХ для диагональности: $\varphi = 20^\circ$; $\dot{V} = 1,8$ л/мин; $\Delta p = 77$ мм рт. ст.

Fig. 9. Distribution of PCF's angle by diagonality angle: $\varphi = 20^\circ$; $\dot{V} = 1,8$ l/min; $\Delta p = 77$ mmHg




Рис. 10. Зависимость наклона НРХ для диагональности: $\varphi = 45^\circ$; $\dot{V} = 1,8$ л/мин; $\Delta p = 77$ мм рт. ст.

Fig. 10. Distribution of PCF's angle by diagonality angle: $\varphi = 45^\circ$; $\dot{V} = 1,8$ l/min; $\Delta p = 77$ mmHg




Рис. 11. Зависимость наклона НРХ для диагональности: $\varphi = 60^\circ$; $\dot{V} = 1,8$ л/мин; $\Delta p = 77$ мм рт. ст.

Fig. 11. Distribution of PCF's angle by diagonality angle: $\varphi = 60^\circ$; $\dot{V} = 1,8$ l/min; $\Delta p = 77$ mmHg

Выводы

Обобщая данные, полученные в результате математического моделирования течения крови, доказано, что изменение диагональности проточной части двояко влияет на угол наклона НРХ: изменением диаметров втулки и периферии при диагональности равной 20° и 60° можно добиться требуемого увеличения угла наклона НРХ. При этом наибольшее увеличение угла наклона НРХ достигается для комбинации параметров $d = 8$ мм, $D = 14$ мм, $\varphi = 60^\circ$. Отмечено, что изменения диаметров втулки и периферии практически не влияют на наклон НРХ при диагональности $\varphi = 45^\circ$. Следует так-

же отметить, что минимальные значения наклона НРХ наблюдается при средних значениях диаметрах втулки и периферии, равных $d = 9$ мм и $D = 13$ мм, соответственно.

Экстраполируя полученные результаты математического моделирования, можно сделать вывод, что дальнейшее уменьшение диаметра втулки (менее 8 мм) при увеличении диагональности более 60° , а также при уменьшении диаметра периферии (менее 12 мм) при диагональности менее 20° приводит к увеличению наклона НРХ и достижению требуемых значений наклона НРХ для клинического применения насосов АВК.

В дальнейшем предполагается выявить закономерности наклона НРХ не только от геометрических параметров АВК, но и от густоты, числа лопаток рабочего колеса. Это позволит создавать более совершенные АВК, подходящие большему количеству пациентов.

Список литературы

1. The Heart of the World / M. Di Cesare, P. Perel, S. Taylor, C. Kabudula, H. Bixby, T. A. Gaziano [et al.] // Glob. Heart. 2024. N 19. P. 11. <https://doi.org/10.5334/gh.1288>
2. Global burden of heart failure: a comprehensive and updated review of epidemiology / G. Savarese, P. M. Becher, L. H. Lund, P. Seferovic, G. M. C. Rosano, A. J. S. Coats // Cardiovasc. Res. 2023. N 118. P. 3272–3287. <https://doi.org/10.1093/cvr/cvac013>
3. Sex-specific risk factors for new-onset heart failure: the PREVEND study at 25 years / B. J. Van Essen, J. E. Emmens, J. Tromp, W. Ouwerkerk, M. D. Smit, C. A. Geluk [et al.] // Eur. Heart. J. 2025. N 46. P. 1528–1536. <https://doi.org/10.1093/eurheartj/ehae868>
4. Global epidemiology of heart failure / M. S. Khan, I. Shahid, A. Bennis, A. Rakishcheva, M. Metra, J. Butler // Nat. Rev. Cardiol. 2024. N 21. P. 717–34. <https://doi.org/10.1038/s41569-024-01046-6>
5. Heart Disease Mortality in the United States, 1970 to 2022 / S. J. King, T. Y. Wangdak Yuthok, A. M. Bacong, A. Khandelwal, D. S. Kazi, M. E. Mussolino [et al.] // J. Am. Heart. Assoc. 2025. N 14. P. e038644. <https://doi.org/10.1161/JAHA.124.038644>
6. Twenty-year temporal and regional trends in heart transplantation in Europe: results from the Global Observatory on Donation and Transplantation (GODT) / Y. Manla, F. J. Al Badarin, M. Soliman, L. Gobolos, F. Alsindi, F. Bader // Eur. Heart. J. 2021. N 42. P. ehab724.0968. <https://doi.org/10.1093/eurheartj/ehab724.0968>
7. Early renal failure after primary thoracic organ transplantation / E. Hsich, T. P. Singh, W. S. Cherikh, A. Lewis, S. Kian, M. Perch [et al.] // J. Heart. Lung. Transplant. 2025. N 44. P. 1199–214. <https://doi.org/10.1016/j.healun.2024.11.042>
8. The International Thoracic Organ Transplant Registry of the International Society for Heart and Lung Transplantation: 2025 Annual Report of Heart and Lung Transplantation / T. P. Singh, E. Hsich, W. S. Cherikh, M. Perch, D. Hayes, A. Lewis [et al.] // J. Heart. Lung. Transplant. 2025. P. S1053249825019205. <https://doi.org/10.1016/j.healun.2025.04.014>
9. OPTN/SRTR 2023 Annual Data Report: Heart / M. M. Colvin, J. M. Smith, Y. S. Ahn, K. A. Lindblad, D. Handarova, A. K. Israni [et al.] // Am. J. Transplant. 2025. N 25. P. S329–421. <https://doi.org/10.1016/j.ajt.2025.01.024>
10. Left Ventricular Assist Devices: A Primer For the General Cardiologist / S. Chaudhry, A. D. DeVore, H. Vidula, M. Nassif, K. Mudy, E. Y. Birati [et al.] // J. Am. Heart. Assoc. 2022. N 11. P. e027251. <https://doi.org/10.1161/JAHA.122.027251>

11. Schmidt T., Reiss N. LVAD in der kardiologischen Rehabilitation: Leistungsphysiologische und rhythmologische Aspekte // *Herzschrittmachertherapie Elektrophysiologie*. 2023. N 34. P. 45–51. <https://doi.org/10.1007/s00399-022-00914-3>
12. LVAD therapy as a catalyst to heart failure remission and myocardial recovery / E. A. Hamad, M. Byku, S. B. Larson, F. Billia // *Clin. Cardiol.* 2023. N 46. P. 1154–62. <https://doi.org/10.1002/clc.24094>
13. Хаустов А. И., Боярский Г. Г., Кротов К. В. Разработка микронасосной системы для поддержки кровообращения // *Известия высших учебных заведений России. Радиоэлектроника*. 2022. № 25(5). С. 104–112. <https://doi.org/10.32603/1993-8985-2022-25-5-104-112>
14. Physiology and Clinical Utility of HeartMate Pump Parameters / M. N. Belkin, V. Kagan, C. Labuhn, S. P. Pinney, J. Grinstein // *J. Card. Fail.* 2022. N 28. P. 845–862. <https://doi.org/10.1016/j.cardfail.2021.11.016>
15. Кротов К. В., Хаустов А. И. Влияние геометрических параметров насосов аппарата вспомогательного кровообращения на их гемолитические характеристики // *Моделирование, оптимизация и информационные технологии*. 2025. № 13(1). С. 1–12. <https://doi.org/10.26102/2310-6018/2025.48.1.028>
16. Кротов К. В., Хаустов А. И., Боярский Г. Г. Моделирование травмы крови в силовом поле // *Математическое моделирование на суперЭВМ экса- и зеттафлопсной производительности: сборник тезисов конференции*. Саров: Российский федеральный ядерный центр – Всероссийский НИИ экспериментальной физики, 2022. С. 56–57. https://doi.org/10.53403/9785951505224_56
17. Numerical computations of blood flow through stenosed arteries via CFD tool OpenFOAM / S. Nadeem, S. Akhtar, A. Saleem, N. Akkurt, H. Ali Ghazwani, S. M. Eldin // *Alex. Eng. J.* 2023. N 69. P. 613–637. <https://doi.org/10.1016/j.aej.2023.02.005>
18. Technique for axial pump characteristics predicting in CFD package OpenFOAM / E. A. Ivanov, A. A. Zharkovsky, I. O. Borshchev, D. G. Svoboda // *AIP Conference Proceedings: Oil and Gas Engineering Conference*. New York: American Institute of Physics Inc., 2019. Vol. 2141, is. 1. P. 030063. <https://doi.org/10.1063/1.5122113>
19. Numerical simulation research on multiphase flow of aviation centrifugal pump based on OpenFOAM / X. Liu, J. Fu, J. Yang, D. Yin, Z. Zhou, H. Li // *Chin. J. Aeronaut.* 2024. N 37. P. 256–275. <https://doi.org/10.1016/j.cja.2023.11.016>
20. Механические устройства поддержки кровообращения для пациентов с малыми антропометрическими показателями / О. Ю. Есипова, А. С. Есипов, А. П. Кулешов, Н. В. Грудинин // *Вестник трансплантологии и искусственных органов*. 2024. № 26(1). С. 78–87. <https://doi.org/10.15825/1995-1191-2024-1-78-87>

References

1. Di Cesare M., Perel P., Taylor S., Kabudula C., Bixby H., Gaziano T.A., et al. The Heart of the World. *Glob Heart*. 2024;(19):11. <https://doi.org/10.5334/gh.1288>
2. Savarese G., Becher P.M., Lund L.H., Seferovic P., Rosano G.M.C., Coats A.J.S. Global burden of heart failure: a comprehensive and updated review of epidemiology. *Cardiovasc Res*. 2023;(118):3272–3287. <https://doi.org/10.1093/cvr/cvac013>
3. Van Essen B.J., Emmens J.E., Tromp J., Ouwerkerk W., Smit M.D., Geluk C.A., et al. Sex-specific risk factors for new-onset heart failure: the PREVEND study at 25 years. *Eur Heart J*. 2025;(46):1528–1536. <https://doi.org/10.1093/eurheartj/ehae868>
4. Khan M.S., Shahid I., Bennis A., Rakisheva A., Metra M., Butler J. Global epidemiology of heart failure. *Nat. Rev. Cardiol*. 2024;(21):717–34. <https://doi.org/10.1038/s41569-024-01046-6>
5. King S.J., Wangdak Yuthok T.Y., Bacong A.M., Khandelwal A., Kazi D.S., Mussolino M.E., et al. Heart Disease Mortality in the United States, 1970 to 2022. *J. Am. Heart. Assoc.* 2025;(14):e038644. <https://doi.org/10.1161/JAHA.124.038644>
6. Manla Y., Al Badarin F.J., Soliman M., Gobolos L., Alsindi F., Bader F. Twenty-year temporal and regional trends in heart transplantation in Europe: results from the Global Observatory on Donation and Transplantation (GODT). *Eur. Heart. J.* 2021;(42):ehab724.0968. <https://doi.org/10.1093/eurheartj/ehab724.0968>
7. Hsich E., Singh T.P., Cherikh W.S., Lewis A., Kian S., Perch M., et al. Early renal failure after primary thoracic organ transplantation. *J. Heart. Lung. Transplant.* 2025;(44):1199–214. <https://doi.org/10.1016/j.healun.2024.11.042>
8. Singh T.P., Hsich E., Cherikh W.S., Perch M., Hayes D., Lewis A., et al. The International Thoracic Organ Transplant Registry of the International Society for Heart and Lung Transplantation: 2025 Annual Report of Heart and Lung Transplantation. *J. Heart. Lung. Transplant.* 2025;S1053249825019205. <https://doi.org/10.1016/j.healun.2025.04.014>
9. Colvin M.M., Smith J.M., Ahn Y.S., Lindblad K.A., Handarova D., Israni A.K., et al. OPTN/SRTR 2023 Annual Data Report: Heart. *Am. J. Transplant.* 2025;(25):S329–421. <https://doi.org/10.1016/j.ajt.2025.01.024>
10. Chaudhry S., DeVore A.D., Vidula H., Nassif M., Mudy K., Birati E.Y., et al. Left Ventricular Assist Devices: A Primer For the General Cardiologist. *J. Am. Heart. Assoc.* 2022;(11):e027251. <https://doi.org/10.1161/JAHA.122.027251>
11. Schmidt T., Reiss N. LVAD in der kardiologischen Rehabilitation: Leistungsphysiologische und rhythmologische Aspekte. *Herzschrittmachertherapie Elektrophysiologie*. 2023;(34):45–51. <https://doi.org/10.1007/s00399-022-00914-3>

12. Hamad E.A., Byku M., Larson S.B., Billia F. LVAD therapy as a catalyst to heart failure remission and myocardial recovery. *Clin Cardiol.* 2023;(46):1154–62. <https://doi.org/10.1002/clc.24094>
13. Khaustov A.I., Boyarsky G.G., Krotov K.V. Development of a micro-pump system to support blood circulation. *Izvestiya vysshikh uchebnykh zavedenii Rossii. Radioelektronika = Proceedings of Higher Educational Institutions of Russia. Radio Electronics.* 2022;(25):104–112. (In Russ.) <https://doi.org/10.32603/1993-8985-2022-25-5-104-112>
14. Belkin M.N., Kagan V., Labuhn C., Pinney S.P., Grinstein J. Physiology and Clinical Utility of HeartMate Pump Parameters. *J. Card. Fail.* 2022;(28):845–862. <https://doi.org/10.1016/j.cardfail.2021.11>
15. Krotov K.V., Khaustov A.I. Influence of geometric parameters of pumps of the auxiliary circulation apparatus on their hemolytic characteristics. *Modelirovanie, optimizatsiya i informatsionnye tekhnologii = Modeling, Optimization, and Information Technology.* 2025;(13):1-12. (In Russ.) <https://doi.org/10.26102/2310-6018/2025.48.1.028>
16. Krotov K.V., Khaustov A.I., Boyarskii G.G. Modeling of blood trauma in a force field. In: *Matematicheskoe modelirovanie na superEVM eksa- i zettaflopsnoi proizvoditel'nosti: sbornik tezisov konferentsii = Mathematical modeling on supercomputers of ex- and ztaflop performance: A collection of conference abstracts.* Sarov: Rossiiskii federal'nyi yadernyi tsentr – Vserossiiskii NII eksperimental'noi fiziki; 2022. P. 56-57. (In Russ.) https://doi.org/10.53403/9785951505224_56
17. Nadeem S., Akhtar S., Saleem A., Akkurt N., Ali Ghazwani H., Eldin S.M. Numerical computations of blood flow through stenosed arteries via CFD tool OpenFOAM. *Alex. Eng. J.* 2023;(69):613–37. <https://doi.org/10.1016/j.aej.2023.02.005>
18. Ivanov E.A., Zharkovsky A.A., Borshchev I.O., Svoboda D.G. Technique for axial pump characteristics predicting in CFD package OpenFOAM. In: *AIP Conference Proceedings: Oil and Gas Engineering Conference.* Vol. 2141, is. 1. New York: American Institute of Physics Inc.; 2019. P. 030063. <https://doi.org/10.1063/1.5122113>
19. Liu X., Fu J., Yang J., Yin D., Zhou Z., Li H. Numerical simulation research on multiphase flow of aviation centrifugal pump based on OpenFOAM. *Chin. J. Aeronaut.* 2024;(37):256–75. <https://doi.org/10.1016/j.cja.2023.11.016>
20. Esipova O.Yu., Esipov A.S., Kuleshov A.P., Grudin N.V. Mechanical circulatory support devices for patients with low anthropometric parameters. *Vestnik transplantologii i iskusstvennykh organov = Bulletin of Transplantology and Artificial Organs.* 2024;(26):78–87. (In Russ.) <https://doi.org/10.15825/1995-1191-2024-1-78-87>

Информация об авторах / Information about the Authors

Кротов Кирилл Владимирович, аспирант кафедры 614, инженер, Московский авиационный институт (национальный исследовательский университет), г. Москва, Российская Федерация,
e-mail: Krotovkv@yandex.ru,
ORCID: 0009-0004-0688-9223

Kirill V. Krotov, Postgraduate at the Department 614, Moscow Aviation Institute (National Research University), Moscow, Russian Federation,
e-mail: Krotovkv@yandex.ru,
ORCID: 0009-0004-0688-9223

Боярский Глеб Геннадьевич, кандидат технических наук, ведущий инженер, Московский авиационный институт (национальный исследовательский университет), г. Москва, Российская Федерация,
e-mail: boyarskijgg@mai.ru

Gleb G. Boyarsky, Candidate of Sciences (Engineering), Lead engineer, Moscow Aviation Institute (National Research University), Moscow, Russian Federation,
e-mail: boyarskijgg@mai.ru

Хаустов Александр Иванович, доктор технических наук, профессор кафедры 614, Московский авиационный институт (Национальный исследовательский университет), г. Москва, Российская Федерация,
e-mail: khaustov.alex@mail.ru,
ORCID: 0000-0003-2131-751X

Alexander I. Khaustov, Doctor of Sciences (Engineering), Professor at the Department 614, Moscow Aviation Institute (National Research University), Moscow, Russian Federation,
e-mail: khaustov.alex@mail.ru,
ORCID: 0000-0003-2131-751X

<https://doi.org/10.21869/2223-1536-2026-16-1-206-220>

УДК 004.942

Нечеткие модели прогнозирования неврозов у преподавателей и студентов высшей школы

С. Н. Родионова¹✉, Н. А. Кореневский¹, А. А. Трусевич¹, Е. Д. Малыхина¹

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: knsofia@mail.ru

Резюме

Целью исследования является разработка нечетких моделей прогнозирования неврозов у преподавателей и студентов высшей школы, которые позволят повысить эффективность исследований за счет сокращения объема и исключения повторов традиционных опросников при сохранении высокой точности прогнозирования.

Методы. Исследование включало анализ психолого-педагогических и социологических данных, систематизацию факторов риска (академический и профессиональный стресс, цифровая нагрузка, социально-экономические условия). Для построения моделей была выбрана методология синтеза гибридных нечетких решающих правил, разработанная на кафедре биомедицинской инженерии Юго-Западного государственного университета, в соответствии с которой для каждого признака были определены соответствующие функции принадлежности, агрегированные в итоговое решающее правило. Оценка эффективности модели проводилась с использованием мер доверия к результатам классификации и контрольных выборок.

Результаты. В рамках исследования экспертным методом был сформирован комплекс предикторов для решения задачи прогнозирования невротических расстройств у преподавателей и студентов. В состав модели включены как традиционные, так и специфические факторы риска. Дополнительно учтены параметры цифровой гигиены и профессиональной нагрузки. На основе сформированного набора признаков синтезирована математическая модель классификации риска возникновения неврозов, обеспечивающая меру доверия к решающему правилу не хуже 0,92. Полученные результаты подтверждают, что предложенные модели обеспечивают высокое качество прогнозирования неврозов у преподавателей и студентов при существенном снижении нагрузки на респондента.

Заключение. В ходе проведенных исследований модели прогнозирования неврозов у преподавателей высшей школы и студентов, отличающиеся тем, что в них совместно с общепринятыми в медицине факторами риска используются показатели, характеризующие трудовой процесс, уровень информационной нагрузки, обеспечили уверенность в правильном принятии решения не хуже 0,9, что позволяет рекомендовать их для использования в медицинской практике.

Ключевые слова: невротические расстройства; прогнозирование; студенты; преподаватели; нечеткие модели; решающие правила.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Нечеткие модели прогнозирования неврозов у преподавателей и студентов высшей школы / С. Н. Родионова, Н. А. Корневский, А. А. Трусевич, Е. Д. Мalykhina // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 206–220. <https://doi.org/10.21869/2223-1536-2026-16-1-206-220>

Поступила в редакцию 16.01.2026

Подписана в печать 14.02.2026

Опубликована 31.03.2026

Fuzzy models for predicting neuroses in higher education teachers and students

Sofya N. Rodionova¹✉, Nikolay A. Korenevsky¹,
Alena A. Trusevich¹, Ekaterina D. Malykhina¹

¹ Southwest State University

50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: knsofia@mail.ru

Abstract

The purpose of the research is to develop fuzzy models for predicting neuroses in higher education teachers and students. These models will improve the effectiveness of research by reducing the volume and eliminating duplication of traditional questionnaires while maintaining high prediction accuracy.

Methods. The study included an analysis of psychological, pedagogical, and sociological data, and a systematization of risk factors (academic and professional stress, digital workload, and socioeconomic conditions). To build the models, we selected a hybrid fuzzy decision rule synthesis methodology developed at the Department of Biomedical Engineering at Southwestern State University. This methodology defined the corresponding membership functions for each feature and aggregated them into a final decision rule. Model performance was assessed using confidence measures for the classification results and validation samples.

Results. Using an expert method, we developed a set of predictors for predicting neurotic disorders in teachers and students. The model included both traditional and specific risk factors. Digital hygiene and occupational stress parameters were also considered. Based on the resulting set of features, a mathematical model for classifying the risk of developing neuroses was synthesized, providing a confidence measure for the decision rule of at least 0.92. The results confirm that the proposed models provide high-quality predictions of neuroses in teachers and students while significantly reducing respondent burden.

Conclusion In the course of the studies, models for predicting neuroses in university teachers and students, which are distinguished by their use of indicators characterizing the work process and level of information load in conjunction with generally accepted medical risk factors, provided a confidence level of at least 0.9 in correct decision-making, allowing them to be recommended for use in medical practice.

Keywords: neurotic disorders; prediction; students; teachers; fuzzy models; decision rules.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Rodionova S.N., Korenevsky N.A., Trusevich A.A., Malykhina E.D. Fuzzy models for predicting neuroses in higher education teachers and students. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(1):206–220. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-206-220>

Received 16.01.2026

Accepted 14.02.2026

Published 31.03.2026

Proceedings of the Southwest State University. Series: Control, Computer Engineering,
Information Science. Medical Instruments Engineering. 2026;16(1):206–220

Введение

По данным психологических, педагогических и социологических исследований, отмечается высокий уровень психологического неблагополучия как среди педагогов, так и среди студентов образовательных организаций [1, с. 39]. Причины неврозов и невротических расстройств у студентов и преподавателей связаны со специфическими раздражителями академической среды [2, с. 73-74].

Среди основных причин развития неврозов у студентов выделяют: академический стресс и перфекционизм, на фоне высокой учебной нагрузки, давления «сроков» сдачи текущей и итоговой работы в семестре, страха неудачи. По данным ВОЗ, до 30% студентов во всём мире демонстрируют симптомы, соответствующие клинически значимой тревоге и депрессии, связанные с академическим давлением [3, с. 65]. Исследования Национального союза студентов показывают, что 87% студентов испытывают финансовую неустойчивость из-за вынужденного совмещения работы с учёбой. По результатам опроса ВЦИОМ в России отмечают, что карьерные перспективы являются одним из ведущих источников тревоги для более 60% молодёжи. В ряде источников отмечается, что цифровизация образования приводит к существенному повышению нагрузки на зрительный анализатор, гиподинамии, синдрому «zoom-усталости».

Развитие профессиональных неврозов у педагогов также вызывается це-

лым рядом разнообразных причин [4, с. 261]. Согласно исследованиям НИУ ВШЭ, более 55% преподавателей испытывают сильный дискомфорт из-за гонки за публикациями Scopus и WoS, подвергаются давлению грантовой активности. Существенную роль играют: страх из-за «невыполнения плана» и угрозы потери позиции; административно-бюрократический прессинг; частые цейтноты и вынужденные конфликты с коллегами, подчиненными, начальством; ненормированные рабочие дни, сопровождающиеся трудом во внеурочное время; нехватка времени на отдых, сон и регулярное питание [5, с. 127-128]. Согласно опросу «Российского профессорского собрания» (РПС) и Общероссийского профсоюза образования, более 70% времени уходит на преподавательскую деятельность. Ряд исследователей в качестве профессиональных рисков отмечают низкие зарплаты и финансовые переживания, поиск подработок и, как следствие, еще более высокую загруженность и т. д. Часто проблема усложняется условиями жизни вне работы и индивидуальными особенностями организма. Согласно данным НИИ медицины труда им. Н. Ф. Измерова, выраженный синдром эмоционального выгорания наблюдается у 25-35% преподавателей вузов, а отдельные симптомы выгорания и хронического стресса (группа риска) – у 60-70% опрошенных [6, с. 113].

На сегодняшний день современная психодиагностика невротических рас-

стройств предлагает широкий арсенал опросников: как комплексных, охватывающих максимум симптомов (опросник SCL-90-R, шкалы Гамильтона и др.), так и специфических, специализирующихся на определенном расстройстве (шкала тревоги Спилбергера – Ханина, шкала депрессии Бека, симптомный опросник Derogatis и др.) [7, с. 8]. Однако их ключевой проблемой становятся объем и повторяемость. Длительность таких опросников ведет к утомлению и снижению концентрации внимания у обследуемых, а повторяющийся характер вопросов вызывает реактивное раздражение [8, с. 627-628]. Эти факторы напрямую влияют на качество данных, снижая надежность результатов, так как в них начинает преобладать не исходная симптоматика, а ситуационная усталость [9, с. 158-160].

В ходе исследований, проведенных на кафедре биомедицинской инженерии, было показано, что рационализация методики опроса существенно улучшает качество прогнозирования и ранней диагностики неврозов [10, с. 83].

Материалы и методы

Выбор состава информативных предикторов для синтеза решающих правил прогнозирования появления и развития неврозов у педагогов и студентов (класс $\omega_{НП}$) производился с учетом результатов, полученных в работе [11, с. 147]. В этой работе в качестве базовых переменных для синтеза функций принадлежности $\mu_{ВН}$ к классу $\omega_{ВН}$

предлагается следующий набор информативных признаков: прием лекарственных средств, вредно влияющих на нервную систему (LS); употребление алкоголя (AL); наследственная предрасположенность к нервным болезням (NP).

Используя алгоритм опорных точек по шкалам LS и AL с участием экспертов, была получена пара функций принадлежности, определяющих соответствующие уверенности в классе $\omega_{ВН}$ LS_N и AL_N [12, с. 36]:

$$LS_N = \mu_{ВН}(LS) = \begin{cases} 0, & \text{если } LS \leq 1, \\ 0,0625LS - 0,0625, & \text{если } LS > 1, \end{cases}$$

где значение LS определяется по опроснику вида:

- не принимаю – 0;
- реже чем 1 раз в год – 1;
- 2-5 раз в год – 2;
- 5-10 раз в год – 3; вида
- ежемесячно – 4;
- на постоянной основе – 5.

$$AL_N = \mu_{ВН}(AL) = \begin{cases} 0, & \text{если } AL \leq 2, \\ 0,067AL - 0,133, & \text{если } AL > 2, \end{cases}$$

где значение AL определяется по опроснику вида:

- не употребляю – 0;
- реже чем 1 раз в месяц – 1;
- один раз в месяц – 2;
- более одного раза в неделю – 3;
- один раз в неделю – 4;
- ежедневно – 5.

На экспертном уровне по данным работ [13, с. 105-107] было принято ре-

шение использовать функцию принадлежности $\mu_{\text{НП}}(NP)$:

$$NP_N = \mu_{\text{ВН}}(NP) = \begin{cases} 0,05NP, & \text{если } NP < 3, \\ 0,15, & \text{если } NP = 3, \end{cases}$$

где NP_N – уверенности в классе $\omega_{\text{ВН}}$ по показателю «наследственная предрасположенность».

Дополнительно к выбранным признакам предложено использовать 13 двоичных факторов риска (b_i), характеризующих клинические отклонения обследуемого (гормональные нарушения, эндокринные заболевания, аллергические заболевания и др.). С полным их перечнем можно ознакомиться в работе [14, с. 165]. Соответствующая функция принадлежности вычисляется по формуле

$$KD_N = \mu_{\text{ВН}}(KD) = 0,03 \sum_i b_i,$$

где $i = 1, \dots, 13$; KD_N – уверенности в классе $\omega_{\text{ВН}}$ по факторам риска b_i .

В следующую группу факторов риска вошли предикторы, связанные с профессиональной деятельностью педагогов и студентов, – психоэмоциональное напряжение (ПЭН) (Y_P) и длительное умственное утомление (УУ).

Для определения Y_P предложен сокращенный опросник вида:

- психоэмоционального напряжения не ощущаю – 0;
- легкое ПЭН, не приводящее к ощущению дискомфорта, – 1;
- среднее ПЭН, уходящее в процессе ежедневного отдыха, – 2;
- значительное ПЭН, требующее специальной релаксации, – 3;

– психическое перенапряжение, приводящее к психосоматическим заболеваниям, – 4.

Для определения уровня умственного утомления (УУ) Y_u предлагается использовать опросник вида:

- умственного утомления не ощущаю – 0;
- легкое УУ, не приводящее к ощущению дискомфорта, – 1;
- среднее УУ, уходящее в процессе ежедневного отдыха, – 2;
- значительное УУ, требующее специальной релаксации, – 3;
- умственное переутомление, приводящее к психосоматическим заболеваниям, – 4.

Сокращение опросников по ПЭН и умственному утомлению при сохранении высокого качества принятия решений компенсируется использованием оригинальных дополнительных предикторов.

С участием экспертов для были получены соответствующие функции принадлежности к классу $\omega_{\text{НП}}$ вида

$$Y_{P_{\text{н}}} = \mu_{\text{ВН}}(Y_P) = \begin{cases} 0, & \text{если } Y_P \leq 1, \\ 0,1 Y_P - 0,1, & \text{если } Y_P > 1, \end{cases}$$

$$Y_{U_{\text{н}}} = \mu_{\text{ВН}}(Y_u) = \begin{cases} 0, & \text{если } Y_u \leq 1, \\ 0,133 Y_u - 0,133, & \text{если } Y_u > 1, \end{cases}$$

где $Y_{P_{\text{н}}}$ и $Y_{U_{\text{н}}}$ – уверенности в классе $\omega_{\text{ВН}}$ по показателям длительное ПЭН и умственное утомление.

Анализ литературы показывает, что с ростом информационных потоков,

воздействующих на человека, растет количество психических и стрессобусловленных заболеваний. Таким образом, адекватная оценка изменений функционального статуса работников умственного труда предполагает комплексный учет факторов информационной нагрузки, включая как её объем (количественный аспект), так и содержательно-смысловые особенности (качественный аспект) [15, с. 34]. В работе [16, с. 5] уровень информационной нагрузки у офисных работников, основным инструментом которых является компьютер, что также характерно для преподавателей и студентов, предлагается определять по оценочным шкалам качества сигнала-носителя и скорости информационного потока. Для этого с учетом анализа существующих методик и экспертного мнения на кафедре биомедицинской инженерии ЮЗГУ было разработано два балльных опросника для оценки информационной нагрузки от контакта с видеомонитором по двум показателям: качеству представления информации на экране монитора (шкала Y_k) и скорости предъявления информации на экране монитора (шкала Y_c).

На шкалах баллов этих опросников с использованием алгоритма опорных точек с участием экспертов были получены функции принадлежности к классу $\omega_{ВН}$, определяющие соответствующие уверенности в классе $\omega_{ВН} UK$ и UC :

$$UK = \mu_{ВН}(Y_k) = \begin{cases} 0, & \text{если } Y_k \leq 1, \\ 0,083 Y_k - 0,083, & \text{если } Y_k > 1, \end{cases}$$

$$UC = \mu_{ВН}(Y_c) = 0,0625 Y_c.$$

В работе [17, с. 90] было показано, что одним из факторов риска появления и развития нервных болезней является длительный контакт преподавателей и студентов с персональными компьютерами (ПК) (показатель $Y_{ПК}$) и мобильными устройствами (МТ) (показатель $Y_{МТ}$). С учетом этого на экспертном уровне было принято решение включить в синтезируемую модель, составляющую уверенности в классе $\omega_{НП}$ по показателю время контакта с компьютером $PK = \mu_{ВН}(Y_{ПК})$ и мобильным $MT = \mu_{ВН}(Y_{МТ})$, определяемую по табличной модели, приведенной в работе [14, с. 167].

Анализ информационной нагрузки на преподавателей и студентов показывает, что основные информационные потоки распределяются следующим образом: сбор информации из различных источников с целью ее усвоения и подготовки к занятиям; осмысливание, переработка и запоминание и (или) фиксация информации на электронных или бумажных носителях; осмысленная передача структурированной информации обучающимся, коллегам, в ходе контрольных мероприятий и т. д. [18, с. 123]. С учетом такой специфики для оценки информационной нагрузки на преподавателей по согласованию с экспертной группой было принято решение использовать четыре обобщенных показателя: a_1 – количество часов, затрачиваемых на сбор информации; a_2 – количество часов, затрачиваемых на

переработку информации и ее документирование; a_3 – количество часов, затрачиваемых на передачу информации; a_4 – количество печатных листов подготовленной учебно-методической литературы; a_5 – количество печатных листов подготовленной научно-технической продукции [19, с. 312].

Для расчета уровня информационной нагрузки по показателям a_s ($s = 1, \dots, 5$) было принято решение использовать функции уровня информа-

ционной нагрузки $f_{ин}(a_s)$, графики которых строились с использованием алгоритма опорных точек. В качестве экспертов выступали ведущие преподаватели кафедры биомедицинской инженерии, авторы учебников, учебных пособий, монографий и статей в ведущих отечественных и зарубежных изданиях [20, с. 2].

В ходе проведенных исследований был получен следующий набор функций уровня информационной нагрузки:

$$f_{ин}(a_1) = \begin{cases} 0, & \text{если } a_1 < 300, \\ 0,00000163(a_1 - 300)^2, & \text{если } 300 \leq a_1 < 650, \\ 0,4 - 0,00000163(a_1 - 1000)^2, & \text{если } 650 \leq a_1 < 1000, \\ 0,4, & \text{если } a_1 \geq 1000, \end{cases}$$

$$f_{ин}(a_2) = \begin{cases} 0, & \text{если } a_2 < 300, \\ 0,00000278(a_2 - 300)^2, & \text{если } 300 \leq a_2 < 600, \\ 0,5 - 0,00000278(a_2 - 900)^2, & \text{если } 600 \leq a_2 < 900, \\ 0,5, & \text{если } a_2 \geq 900, \end{cases}$$

$$f_{ин}(a_3) = \begin{cases} 0, & \text{если } a_3 < 200, \\ 0,00000333(a_3 - 200)^2, & \text{если } 200 \leq a_3 < 500, \\ 0,6 - 0,00000333(a_3 - 800)^2, & \text{если } 500 \leq a_3 < 800, \\ 0,6, & \text{если } a_3 \geq 800, \end{cases}$$

$$f_{ин}(a_4) = \begin{cases} 0, & \text{если } a_4 < 10, \\ 0,000123(a_4 - 10)^2, & \text{если } 10 \leq a_4 < 55, \\ 0,5 - 0,000123(a_4 - 100)^2, & \text{если } 55 \leq a_4 < 100, \\ 0,5, & \text{если } a_4 \geq 100, \end{cases}$$

$$f_{ин}(a_5) = \begin{cases} 0, & \text{если } a_5 < 5, \\ 0,000187(a_5 - 5)^2, & \text{если } 5 \leq a_5 < 45, \\ 0,6 - 0,000187(a_5 - 85)^2, & \text{если } 45 \leq a_5 < 85, \\ 0,6, & \text{если } a_5 \geq 85. \end{cases}$$

Финальное решающее правило оценки уровня информационной нагрузки на преподавателей и студентов YIN с учетом роли каждой функции уровня информационной нагрузки $f_{ин}(a_s)$ имеет следующий вид:

$$YIN(s+1) = YIN(s) + f_{ин}(a_{s+1}) [1 - YIN(s)],$$

где $YIN(1) = f_{ин}(a_1)$; $s = 1, \dots, 5$.

Уверенность в классе $\omega_{вн}$ по показателю YIN определяется выражением

$$UIN_{\text{НП}} = \mu_{\text{ВН}}(YIN) = \begin{cases} 0, & \text{если } YIN < 0,2, \\ 2,22(YIN - 0,2)^2, & \text{если } 0,2 \leq YIN < 0,5, \\ 0,4 - 2,22(YIN - 0,8)^2, & \text{если } 0,5 \leq YIN < 0,8, \\ 0,4, & \text{если } YIN \geq 0,8. \end{cases}$$

Финальная модель прогнозирования появления и развития неврозов у преподавателей и студентов высшей школы с учетом роли каждой составляющей в принятии решений представляет собой модифицированную накопительную формулу Е. Шортлифа:

$$UF_{\text{ВН}}(j+1) = UF_{\text{ВН}}(j) + F_j[1 - UF_{\text{ВН}}(j)], \quad (1)$$

где $UF_{\text{ВН}}(1) = F_1 = LS_N$; $F_2 = AL_N$;

$F_3 = NP_N$; $F_4 = KD_N$; $F_5 = YP_{\text{П}}$;

$F_6 = YU_{\text{П}}$; $F_7 = UK$; $F_8 = UC$;

$F_9 = PK$; $F_{10} = MT$; $F_{11} = UIN_{\text{ВН}}$;

$j = 1, \dots, 10$; $q = 1, \dots, 11$.

Полученная прогностическая модель может быть использована как конечная модель для оценки уверенности в появлении и развития неврозов у преподавателей и студентов высшей школы, а также при решении задач классификации риска возникновения неврозов, наличия ранних стадий невротических расстройств, прогнозирования и диагностики ранних стадий неврозов работников умственного

труда, оценки качества работы операторов информационно насыщенных систем и др.

Результаты и их обсуждение

В качестве конкретного примера рассмотрим решение классификационной задачи построения решающих правил для выделения выбранных экспертами классами риска возникновения неврозов у преподавателей высшей школы и студентов.

Используя рекомендации [11, с. 147] на шкале $UF_{\text{ВН}}$, эксперты определили три функции принадлежности $\mu_{\omega_i}(UF_{\text{ВН}})$ к классам риска возникновения неврозов: $\omega_{\text{НН}}$ – риск возникновения невроза незначителен; $\omega_{\text{НВ}}$ – риск возникновения невроза достаточно высок; $\omega_{\text{ПН}}$ – «приходящий» невроз.

Графики функций принадлежности $\mu_{\omega_i}(UF_{\text{ВН}})$ приведены ниже (рис. 1).

Аналитически графики, приведенные на рисунке 1, описываются следующими выражениями:

$$\mu_{\omega_{\text{НН}}} = \begin{cases} 0,9, & \text{если } UF_{\text{ВН}} < 0,3, \\ -4,5UF_{\text{ВН}} + 2,25, & \text{если } 0,3 \leq UF_{\text{ВН}} < 0,5, \\ 0, & \text{если } UF_{\text{ВН}} \geq 0,5, \end{cases}$$

$$\mu_{\omega_{HB}} = \begin{cases} 0, & \text{если } UF_{BH} < 0,3, \\ 4,5UF_{BH} - 1,35, & \text{если } 0,3 \leq UF_{BH} < 0,5, \\ 0,9, & \text{если } 0,5 \leq UF_{BH} < 0,7, \\ -9UF_{BH} + 7,2, & \text{если } 0,7 \leq UF_{BH} < 0,8, \\ 0, & \text{если } UF_{BH} \geq 0,8, \end{cases}$$

$$\mu_{\omega_{PH}} = \begin{cases} 0, & \text{если } UF_{BH} < 0,7, \\ 9UF_{BH} - 6,3, & \text{если } 0,7 \leq UF_{BH} < 0,8, \\ 0,9, & \text{если } UF_{BH} \geq 0,8. \end{cases}$$




Рис. 1. Графики функций принадлежности к классам риска возникновения невроза

Fig. 1. Graphs of neurosis risk class membership functions

Задача классификации решается путем выбора максимальных значений функций принадлежности по классам:

$$\Omega_{\ell} = \max[\mu_{\omega_1}(UF_{BH}), \mu_{\omega_2}(UF_{BH}), \mu_{\omega_3}(UF_{BH})]. \quad (2)$$

При равенстве двух функций принадлежности решение принимается в пользу более тяжелого состояния.

Оценка качества принимаемых решений для модели (1) проводилась с использованием экспертного метода Дельфи, в результате чего было показано, что по наибольшим значениям функций принадлежности к классу ω_{BH} мера доверия к модели (1) превышает величину 0,95, а мера доверия по

наиболее часто встречающимся факторам риска составляет 0,92.

Оценка качества принимаемых решений для модели (2) проводилась как на экспертном уровне, так и на контрольных выборках. В ходе экспертного оценивания и математического моделирования была определена оценка степени доверия к модели (2) на уровне 0,9, что нашло отражение в максимальных значениях функций принадлежности, приведенных на рисунке 1. На контрольных выборках для классов ω_{HH} , ω_{HB} и ω_{PH} определялись такие показатели качества, как диагностическая чувствительность (ДС), диагностическая специфичность

(ДС), диагностическая эффективность (ДЭ) и прогностическая значимость положительных (ПЗ+) и отрицательных (ПЗ-) результатов. В результате проведенных испытаний были определены следующие показатели качества работы модели (2).

Для классов ω_{HH}, ω_{HB} : ДЧ = 0,93; ДС = 0,92; ДЭ = 0,92; ПЗ⁺ = 0,92; ПЗ⁻ = 0,93. Для классов ω_{HH}, ω_{HH} : все показатели превышают значение 0,98. Для классов ω_{HB} и ω_{HH} : ДЧ = 0,94; ДС = 0,91; ДЭ = 0,93; ПЗ⁺ = 0,91; ПЗ⁻ = 0,94.

Таким образом, результаты экспертного оценивания и статистических испытаний показали высокое качество работы полученных прогностических моделей.

Выводы

Проведенные исследования показали, что для улучшения качества прогнозирования неврозов у студентов и преподавателей необходимо модернизировать методику проведения опроса, уменьшив объем и повторяемость, при этом сохраняя максимальную точность и эффективность. Синтезированные модели прогнозирования неврозов у преподавателей высшей школы и студентов, отличающиеся тем, что в них совместно с общепринятыми в медицине факторами риска используются показатели, характеризующие трудовой процесс, уровень информационной нагрузки, позволяют получать уверенность в правильном принятии решения не хуже 0,9, что позволяет рекомендовать их для медицинской практики.

Список литературы

1. Мосунова К. А. Классовый невроз и его актуальность в трансгенерационной терапии // Обзор педагогических исследований. 2024. Т. 6, № 5. С. 38-45. <https://doi.org/10.58224/2687-0428-2024-6-5-38-45>
2. Сабирова Р. Ш., Умуркулова М. М., Куо Б. Ч. Х. Академический стресс на разных годах обучения // Вестник Карагандинского университета. Серия «Педагогика». 2020. Т. 100, № 4. С. 71–78. <https://doi.org/10.31489/2020Ped4/71-78>
3. Сёмина М. В., Фёдорова Е. П. Проявление академического стресса у студентов: теоретические аспекты исследования // Северо-Кавказский психологический вестник. 2023. Т. 21, № 3. С. 63–74. <https://doi.org/10.21702/ncpb.2023.3.5>
4. Моросанова В. И., Бондаренко И. Н., Доливец С. С. Академический стресс и психологические ресурсы достижения образовательных целей // Образование и наука. 2025. Т. 27, № 2. С. 108–134. <https://doi.org/10.17853/1994-5639-2025-2-108-134>
5. Гладышева О. В., Хабарова Т. Ю., Бакулина Л. С. Исследование влияния индивидуально-личностных особенностей на развитие невротических расстройств у педагогов образовательных организаций и студентов педагогического вуза // Международ-

ный научно-исследовательский журнал. 2022. № 3-3 (117). С. 126–133. <https://doi.org/10.23670/IRJ.2022.117.3.098>

6. Шамиева Н. С., Фархутдинова Л. В. Проблема эмоционального выгорания педагогов, работающих с детьми с расстройствами аутистического спектра // Наукосфера. 2021. № 12-2. С. 112–116. <https://doi.org/10.5281/zenodo.5809191>

7. Ларских М. В., Филиппова Т. В., Терехова Е. Ю. Формирование и развитие адаптивных копинг-стратегий у больных отделения неврозов // Медицинская психология в России. 2020. Т. 12, № 1 (60). С. 1-11. <https://doi.org/10.24412/2219-8245-2020-1-8>

8. Руденко С. Л. Взаимосвязь субъективного качества жизни и социального восприятия у лиц с истерическим неврозом // СибСкрипт. 2023. Т. 25, № 5 (99). С. 625–634. <https://doi.org/10.21603/sibscript-2023-25-5-625-634>

9. Метод диагностики преходящих невротических расстройств на основе гибридных нечетких моделей / Р. И. Сафронов, О. А. Кныш, С. Н. Родионова, Л. В. Стародубцева // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2025. Т. 15, № 1. С. 157–169. <https://doi.org/10.21869/2223-1536-2025-15-1-157-169>

10. Метод комплексной оценки уровня информативности классификационных признаков в условиях нечеткой структуры данных / Н. А. Корневский, В. В. Аксёнов, С. Н. Родионова, С. Н. Гонтарев, Л. П. Лазурина, Р. И. Сафронов // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. Т. 12, № 3. С. 80–96. <https://doi.org/10.21869/2223-1536-2022-12-3-80-96>

11. Прогнозирование появления и развития невротических расстройств, провоцируемых инженерным трудом / Н. А. Корневский, О. Ю. Лукаш, Р. И. Сафронов, С. Н. Родионова, С. П. Серегин, Г. В. Сипливый // Системный анализ и управление в биомедицинских системах. 2024. Т. 23, № 3. С. 146–153. <https://doi.org/10.36622/1682-6523.2024.23.3.020>

12. Оценка влияния трудовой деятельности на уровень адаптационного потенциала по характеристикам антиоксидантной системы / О. А. Кныш, Р. И. Сафронов, О. Ю. Лукаш, Л. В. Стародубцева // Вестник научных конференций. 2024. № 12-4 (112). С. 36–38.

13. Синтез моделей прогнозирования и диагностики профессиональных заболеваний на основе гибридной нечеткой технологии / Р. И. Сафронов, К. В. Разумова, А. Ю. Рыбаков, А. В. Лях // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2023. Т. 13, № 3. С. 102–121. <https://doi.org/10.21869/2223-1536-2023-13-3-102-121>

14. Использование показателей, характеризующих адаптационные механизмы для оценки уровня защиты организма от воздействия внешних факторов риска / Р. И. Сафронов, С. Н. Родионова, Е. В. Крикунова, Л. В. Стародубцева, С. С. Сергеева, А. В. Титова // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2021. Т. 11, № 4. С. 163–179. <https://doi.org/10.21869/2223-1536-2021-11-4-163-179>
15. Захаревская Е. А. Оценка влияния стрессовых реакций на функциональное состояние сотрудников ОВД // Психология и педагогика служебной деятельности. 2023. № 1. С. 33–38. <https://doi.org/10.24412/2658-638X-2023-1-33-38>
16. Методика определения психической надежности сотрудников транспортной безопасности с использованием машинного обучения / Е. В. Жовнерчук, В. А. Чичкалюк, И. Ю. Жовнерчук [и др.] // Психическое здоровье. 2022. Т. 17, № 12. С. 3–10. <https://doi.org/10.25557/2074-014X.2022.12.3-10>
17. Сафронов Р. И. Синтез нечетких моделей оценки влияния производственной среды на состояние здоровья работников по факторам трудовой адаптации // Системный анализ и управление в биомедицинских системах. 2023. Т. 22, № 3. С. 89–98. <https://doi.org/10.36622/VSTU.2023.22.3.012>
18. Мультимодальный классификатор медицинского риска на основе многоэлектродного биоимпедансного преобразователя / А. В. Серебровский, Н. А. Корсунский, А. В. Лях, В. Н. Мишустин, О. В. Шаталова, Л. В. Шульга // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 3. С. 121–143. <https://doi.org/10.21869/2223-1536-2024-14-3-121-143>
19. A systematic review of the neurobiological and clinical features of neurasthenia (F48.0): Redefining a modern entity / J. Garcia-Campayo [et al.] // Journal of Affective Disorders. 2023. Vol. 333. P. 311–323. <https://doi.org/10.1016/j.jad.2023.04.040>
20. Somatic symptom disorder: A primary diagnosis in patients with prominent medically unexplained symptoms / H. Zaman [et al.] // General Hospital Psychiatry. 2024. Vol. 86. P. 1–8. <https://doi.org/10.1016/j.genhosppsych.2023.11.007>

References

1. Mosunova K.A. Class neurosis and its relevance in transgenerational therapy. *Obozor pedagogicheskikh issledovanij = Review of Pedagogical Research*. 2024;6(5):38–45. (In Russ.) <https://doi.org/10.58224/2687-0428-2024-6-5-38-45>
2. Sabirova R.Sh., Umurkulova M.M., Kuo B.Ch.Kh. Academic stress in different years of study. *Vestnik Karagandinskogo universiteta. Seriya «Pedagogika» = Bulletin of the Karaganda University. Pedagogy Series*. 2020;100(4):71–78. (In Russ.) <https://doi.org/10.31489/2020Ped4/71-78>

3. Semina M.V., Fedorova E.P. Manifestation of academic stress in students: theoretical aspects of the study. *Severo-Kavkazskij psihologicheskij vestnik = North Caucasian Psychological Bulletin*. 2023;21(3):63-74 (In Russ.) <https://doi.org/10.21702/ncpb.2023.3.5>
4. Morosanova V.I., Bondarenko I.N., Dolivets S.S. Academic stress and psychological resources for achieving educational goals. *Obrazovanie i nauka = The Education and Science Journal*. 2025;27(2):108-134. (In Russ.) <https://doi.org/10.17853/1994-5639-2025-2-108-134>
5. Gladysheva O.V., Khabarova T.Yu., Bakulina L.S. Study of the influence of individual personal characteristics on the development of neurotic disorders in teachers of educational organizations and students of a pedagogical university. *Mezhdunarodnyj nauchno-issledovatel'skij zhurnal = International Research Journal*. 2022;(3-3):126-133. (In Russ.) <https://doi.org/10.23670/IRJ.2022.117.3.098>
6. Shamieva N.S., Farkhutdinova L.V. The problem of emotional burnout of teachers working with children with autism spectrum disorders. *Naukosfera = Naukosphere*. 2021;(12-2):112-116. (In Russ.) <https://doi.org/10.5281/zenodo.5809191>
7. Larskikh M.V., Filippova T.V., Terekhova E.Yu. Formation and development of adaptive coping strategies in patients of the neurosis department. *Medicinskaya psihologiya v Rossii = Medical Psychology in Russia*. 2020;12(1):1-11. (In Russ.) <https://doi.org/10.24412/2219-8245-2020-1-8>
8. Rudenko S.L. The relationship between subjective quality of life and social perception in individuals with hysterical neurosis. *SibScript = SibScript*. 2023;25(5):625-634. (In Russ.) <https://doi.org/10.21603/sibscript-2023-25-5-625-634>
9. Safronov R.I., Knysh O.A., Rodionova S.N., Starodubtseva L.V. Method for diagnosing transient neurotic disorders based on hybrid fuzzy models. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2025;15(1):157-169. (In Russ.) <https://doi.org/10.21869/2223-1536-2025-15-1-157-169>
10. Korenevskiy N.A., Aksenov V.V., Rodionova S.N., Gontarev S.N., Lazurina L.P., Safronov R.I. Method for comprehensive assessment of the level of information content of classification features in conditions of fuzzy data structure. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2022;12(3):80-96. (In Russ.) <https://doi.org/10.21869/2223-1536-2022-12-3-80-96>
11. Korenevskiy N.A., Lukash O.Yu., Safronov R.I., Rodionova S.N., Seregin S.P., Siplivyy G.V. Forecasting the occurrence and development of neurotic disorders provoked by engineering work. *Sistemnyj analiz i upravlenie v biomedicinskih sistemah = Systems*

12. Knysh O.A., Safronov R.I., Lukash O.Yu., Starodubtseva L.V. Assessment of the influence of work activity on the level of adaptive potential based on the characteristics of the antioxidant system. *Vestnik nauchnyh konferencij = Bulletin of Scientific Conferences*. 2024;(12-4):36-38. (In Russ.)

13. Safronov R.I., Razumova K.V., Rybakov A.Yu., Lyakh A.V. Synthesis of models for predicting and diagnosing occupational diseases based on hybrid fuzzy technology. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2023;13(3):102-121. (In Russ.). <https://doi.org/10.21869/2223-1536-2023-13-3-102-121>

14. Safronov R.I., Rodionova S.N., Krikunova E.V., Starodubtseva L.V., Sergeeva S.S., Titova A.V. The use of indicators characterizing adaptation mechanisms to assess the level of the body's protection from exposure to external risk factors. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2021;11(4):163-179. (In Russ.) <https://doi.org/10.21869/2223-1536-2021-11-4-163-179>

15. Zakharevskaya E.A. Assessment of the impact of stress reactions on the functional state of police officers. *Psihologiya i pedagogika sluzhebnnoj deyatel'nosti = Psychology and Pedagogy of Service Activities*. 2023;(1):33-38. (In Russ.) <https://doi.org/10.24412/2658-638X-2023-1-33-38>

16. Zhovnerchuk E.V., Chikhalyuk V.A., Zhovnerchuk I.Yu., et al. Methodology for determining the mental reliability of transport security personnel using machine learning. *Psihicheskoe zdorov'e = Mental Health*. 2022;17(12):3-10. (In Russ.) <https://doi.org/10.25557/2074-014X.2022.12.3-10>

17. Safronov R.I. Synthesis of fuzzy models for assessing the impact of the working environment on the health of workers based on factors of work adaptation. *Sistemnyj analiz i upravlenie v biomeditsinskih sistemah = Systems Analysis and Management in Biomedical Systems*. 2023;22(3):89-98. (In Russ.) <https://doi.org/10.36622/VSTU.2023.22.3.012>

18. Serebrovsky A.V., Korsunsky N.A., Lyakh A.V., Mishustin V.N., Shatalova O.V., Shulga L.V. Multimodal medical risk classifier based on a multi-electrode bioimpedance transducer. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science*.

Medical Instruments Engineering. 2024;14(3):121-143. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-3-121-143>

19. Garcia-Campayo J., et al. A systematic review of the neurobiological and clinical features of neurasthenia (F48.0): Redefining a modern entity. *Journal of Affective Disorders*. 2023;333:311-323. <https://doi.org/10.1016/j.jad.2023.04.040>

20. Zaman H., et al. Somatic symptom disorder: A primary diagnosis in patients with prominent medically unexplained symptoms. *General Hospital Psychiatry*. 2024;86:1-8. <https://doi.org/10.1016/j.genhosppsych.2023.11.007>

Информация об авторах / Information about the Authors

Родионова Софья Николаевна, кандидат технических наук, доцент кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: knsofia@mail.ru, ORCID: 0000-0002-4477-3975

Sofya N. Rodionova Candidate of Sciences (Engineering), Associate Professor at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: knsofia@mail.ru, ORCID: 0000-0002-4477-3975

Корневский Николай Алексеевич, доктор технических наук, профессор, профессор кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: kstu-bmi@yandex.ru, ORCID: 0000-0003-2048-0956

Nikolay A. Korenevsky, Doctor of Sciences (Engineering), Professor, Professor at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: kstu-bmi@yandex.ru, ORCID: 0000-0003-2048-0956

Трусевич Алена Александровна, студент кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: alyona.04@list.ru

Alena Al. Trusevich, Student at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: myelectronworld@mail.ru

Малыхина Екатерина Денисовна, студент кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: katerinakartamysheva@yandex.ru

Ekaterina D. Malykhina, Student at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: katerinakartamysheva@yandex.ru

<https://doi.org/10.21869/2223-1536-2026-16-1-221-241>

УДК 004.89

Гибридные технологии искусственного интеллекта и биоимпедансной спектроскопии для классификации функционального состояния органов и систем человека

Н. А. Корсунский¹ ✉

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: cor.nick2013@yandex.ru

Резюме

Цель исследования заключается в разработке метода многоотведённой биоимпедансной спектроскопии грудной клетки, ориентированного на объективную и доступную оценку функционального состояния дыхательной системы и дифференциальную диагностику патологий лёгких.

Методы. В работе предложен метод регистрации и обработки биоимпедансных характеристик грудной клетки, основанный на использовании восьми контактных электродов и последовательном формировании двадцати восьми уникальных биоимпедансных отведений. Для каждого отведения выполняется многочастотное зондирование тканей переменным током малой амплитуды с последующей регистрацией амплитудно-фазочастотных характеристик, построением графиков Коула и вычислением диагностических дескрипторов. Обработка данных реализована с применением многоуровневого обучаемого классификатора, включающего нейронные сети первого уровня для анализа отдельных отведений, сети второго уровня - для агрегирования информации по топологическим группам, соответствующим анатомическим зонам грудной клетки, и интегрирующую сеть для формирования итоговой оценки функционального состояния дыхательной системы. Разработан аппаратно-программный модуль, обеспечивающий автоматизированное переключение отведений и формирование признаковового пространства.

Результаты. Проведена экспериментальная апробация предложенного метода на группе добровольцев и пациентов с различными нарушениями вентилиционной функции лёгких. Показано, что использование многоотведённой схемы измерений и пространственно ориентированной обработки биоимпедансных данных обеспечивает повышение разделимости диагностических групп по сравнению с традиционными схемами биоимпедансных измерений. Разработанный классификатор продемонстрировал устойчивую работу и высокие показатели точности, чувствительности и специфичности, сопоставимые с результатами традиционных инструментальных методов диагностики. Применение собственного модуля коммутации электродных каналов позволило автоматизировать процесс измерений, снизить влияние артефактов и сократить время обследования.

Заключение. Предложенный метод многочастотной многоотведённой биоимпедансной спектроскопии в сочетании с многоуровневой архитектурой классификации может быть использован при создании систем поддержки клинических решений для диагностики социально значимых заболеваний дыхательной системы, обеспечивая расширение функциональных возможностей и повышение качества классификации.

Ключевые слова: биоимпедансная спектроскопия; классификатор; нечеткий логический вывод; гибридная нейронная сеть, интеллектуальная поддержка принятия медицинских решений.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Корсунский Н. А. Гибридные технологии искусственного интеллекта и биоимпедансной спектроскопии для классификации функционального состояния органов и систем человека // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 221–241. <https://doi.org/10.21869/2223-1536-2026-16-1-221-241>

Поступила в редакцию 11.01.2026

Подписана в печать 10.02.2026

Опубликована 31.03.2026

Hybrid artificial intelligence and bioimpedance spectroscopy technologies for classifying the functional state of human organs and systems

Nikita A. Korsunsky¹ ✉

¹ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: cor.nick2013@yandex.ru

Abstract

The purpose of the research is to develop a multi-lead bioimpedance spectroscopy method for objective and accessible assessment of the functional state of the respiratory system and differential diagnosis of lung pathologies.

Methods. A method for registering and processing thoracic bioimpedance characteristics is proposed, based on the use of eight contact electrodes and sequential formation of twenty-eight unique bioimpedance leads. For each lead, multifrequency tissue probing with low-amplitude alternating current is performed, followed by registration of amplitude-phase-frequency characteristics, construction of Cole plots, and extraction of diagnostic descriptors. Signal processing is implemented using a multi-level trainable classifier, including first-level neural networks for individual lead analysis, second-level networks aggregating information within topological groups corresponding to anatomical zones of the chest, and a final integrating network forming the overall assessment of the respiratory system functional state. A dedicated hardware-software module was developed to provide automated lead switching and feature space formation.

Results. Experimental validation of the proposed method was carried out on groups of healthy volunteers and patients with various ventilation impairments. The results demonstrate that the use of a multi-lead measurement scheme and spatially oriented bioimpedance data processing improves diagnostic group separability compared to conventional bioimpedance measurement approaches. The developed classifier showed stable performance and high accuracy, sensitivity, and specificity, comparable to those of traditional instrumental diagnostic methods. Integration of a custom electrode channel switching module enabled automation of measurements, reduction of artifacts, and shortening of examination time.

Conclusion. The proposed multifrequency multi-lead bioimpedance spectroscopy method combined with a multi-level classification architecture can be applied in clinical decision support systems for diagnosing socially significant respiratory diseases, enhancing classification quality and expanding the functionality of intelligent medical decision-making systems.

Keywords: bioimpedance spectroscopy; neural network classifier; fuzzy inference; hybrid neural network; intelligent medical decision support.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Korsunsky N.A. Hybrid artificial intelligence and bioimpedance spectroscopy technologies for classifying the functional state of human organs and systems. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravljenje, vychislitel'naja tehnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(1):221–241. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-221-241>

Received 11.01.2026

Accepted 10.02.2026

Published 31.03.2026

Введение

Вирусные поражения дыхательной системы, включая острые респираторные инфекции и вирусные формы пневмонии, занимают ведущее место в структуре заболеваемости и смертности населения. Наибольшие трудности вызывает раннее выявление патологического процесса и объективная оценка его тяжести, поскольку именно эти этапы определяют эффективность лечения и возможность предупреждения осложнений.

Применяемые в клинической практике методы визуализации (рентгенография, компьютерная томография) позволяют получать подробную информацию о состоянии лёгких, однако сопровождаются лучевой нагрузкой, требуют значительных ресурсов и не всегда подходят для регулярного мониторинга пациента. В последние годы внимание исследователей привлекает метод биоимпедансной спектроскопии, который основан на анализе электрических свойств тканей [1]. Доказано, что параметры биоимпеданса изменяются при воспалении, скоплении жидкости и нарушении вентиляционно-перфузионного равновесия, что открывает возможности для неинвазивной диагностики патологий дыхательной системы [2].

Вместе с тем большинство существующих биоимпедансных систем реализуются с использованием ограниченного числа электродов и фиксированных схем измерений, что приводит к формированию интегральных показателей, слабо чувствительных к пространственной неоднородности электрических свойств лёгочной ткани. Отсутствие учёта анизотропии грудной клетки и направлений протекания зондирующего тока снижает диагностическую информативность метода при локальных и региональных нарушениях вентиляции. Это обуславливает необходимость разработки многоотведённых биоимпедансных способов измерений и интеллектуальных алгоритмов обработки данных, ориентированных на анализ пространственной структуры импеданса дыхательной системы.

Главным преимуществом биоимпедансных технологий является их безопасность и возможность многократного применения без ущерба для пациента. Практическая значимость подобных технологий определяется их применимостью как в условиях интенсивной терапии, так и при проведении амбулаторного мониторинга. Параллельно с этим продолжается активное развитие интел-

лектуальных методов анализа, обеспечивающих автоматизацию обработки крупных массивов биомедицинских данных и снижение нагрузки на персонал.

Параллельно с этим активно развивается направление применения методов искусственного интеллекта, позволяющих автоматизировать обработку больших массивов данных [3]. Использование гибридных систем, сочетающих нейросетевые алгоритмы с методами нечеткой логики, показало эффективность в медицинской диагностике и прогнозировании [4].

Материалы и методы

В представленной работе рассматривается разработка и исследование технологий, объединяющих биоимпедансную спектроскопию и алгоритмы искусственного интеллекта, с целью классификации функционального состояния органов дыхания и поддержки принятия решений при диагностике вирусных заболеваний лёгких.

В биоимпедансных исследованиях используются два подхода для выявления патологических морфологических образований. Первый подход основан на абсолютном измерении биоимпеданса с последующей идентификацией сегментов с аномальной электрической проводимостью, а второй включает дифференциальные измерения, основанные на сравнении значений биоимпеданса, полученных в различных условиях измерения. Известны три метода изменения условий измерения.

Первый метод основан на изучении эволюции биоимпеданса во времени – Т-модальный. Этот метод часто используется при мониторинге функционального состояния дыхательной системы, в том числе в отделении интенсивной терапии. Измерительная система может содержать: 8 электродов, 16 электродов, 32 электрода или даже 64 электрода, индивидуально подключенные или размещенные на эластичном поясе или нетканом жилете, размеры которого адаптированы к антропометрическим характеристикам пациента. В случае мониторинга функционального состояния дыхательной системы электроды должны быть размещены в IV-V межреберном пространстве (расположение электродов слишком низко: влияние на значение комплайенса; расположение электродов слишком высоко: ложная гиперинфляция) [5].

Второй метод основан на изменении биоимпеданса в частотной области – F-модальный. Обычно изучаем биоимпеданс на частотах от 1 Гц до 500 кГц. Шаблон биоимпеданса можно получить с помощью массива электродов как пространство абсолютных значений импеданса с последующим наложением биоимпедансных изображений на разных частотах или путем анализа графиков Коула, если для анализа используются региональные измерения импеданса.

Третий метод основан на свойстве анизотропии биоимпеданса – А-модальный. Он связан с изучением направленных свойств проводимости

тканей. В норме биологические структуры характеризуются высокой степенью упорядоченности, что отражается на их электрических и электромагнитных параметрах. При патологических процессах – воспалении, нарушениях иммунного ответа или неопластическом росте – эта упорядоченность снижается, что приводит к росту изотропии и изменению электрических характеристик тканей [6]. Таким образом, снижение анизотропии можно рассматривать как один из биомаркеров нарушений функционального состояния организма.

В исследовании были получены данные об изменении электрического импеданса в различных анатомических областях организма. Проведённый анализ показал, что динамика импедансных характеристик проявляется как в низкочастотном, так и в высокочастотном диапазоне зондирующих токов. Наиболее выраженные изменения фиксируются у пациентов с деструктивными формами заболевания, что связано с нарушениями водно-электролитного баланса и морфологическими повреждениями как внутриклеточных, так и внеклеточных структур. По мере проведения терапии значения импеданса постепенно стремятся к физиологической норме, что подтверждает клиническую значимость метода.

В [1] авторами были получены данные биоимпеданса у группы добровольцев, не имевших хронической патологии дыхательной системы. Целью эксперимента являлась проверка кор-

ректности применения амплитудно-фазово-частотных характеристик (АФЧХ) для формирования информативных признаков, используемых при построении классификаторов функционального состояния организма [7]. Было установлено, что значения биоимпеданса в различных частотных диапазонах изменяются в зависимости от индивидуальных особенностей организма, однако сохраняют устойчивые закономерности. Наибольшие изменения регистрировались в области низких и средних частот, что связано с перераспределением жидкости между внутриклеточным и внеклеточным секторами [8]. При этом использование медианных значений в поддиапазонах частот позволило минимизировать влияние случайных шумов и повысить точность формирования дескрипторов. Полученные результаты подтверждают возможность практического применения метода: даже при обследовании здоровых добровольцев выявлены стабильные характеристики, которые могут служить основой для построения векторов признаков [9]. Это позволяет рекомендовать предложенный подход в качестве базового при разработке интеллектуальных систем классификации заболеваний дыхательной системы.

Интеллектуальные системы поддержки медицинских решений широко применяются для прогнозирования клинических рисков и анализа данных при социально значимых патологиях

[10]. В рамках проводимого исследования была разработана и протестирована система, включающая базу предикторов риска, извлекаемых из результатов биоимпедансных измерений, в т. ч. из биоимпедансной спектроскопии. Центральной задачей являлось формирование информативного признакового пространства для последующего использования в системе дифференциальной диагностики заболеваний лёгких.

В качестве метода получения исходных данных была выбрана импедансная спектроскопия, описанная ранее в [11]. Метод основан на зондировании биоматериала полигармоническими токами в нескольких взаимно независимых отведениях [12]. Для каждого из отведений формируется амплитудно-фазово-частотная характеристика импеданса, представляющая собой разновидность диаграммы Коула [13]. Получение подобных зависимостей позволяет выделять суррогатные маркеры, преобразуемые в

числовые дескрипторы для дальнейшей классификации [14].

Для проведения измерений используется система из восьми контактных электродов, размещённых на передней, боковых и задней поверхностях грудной клетки пациента. Путём последовательного перебора всех уникальных пар электродов формируется 28 биоимпедансных отведений, различающихся направлением протекания зондирующего тока и пространственной ориентацией области чувствительности (рис. 1). Сформированные импедансные отведения распределяются по шести топологическим группам в соответствии с пространственным расположением электродов и направлениями протекания зондирующего тока. Выделяются передняя верхняя и передняя нижняя группы, правая и левая боковые группы, а также задняя верхняя и задняя нижняя группы отведений, соответствующие основным анатомическим зонам грудной клетки.




Рис. 1. Топология размещения электродов при проведении биоимпедансных исследований на поверхности грудной клетки с формированием многоотведённой измерительной конфигурации

Fig. 1. The topology of electrode placement during bioimpedance studies on the surface of the chest with the formation of a multi-directional measuring configuration

Такой подход позволяет регистрировать пространственно распределённые изменения электрических свойств лёгочной ткани и учитывать региональные особенности вентиляции. Полученные биоимпедансные сигналы используются для формирования диагностических признаков, отражающих региональные особенности электрических свойств лёгочной ткани, и последующей интеллектуальной классификации функционального состояния дыхательной системы.

Использование восьми контактных электродов и последовательная коммутация всех уникальных пар позволяли регистрировать двадцать восемь биоимпедансных отведений, различающихся направлением протекания зондирующего тока и ориентацией чувствительных областей. По результатам

многочастотных измерений для каждого отведения строились комплексные диаграммы биоимпеданса в виде графиков Коула, отражающих взаимосвязь действительной и мнимой составляющих импеданса [15]. На основе анализа формы полученных зависимостей выполнялось формирование векторов диагностических дескрипторов, характеризующих геометрию кривой и её частотные особенности. Для повышения устойчивости последующей классификации диапазон значений действительной части импеданса был разделён на шесть поддиапазонов, что позволило повысить чувствительность признакового пространства к изменению функционального состояния тканей.

Рассмотрим пример формирования вектора информативных признаков на основе графика Коула (рис. 2).




Рис. 2. Пример формирования вектора информативных признаков

Fig. 2. Example of forming a vector of informative features

Из каждого графика выделяется набор диагностических дескрипторов, характеризующих форму кривой, частотные свойства и соотношение действительной и мнимой составляющих импеданса. Полученные дескрипторы формируют вектор признаков, используемый на последующих этапах автоматизированной классификации (см. рис. 2).

В рамках дифференциальной диагностики вирусных заболеваний лёгких система поддержки принятия решений оценивает вероятности альтернативных гипотез, которые могут быть выражены как в балльной форме, так и в процентах. Сравнение этих значений предо-

ставляет лицу, принимающему решение, объективные критерии для выбора диагностической или профилактической стратегии. Таким образом, даже частично неопределённые или нечёткие данные могут быть использованы в качестве диагностических маркеров.

Разрабатываемый классификатор реализован в виде многоуровневой нейросетевой структуры, обеспечивающей поэтапную обработку биоимпедансных данных и формирование интегральной оценки функционального состояния дыхательной системы. Рассмотрим структурную схему предложенного классификатора (рис. 3).




Рис. 3. Структура гибридной системы классификации

Fig. 3. Structure of a hybrid classification system

На первом иерархическом уровне гибридной системы функционируют нейронные сети, каждая из которых ассоциирована с отдельным биоимпедансным отведением и выполняет анализ набора диагностических дескрипторов. Поскольку формирование отведений выполняется последовательно, выходные значения нейронных сетей первого уровня сохраняются в запоминающем устройстве и используются на последующих этапах обработки.

На втором иерархическом уровне реализованы нейронные сети, агрегирующие результаты первого уровня в соответствии с топологическими группами отведений, сформированными на основе пространственного расположения электродов и соответствующих анатомических зон грудной клетки. Такое агрегирование позволяет учитывать региональные особенности распределения биоимпеданса и снижать влияние локальных артефактов измерений.

На третьем иерархическом уровне используется интегрирующая нейронная сеть, объединяющая выходные сигналы сетей второго уровня и формирующая итоговую классификационную оценку функционального состояния дыхательной системы.

Применение многоуровневой архитектуры обеспечивает устойчивость классификации, повышение достоверности принимаемых решений и адаптацию к вариабельности биоимпедансных данных. Диагностика заболеваний дыхательной системы требует применения

методов, обеспечивающих дифференциацию состояний со схожей клинической симптоматикой, а также количественную оценку степени функциональных нарушений.

В этой связи при проектировании интеллектуальных систем поддержки принятия медицинских решений широкое распространение получили подходы, основанные на применении многоуровневых нейросетевых моделей и агрегировании информативных признаков, получаемых из измерительных данных [16]. В предлагаемой системе поддержки принятия решений в качестве основного источника диагностической информации используются биоимпедансные характеристики грудной клетки, регистрируемые при многоотведённом зондировании. Анализ данных реализуется на основе многоуровневого нейросетевого классификатора, включающего последовательные этапы обработки отдельных импедансных отведений, их агрегирование по топологическим группам, соответствующим анатомическим зонам грудной клетки, и формирование итоговой классификационной оценки функционального состояния дыхательной системы.

Для проведения биоимпедансных исследований использовалось устройство сбора данных E20-10 производства компании L-Card, которое служило базовым элементом измерительной системы. Структурная схема прибора приведена ниже (рис. 4).




Рис. 4. Структурная схема прибора для биоимпедансной спектроскопии

Fig. 4. Block diagram of a device for bioimpedance spectroscopy

В состав измерительной системы входили три основных блока:

- E20-10 – модуль сбора данных, содержащий каналы АЦП и ЦАП для формирования и регистрации сигналов;
- преобразователь «ток – напряжение», обеспечивающий корректное согласование сигналов между объектом исследования и системой регистрации;
- коммуникационный блок с биологическим объектом, через который осуществлялось подключение электродов к исследуемым тканям.

Такое построение системы позволяет формировать амплитудно-фазово-частотные характеристики биоимпеданса в широком диапазоне частот и создавать пространство информативных признаков для дальнейшего анализа гибридными классификаторами.

Диапазон рабочих частот зондирующего сигнала составлял от 0 Гц до 20 кГц. Амплитуда тока подбиралась индивидуально в пределах 10–20 мкА, что обеспечивало безопасность процедуры и отсутствие искажений, связан-

ных с влиянием силы тока на биообъект. Данные пациентов, а также дата, установленная для обучения нейронных моделей, хранятся в базе данных (БД).

В составе программного инструментария использовался модуль нечёткого вывода *gusfis*, разработанный на кафедре биомедицинской инженерии ЮЗГУ, который реализует алгоритмы логического вывода по Мамдани – Заде, предоставляет возможность настройки функций принадлежности, редактирования базы правил и визуализации результата.

Дополнительно применялся программный пакет, предназначенный для параметризации алгоритмов обработки сигналов и моделирования диагностических решений. Также в работе использовался программный комплекс, основанный на гибридном генетическом алгоритме для идентификации параметров нелинейных моделей импеданса биоматериала [10]. Его применение позволило оптимизировать процесс подбора параметров эквивалентных электрических схем и повысить точность аппроксимации экспериментальных данных.

На рисунке 5 приведена схема работы гибридного алгоритма с этапами инициализации, селекции, кроссовера, мутации и локальной оптимизации.

Использование таких инструментов позволило объединить возможности классических нечетких моделей и методов эволюционной оптимизации, что значительно расширяет функциональ-

ность системы поддержки принятия решений.



Рис. 5. Схема алгоритма оптимизации параметров гибридного алгоритма

Fig. 5. Scheme of the hybrid algorithm parameter optimization algorithm

Программный модуль включает специализированный интерфейс для настройки и проведения биоимпедансных измерений, а также визуализации получаемых данных, такие как: выбор формы тока (синусоидальной или пря-

моугольной); начальная и конечная частоты; шаг и частота дискретизации. Такая гибкость конфигурации позволя-

ла адаптировать измерительный процесс под конкретные условия эксперимента (рис. 6).




Рис. 6. Окно настройки параметров биоимпедансного исследования в программном модуле

Fig. 6. The window for setting up bioimpedance parameters in the software module




Рис. 7. Детализированный результат биоимпедансного исследования для выбранной пары электродов с инструментами анализа

Fig. 7. Detailed result of a bioimpedance study for a selected pair of electrodes with analysis tools

Интерфейс предоставляет возможность выбора активных каналов мультиплексора (от 1 до 8) для подключения соответствующую

Для детального анализа оператор может выбрать любой из графиков, после чего открывается окно с его увеличенным представлением (рис. 7), содержащее инструменты для масштабирования, измерения точных значений и сравнения с предыдущими или эталонными данными.

Представленная функциональность обеспечивает удобную визуализацию и первичный анализ данных перед их отправкой в гибридный классификатор.

Результаты и их обсуждение

Для проверки работоспособности разработанного метода были сформированы три экспериментальные группы,

включающие пациентов Курской областной клинической больницы. Исследование проводилось в период 2019–2023 гг. Распределение пациентов по группам осуществлялось на основании комплекса диагностических процедур, включавших анализ анамнеза, физикальный осмотр, лабораторные и ультразвуковые исследования, лапароскопию, интраоперационную ревизию и компьютерную томографию. Все участники исследования подписали информированное добровольное согласие на участие в эксперименте и были уведомлены о возможном использовании их обезличенных медицинских данных в научных публикациях.

На рисунке 8 представлен пример проведения эксперимента биоимпедансных исследований в восьми ортогональных отведениях, проведенных на одном из добровольцев.




Рис. 8. Фотография проведения измерений биоимпеданса в восьми ортогональных отведениях у одного из добровольцев

Fig. 8. A photograph of the results of bioimpedance measurements in eight orthogonal leads from one of the volunteers

В устройстве, согласно блочной схеме на рисунке 4, использовалось устройство сбора данных E20-10 от L-Card (<https://www.lcard.ru/>), блочная схема которого показана ниже (рис. 9).

В состав модуля входят четыре аналого-цифровых канала с разрядностью 14 бит и максимально допустимой частотой дискретизации до 10 МГц. Переключение между каналами осуществляется встроенным мультиплексором. E20-10 содержит 16 цифровых линий, работающих в соответствии с уровнями логики TTL, а также два цифро-аналоговых канала с 12-разрядным преобразованием и диапазоном выходного напряжения ± 5 В. Такое сочетание

АЦП, ЦАП и цифровых портов делает модуль пригодным как для регистрации многоканальных сигналов, так и для организации управляющих воздействий на внешние устройства. Наличие указанной конфигурации позволяет использовать модуль в составе измерительных комплексов, требующих высокой частоты опроса каналов, например, в задачах биомедицинского мониторинга, экспериментальной электроники и автоматизированного контроля.

В работе E20-10 был дополнен специализированным интерфейсным модулем для взаимодействия с биологическим объектом, архитектура которого показана ниже (рис. 10).





Рис. 9. Структурная схема устройства сбора данных E20-10 с L-Card

Fig. 9. Block diagram of the E20-10 data acquisition device with L-Card



а

б

Рис. 10. Модуль связи с биологическим объектом: а – схема электрическая принципиальная; б – фотография модуля

Fig. 10. Module for communication with a biological object: а – electrical schematic diagram; б – photo of the module

Для расширения возможностей биоимпедансной спектроскопии использовался собственный модуль коммутации электродных каналов. Его интеграция в состав измерительной системы позволила автоматизировать процесс переключения отведений,

уменьшить влияние артефактов и сократить время обследования. Особенность реализации заключается в цифровом управлении переключением каналов и возможности работы с многомерными наборами данных. Его конструкция показана ниже (рис. 11).




Рис. 11. Фотография компонентов мультиплексора

Fig. 11. Photo of the multiplexer components

Коммутация каналов осуществляется микроконтроллером, благодаря чему мультиплексор интегрируется в состав автоматизированного комплекса регистрации биоимпедансных данных. Включение модуля коммутации в комплекс позволило организовать параллельные измерения в различных отведениях, что дало возможность формировать многомерные выборки данных. Такой подход обеспечивает совместимость экспериментов с методами машинного обучения и повышает устойчивость классификации функциональных состояний.

Для валидации предложенного метода были сформированы три экспериментальные группы пациентов. В исследовании приняли участие больные из Курской областной клинической больницы, а также группа здоровых добровольцев.

Группа I включала пациентов с подтверждённой вирусной пневмонией. У большинства больных наблюдались характерные симптомы: одышка, кашель, гипертермия, снижение сатурации крови кислородом. При биоимпедансных исследованиях у этих пациентов отмечались выраженные изменения активного и реактивного сопротивления тканей грудной клетки, особенно в диапазоне низких и средних частот. Это коррелировало с наличием воспалительного инфильтрата и нарушением вентиляционно-перфузионного баланса.

Группа II состояла из пациентов с острыми респираторными вирусными инфекциями (ОРВИ) лёгкого и среднего

течения. Изменения биоимпедансных показателей у этой категории носили менее выраженный характер, однако статистически значимо отличались от данных контрольной группы. Наиболее заметными были изменения в фазовых характеристиках импеданса, что может свидетельствовать о накоплении жидкости в межклеточном пространстве.

Группа III включала здоровых добровольцев без патологии дыхательной системы. Их биоимпедансные характеристики использовались как эталон для сравнения.

Сравнение усреднённых величин активного сопротивления, зарегистрированных при токах зондирования 10 и 20 мкА, показало статистически значимые различия между пациентами экспериментальных групп и контрольной выборкой. Полученные результаты свидетельствуют о выраженных изменениях электрических свойств тканей грудной клетки при воспалительных заболеваниях дыхательной системы. При этом наблюдалась устойчивая зависимость биоимпедансных показателей от типа патологического процесса, что подтверждает диагностическую информативность многоотведённой биоимпедансной регистрации.

Анализ распределения сопротивлений показал, что у пациентов с вирусной пневмонией значения активной составляющей импеданса характеризуются более широким диапазоном вариаций по сравнению с группой ОРВИ и здоровыми добровольцами. Учёт половых различий позволил выявить сходные

тенденции изменения параметров биоимпеданса при сохранении индивидуальной вариабельности значений.

Для решения задачи классификации функционального состояния дыхательной системы была применена гибридная нейро-нечёткая модель, использующая совокупность дескрипторов, сформированных на основе многочастотных биоимпедансных измерений. Результаты распределения пациентов по диагностическим классам показали высокую разделимость групп «Вирусная пневмония», «ОРВИ» и «Норма». Максимальные значения диагностической специфичности достигали 91 %, при минимальных значениях около 67 %, что сопоставимо с показателями традиционных инструментальных методов исследования, включая ультразвуковую диагностику.

Сравнительный анализ качества классификации показал, что применение многоотведённой схемы измерений и пространственно ориентированной обработки биоимпедансных данных обеспечивает повышение устойчивости распознавания и снижает влияние межиндивидуальной вариабельности. Полученные результаты подтверждают перспективность предложенного подхода для неинвазивной экспресс-оценки функционального состояния дыхательной системы.

Выводы

1. Разработан метод формирования дескрипторов на основе биоимпедансной спектроскопии, позволяющий выделять информативные признаки для классификации функционального состояния дыхательной системы.

2. Предложен гибридный классификатор, основанный на комбинации вероятностных нейронных сетей и алгоритмов нечеткой логики, обеспечивающий высокие показатели чувствительности и специфичности при дифференциальной диагностике вирусных заболеваний лёгких.

3. Проведённые клинические испытания показали, что использование биоимпедансной спектроскопии совместно с интеллектуальными методами анализа данных позволяет достичь качества классификации, сопоставимого с традиционными инструментальными методами, но при этом обеспечивает более высокую скорость и безопасность для пациента.

4. Предложенный подход может быть применён для создания систем поддержки принятия решений в пульмонологии, что открывает перспективы его внедрения в практику ранней диагностики и мониторинга течения вирусных заболеваний лёгких.

Список литературы

1. Модели импеданса биоматериала для формирования дескрипторов в интеллектуальных системах диагностики инфекционных заболеваний / А. В. Мирошников, Н. С. Стадниченко, О. В. Шаталова, С. А. Филист // Моделирование, оптимизация и информационные технологии. 2020. Т. 8, № 4 (31). С. 1–14.

2. Chitturi V., Farrukh N. Spatial resolution in electrical impedance tomography // J. Electr. Bioimp. 2017. N 8. P. 66-78. <https://doi.org/10.2478/joeb-2017-0009>
3. Brazey B., Haddab Y., Zemiti N. Robust imaging using electrical impedance tomography: review of current tools // Proc. Math. Phys. Eng. Sci. 2022. N 478(2258). P. 20210713. <https://doi.org/10.1098/rspa.2021.0713>
4. Biotechnical system based on fuzzy logic prediction for surgical risk classification using analysis of current–voltage characteristics of acupuncture points / S. Filist, Riad Taha Al-Kasasbeh, O. Shatalova, N. Korenevskiy, A. Shaqadan, Z. Protasova, M. Ilyash, M. Lukashov // J. Integr. Med. 2022. N 20(3). P. 252-264. <https://doi.org/10.1016/j.joim.2022.02.007>
5. Hybrid neural networks with virtual flows in medical risk classifiers / K. Khatatneh, S. Filist, Riad Taha Al-Kasasbeh, A. A. Aikeyeva // Journal of Intelligent & Fuzzy Systems. 2022. Vol. 43, N 1. P. 1621–1632. <https://doi.org/10.3233/JIFS-219234>
6. Classifier for the functional state of the respiratory system via descriptors determined by using multimodal technology / S. A. Filist, Riad Taha Al-kasasbeh, O.V. Shatalova, A. A. Aikeyeva, Osama M. Al-Habahbeh, Mahdi Salman Alshamasin // Computer Methods in Biomechanics and Biomedical Engineering. 2023. Vol. 26, is. 12. P. 1-19. <https://doi.org/10.1080/10255842.2022.2046656>
7. Developing neural network model for predicting cardiac and cardiovascular health using bioelectrical signal processing / S. Filist, Riad Taha Al-Kasasbeh, O. Shatalova, A. Aikeyeva, N. Korenevskiy, A. Shaqadan, A. Trifonov, M. Ilyash // Computer Methods in Biomechanics and Biomedical Engineering. 2022. N 25(8). P. 908-921. <https://doi.org/10.1080/10255842.2021.1890857>
8. Алгоритм оптимизации модели Войта в классификаторах функционального состояния живых систем / А. В. Мирошников, О. В. Шаталова, М. А. Ефремов, Н. С. Стадниченко, А. Ю. Новоселов, А. В. Павленко // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. Т. 12, № 2. С. 59-75.
9. Шаталова О. В. Итерационная многопараметрическая модель биоимпеданса в экспериментах in vivo // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2019. № 9(1). С. 26-38.
10. Application of fuzzy neural network model and current-voltage analysis of biologically active points for prediction post-surgery risks / O. Shatalova, S. Filist, N. Korenevskiy [et. al.] // Computer Methods in Biomechanics and Biomedical Engineering. 2021. N 24(13). P. 1504-1516. <https://doi.org/10.1080/10255842.2021.1906895>
11. Miroshnikov A. V., Shatalova O. V., Zhilin V. V. Biomaterial impedance model for medical risk classifiers in in vivo experiments // Journal of Physics: Conference Series. 2021. Vol. 1801. P. 012045. <https://doi.org/10.1088/1742-6596/1889/1/012045>

12. Iterative models of bioimpedance in intelligent systems for early diagnosis of infectious diseases / A. V. Miroshnikov, A. V. Kiselev, O. V. Shatalova, R. A. Krupchatnikov // CEUR Workshop Proceedings. ITIDMS 2021 – Proceedings of the International Scientific and Practical Conference «Information Technologies and Intelligent Decision Making Systems». Moscow, 2021. Vol. 2843. P. 25.

13. Классификации биологических объектов на основе многомерного биоимпедансного анализа / А. В. Мирошников, О. В. Шаталова, Н. С. Стадниченко, Л. В. Шульга // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2020. Т. 10, № 3/4. С. 29-49.

14. Использование гибридных нейросетевых моделей для многоагентных систем классификации в гетерогенном пространстве информативных признаков / А. Г. Курочкин, В. В. Жилин, С. Е. Суржикова, С. А. Филист // Прикаспийский журнал: управление и высокие технологии. 2015. № 3(31). С. 85-95.

15. Oludare Isaac Abiodun 1, Aman Jantan 2, Abiodun Esther Omolara 3, Kemi Victoria Dada 4, Nachaat AbdElatif Mohamed 5, Humaira Arshad // Heliyon. 2018. N 4(11). P. e00938. <https://doi.org/10.1016/j.heliyon.2018.e00938>

16. Formation of descriptors for medical risk classifiers based on the current-voltage characteristics of biologically active points / A. V. Miroshnikov, A. V. Kiselev, O. V. Shatalova, S. Kadyrova // Journal of Physics: Conference Series. 2021. Vol. 2060. P. 012013. <https://doi.org/10.1088/1742-6596/1889/1/012013>

References

1. Miroshnikov A.V., Stadnichenko N.S., Shatalova O.V., Filist S.A. Biomaterial impedance models for the formation of descriptors in intelligent systems for the diagnosis of infectious diseases. *Modelirovanie, optimizatsiia i informatsionnye tekhnologii = Modeling, Optimization and Information Technologies*. 2020;8(4):1-14. (In Russ.)

2. Chitturi V., Farrukh N. Spatial resolution in electrical impedance tomography. *J. Electr. Bioimp.* 2017;(8):66-78. <https://doi.org/10.2478/joeb-2017-0009>

3. Brazey B., Haddab Y., Zemiti N. Robust imaging using electrical impedance tomography: review of current tools. *Proc. Math. Phys. Eng. Sci.* 2022;(478):20210713. <https://doi.org/10.1098/rspa.2021.0713>

4. Filist S., Riad Taha Al-Kasasbeh, Shatalova O., Korenevskiy N., Shaqadan A., Protasova Z., Ilyash M., Lukashov M. Biotechnical system based on fuzzy logic prediction for surgical risk classification using analysis of current–voltage characteristics of acupuncture points. *J. Integr. Med.* 2022;(20):252-264. <https://doi.org/10.1016/j.joim.2022.02.007>

5. Khatatneh K., Filist S., Riad Taha Al-Kasasbeh, Aikeyeva A.A. Hybrid neural networks with virtual flows in medical risk classifiers. *Journal of Intelligent & Fuzzy Systems*. 2022;43(1):1621–1632. <https://doi.org/10.3233/JIFS-219234>
6. Filist S.A., Riad Taha Al-kasasbeh, Shatalova O.V., Aikeyeva A.A., Osama M. Al-Hababbeh, Mahdi Salman Alshamasin. Classifier for the functional state of the respiratory system via descriptors determined by using multimodal technology. *Computer Methods in Biomechanics and Biomedical Engineering*. 2023;26(12):1-19. <https://doi.org/10.1080/10255842.2022.2046656>
7. Filist S., Riad Taha Al-Kasasbeh, Shatalova O., Aikeyeva A., Korenevskiy N., Shaqadan A., Trifonov A., Ilyash M. Developing neural network model for predicting cardiac and cardiovascular health using bioelectrical signal processing. *Computer Methods in Biomechanics and Biomedical Engineering*. 2022;(25):908-921. <https://doi.org/10.1080/10255842.2021.1890857>
8. Miroshnikov A.V., Shatalova O.V., Efremov M.A., Stadnichenko N.S., Novoselov A.Y., Pavlenko A.V. An algorithm for optimizing the Voigt model in classifiers of the functional state of living systems. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2022;12(2):59-75. (In Russ.)
9. Shatalova O.V. Iterative multiparametric bioimpedance model in in vivo experiments. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2019;(9):26-38. (In Russ.)
10. Shatalova O., Filist S., Korenevskiy N., et. al. Application of fuzzy neural network model and current-voltage analysis of biologically active points for prediction post-surgery risks. *Computer Methods in Biomechanics and Biomedical Engineering*. 2021;(24):1504-1516. <https://doi.org/10.1080/10255842.2021.1906895>
11. Miroshnikov A.V., Shatalova O.V., Zhilin V.V. Biomaterial impedance model for medical risk classifiers in in vivo experiments. *Journal of Physics: Conference Series*. 2021;1801:012045. <https://doi.org/10.1088/1742-6596/1889/1/012045>
12. Miroshnikov A.V., Kiselev A.V., Shatalova O.V., Krupchatnikov R.A. Iterative models of bioimpedance in intelligent systems for early diagnosis of infectious diseases. In: *CEUR Workshop Proceedings. ITIDMS 2021 – Proceedings of the International Scientific and Practical Conference «Information Technologies and Intelligent Decision Making Systems»*. Vol. 2843. Moscow; 2021. P. 25.
13. Miroshnikov A.V., Shatalova O.V., Stadnichenko N.S., Shulga L.V. Classifications of biological objects based on multidimensional bioimpression analysis. *Izvestiya Yugo-*

Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering. 2020;10(3/4):29-49. (In Russ.)

14. Kurochkin A.G., Zhilin V.V., Surzhikova S.E., Filist S.A. The use of hybrid neural network models for multi-agent classification systems in a heterogeneous space of informative features. *Caspian Journal: Management and High Technologies.* 2015;(3):85-95. (In Russ.)

15. Oludare Isaac Abiodun 1, Aman Jantan 2, Abiodun Esther Omolara 3, Kemi Victoria Dada 4, Nachaat AbdElatif Mohamed 5, Humaira Arshad. *Heliyon.* 2018;(4):e00938. <https://doi.org/10.1016/j.heliyon.2018.e00938>

16. Miroshnikov A.V., Kiselev A.V., Shatalova O.V., Kadyrova S. Formation of descriptors for medical risk classifiers based on the current-voltage characteristics of biologically active points. *Journal of Physics: Conference Series.* 2021;2060:012013. <https://doi.org/10.1088/1742-6596/1889/1/012013>

Информация об авторе / Information about the Author

Корсунский Никита Александрович, аспирант,
Юго-Западный государственный университет,
кафедра программной инженерии, г. Курск,
Российская Федерация,
e-mail: cor.nick2013@yandex.ru,
ORCID: 0009-0005-4606-5517

Nikita A. Korsunsky, Postgraduate, Southwest
State University, Kursk, Russian Federation,
e-mail: cor.nick2013@yandex.ru,
ORCID: 0009-0005-4606-5517

К СВЕДЕНИЮ АВТОРОВ

1. К публикации в журнале «Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение» принимаются актуальные материалы, содержащие новые результаты научных и практических исследований, соответствующие профилю журнала, не опубликованные ранее и не переданные в редакции других журналов.

2. Авторы статей должны представить в редакцию журнала:

- статью, оформленную в соответствии с правилами оформления статей, представляемых для публикации в журнале;
- разрешение на опубликование в открытой печати статьи от учреждения, в котором выполнена работа.
- сведения об авторах (фамилия, имя отчество, место работы, должность, ученая степень, звание, почтовый адрес, телефон, e-mail);
- лицензионный договор.

3. Бумажный вариант статьи подписывается всеми авторами.

4. Редакция не принимает к рассмотрению рукописи, оформленные не по правилам.

5. **Публикация бесплатная.**

6. Основной текст рукописи статьи (кроме аннотации и ключевых слов) набирают в текстовом редакторе MS WORD шрифтом «Times New Roman» размером 14 пт с одинарным интервалом, выравнивание по ширине. Поля с левой стороны листа, сверху и снизу – 2,5 см, с правой стороны – 2 см. Абзацный отступ – 1,5 см.

7. Схема построения публикации: УДК (индекс по универсальной десятичной классификации), фамилия и инициалы автора(ов) с указанием ученой степени, звания, места работы (полностью), электронного адреса (телефона), название (строчные), аннотация и ключевые слова, текст с рисунками и таблицами, список литературы. Авторы, название, аннотация и ключевые слова, список литературы приводятся на русском и английском языках.

Перед основным текстом печатается аннотация (200–250 слов), отражающая краткое содержание статьи.

8. При формировании текста не допускается применение стилей, а также внесение изменения в шаблон или создание собственного шаблона. Слова внутри абзаца следует разделять одним пробелом; набирать текст без принудительных переносов; не допускаются разрядки слов.

9. Для набора формул и переменных следует использовать редактор формул MathType версии 5.2 и выше с размерами: обычный – 12 пт; крупный индекс 7 пт, мелкий индекс – 5 пт; крупный символ – 18 пт; мелкий символ – 12 пт.

Необходимо учитывать, что **полоса набора – 75 мм**. Если формула имеет больший размер, ее необходимо упростить или разбить на несколько строк. **Формулы, внедренные как изображение, не допускаются!**

Все русские и греческие буквы (Ω , η , β , μ , ω , ν и др.) в формулах должны быть набраны прямым шрифтом. Обозначения тригонометрических функций ($\sin$, $\cos$, $\lg$ и т.д.) – прямым шрифтом. Латинские буквы – прямым шрифтом.

Статья должна содержать лишь самые необходимые формулы, от промежуточных выкладок желательно отказаться.

10. Размерность всех величин, принятых в статье, должна соответствовать Международной системе единиц измерений (СИ).

11. Рисунки и таблицы располагаются по тексту. Таблицы должны иметь тематические заголовки. Иллюстрации, встраиваемые в текст, должны быть выполнены в одном из стандартных форматов (TIFF, JPEG, PNG) с разрешением не ниже 300 dpi и публикуются в черно-белом (градации серого) варианте. Качество рисунков должно обеспечивать возможность их полиграфического воспроизведения без дополнительной обработки. **Рисунки, выполненные в MS Word, недопустимы.**

Рисунки встраиваются в текст через опцию «Вставка-Рисунок-Из файла» с обтеканием «В тексте» с выравниванием по центру страницы без абзацного отступа. Иные технологии вставки и обтекания **не допускаются.**

12. **Список литературы к статье обязателен** и должен содержать все цитируемые и упоминаемые в тексте работы (не менее 10). Пристатейные библиографические списки оформляются в соответствии с ГОСТ Р 7.0.5-2008. «Библиографическая ссылка. Общие требования и правила составления». Ссылки на работы, находящиеся в печати, не допускаются. При ссылке на литературный источник в тексте приводится порядковый номер работы в квадратных скобках.

13. В материале для публикации следует использовать только общепринятые сокращения.

Все материалы направлять по адресу: 305040, г. Курск, ул. 50 лет Октября, 94. ЮЗГУ, редакционно-издательский отдел.

Тел.(4712) 22-25-26, тел/факс (4712) 50-48-00.

E-mail: rio_kursk@mail.ru

Изменения и дополнения к правилам оформления статей и информацию об опубликованных номерах можно посмотреть на официальном сайте журнала: <https://swsu.ru/izvestiya/seriesivt/>.