

МИНОБРНАУКИ РОССИИ

Известия

**Юго-Западного
государственного университета**

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

Научный журнал

Том 16 № 2 / 2026

Proceedings

**of the Southwest
State University**

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

Scientific Journal

Vol. 16 № 2 / 2026



**Известия Юго-Западного
государственного университета.
Серия: Управление, вычислительная
техника, информатика. Медицинское приборостроение
(Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta.
Seriya: Upravlenie, vychislitel'naya tekhnika, informatika.
Meditsinskoe 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)

Дунаев Андрей Валерьевич, д-р техн. наук,
доцент, Орловский государственный университет
им. И. С. Тургенева (г. Орел, 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)

Корневский 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, 2026



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 О. А. Леоновой

Подписано в печать 30.06.2026. Формат 60×84/8.

Дата выхода в свет 29.07.2026.

Бумага офсетная. Усл. печ. л. 28,8.

Тираж 1000 экз. Заказ 24.

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 website 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. Sci. (Medical), Professor, Southwest State University (Kursk, Russia)

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

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

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

Andrey V. Dunaev, Dr. Sci. (Engineering), Associate Professor, Orel State University named after I.S. Turgenev (Orel, Russia)

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

Zo Zo Tun, Cand. 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: O. A. Leonova

© Southwest State University, 2026



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

Signed for printing 30.06.2026. Format 60×84/8.

Release date 29.07.2026.

Offset paper. Printer's sheets: 28,8.

Circulation 1000 copies. Order 24.

16+

СОДЕРЖАНИЕ

ИНФОРМАЦИОННЫЕ И ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ	8
Использование дискриминантного метода в прогнозировании прогрессирования первичной глаукомы.....	8
<i>Абрамов А. А., Копылов А. Е., Бахарева А. А., Федосеев И. М., Курзин М. Л., Шарапов И. Ю., Шмарова Д. Р., Шорохова А. А.</i>	
Программно-аппаратный комплекс обеспечения функционирования интерфейса типа «мозг-компьютер»	21
<i>Журавлёв Д. В., Соловьев А. С., Кузьменко Р. В., Калач А. В.</i>	
Разработка и валидация комплекса программ для дистанционной оценки статуса пациентов с хронической обструктивной болезнью легких.....	39
<i>Трусов Ю. А., Гаранин А. А.</i>	
Биотехническая система управления реабилитацией верхних конечностей на основе мониторинга косвенного критерия биотехнического резонанса	54
<i>Петрунина Е. В., Ермаков Д. А., Скворцов М. К., Дрейзин В. Э., Филист С. А., Шаталова О. В.</i>	
Обнаружение и классификация перегрузок многомашинных вычислительных систем.....	76
<i>Бехтин Ю. С., Баланев К. С., Титова А. В.</i>	
МЕХАТРОНИКА, РОБОТОТЕХНИКА.....	91
Автономное управление движением уретероскопа при проведении операции методом ретроградной интратеренальной хирургии	91
<i>Яцун С. Ф., Тисцов Е. Д., Ефремов Д. И., Фурсов Г. А.</i>	
РАСПОЗНАВАНИЕ И ОБРАБОТКА ИЗОБРАЖЕНИЙ	102
Гибридный метод распознавания государственных регистрационных знаков транспортных средств на основе конвейерной архитектуры.....	102
<i>Киселев А. В., Кулешова Е. А., Таныгин М. О., Конаныхина Т. Н., Чьямова З. К.</i>	
Двухконтурная валидация нейросетевой сегментации пневмоторакса в условиях дисбаланса классов	122
<i>Косинов А. В., Крупчатников Р. А., Серебровский В. В., Ефремов М. А., Кондрашов Д. С.</i>	
Автоматизированное распознавание форм патологий верхнечелюстных пазух в цифровой диафаноскопии с помощью свёрточных нейронных сетей.....	150
<i>Герасин Д. В., Брянская Е. О., Бакотина А. В., Дрёмин В. В., Дунаев А. В.</i>	
СИСТЕМНЫЙ АНАЛИЗ И ПРИНЯТИЕ РЕШЕНИЙ	167
Сравнительное исследование инструментов статического анализа PHP-кода.....	167
<i>Огневой Я. В., Слеваков А. Г., Калуцкий И. В., Клименко П. А.</i>	
МОДЕЛИРОВАНИЕ В МЕДИЦИНСКИХ И ТЕХНИЧЕСКИХ СИСТЕМАХ	182
Методология прогнозирования генерации возобновляемых источников энергии для обеспечения качества электроэнергии в сетях	182
<i>Брежнев И. В., Чернецкая И. Е.</i>	
Исследование мозговой активности и концентрации внимания при выполнении интеллектуальных задач.....	197
<i>Кравчук Д. А., Сахаров В. Л., Кириченко И. А.</i>	
Прогностическое моделирование неблагоприятных исходов лечения травм коленного сустава у пациентов с сахарным диабетом	209
<i>Родионова С. Н., Тишин Я. Н., Бабкин А. А.</i>	
Система регулирования лучезащитного сустава с динамикой мышц представленной моделью Хилла.....	218
<i>Щербак О. Ю., Масленников А. Л.</i>	
Методика оптимизации выбора и хранения информации об электрокардиосигналах сверхвысокого разрешения.....	235
<i>Шевяков Д. О., Денисова Е. А., Кордюкова А. А., Афанасенко А. С., Гуревич Б. С.</i>	
К сведению авторов	248

CONTENT

INFORMATION AND INTELLIGENT SYSTEMS	8
The use of the discriminant method in predicting the progression of primary glaucoma.....	8
<i>Abramov A.A., Kopylov A.E., Bakhareva A.A., Fedoseev I.M., Kurzin M.L., Sharapov I.Yu., Shmarova D.R., Shorokhova A.A.</i>	
Hardware and software complex ensuring the functioning of the interface "brain-computer".....	21
<i>Zhuravlev D.V., Soloviev A.S., Kuzmenko R.V., Kalach A.V.</i>	
Development and validation of a software complex for remote assessment of the status of patients with chronic obstructive pulmonary disease	39
<i>Trusov Y.A., Garanin A.A.</i>	
Biotechnical system for managing upper limb rehabilitation based on monitoring an indirect criterion of biotechnical resonance	54
<i>Petrulina E.V., Ermakov D.A., Skvortsov M.K., Drejzin V.E., Filist S.A., Shatalova O.V.</i>	
Detection and classification of network congestions in multi-machine computing systems.....	76
<i>Bekhtin Y.S., Balanev K.S., Titova A.V.</i>	
MECHATRONICS, ROBOTICS	91
Autonomous control of ureteroscope movement during retrograde intrarenal surgery.....	91
<i>Jatsun S.F., Tistsov Y.D., Efremov D.I., Fursov G.A.</i>	
IMAGE RECOGNITION AND PROCESSING	102
A hybrid method for recognizing vehicle registration plates based on a pipeline architecture.....	102
<i>Kiselev A.V., Kuleshova E.A., Tanygin M.O., Konanykhina T.N., Chyamova Z.K.</i>	
Two-loop validation of neural network-based pneumothorax segmentation under class imbalance	122
<i>Kosinov A.V., Krupchatnikov R.A., Serebrovsky V.V., Efremov M.A., Kondrashov D.S.</i>	
Automated recognition of maxillary sinus pathology forms in digital diaphanoscopy using convolutional neural networks.....	150
<i>Gerasin D.V., Bryanskaya E.O., Bakotina A.V., Dremin V.V., Dunaev A.V.</i>	
SYSTEM ANALYSIS AND DECISION-MAKING	167
Comparative study of PHP code static analysis tools	167
<i>Ognevoy Y.V., Spevakov A.G., Kalutskiy I.V., Klimenko P.A.</i>	
MODELING IN MEDICAL AND TECHNICAL SYSTEMS	182
A methodology for short-term forecasting of solar generation to manage power quality in distribution networks	182
<i>Brezhnev I.V., Chernetskaya I.E.</i>	
A study of students' brain activity and concentration while performing intellectual tasks	197
<i>Kravchuk D.A., Sakharov V.L., Kirichenko I.A.</i>	
Prognostic modeling of adverse outcomes of knee joint injury treatment in patients with diabetes mellitus	209
<i>Rodionova S.N., Tishin Y.N., Babkin A.A.</i>	
Rationalization of diagnosis and prediction of traumatic brain injury outcomes by blood biomarkers	218
<i>Scherbak O.Yu., Maslennikov A.L.</i>	
A methodology for optimizing the selection and storage of ultra-high-resolution electrocardiogram information	235
<i>Shevyakov D.O., Denisova E.A., Kordyukova A.A., Afanasenko A.S., Gurevich B.S.</i>	
Information for authors	248

<https://doi.org/10.21869/2223-1536-2025-16-2-8-20>



УДК 519.24; 53; 57.017

Использование дискриминантного метода в прогнозировании прогрессирования первичной глаукомы

А. А. Абрамов¹✉, А. Е. Копылов², А. А. Бахарева³, И. М. Федосеев³,
М. Л. Курзин², И. Ю. Шарапов², Д. Р. Шмарова³, А. А. Шорохова³

¹ Клиника «Скандинавия»

ул. Ильюшина, д. 4/1, г. Санкт-Петербург 197372, Российская Федерация

² Межотраслевой научно-технический комплекс «Микрохирургия глаза»

имени академика С. Н. Федорова, Тамбовский филиал

Рассказовское ш., д. 1, г. Тамбов 392000, Российская Федерация

³ Юго-Западный государственный университет

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

✉ e-mail: anton_abramov@mail.ru

Резюме

Цель исследования – прогнозирование прогрессирования первичной глаукомы дискриминантным методом.

Методы. В исследовании приняли участие 141 пациент с I-й стадией первичной глаукомы и 145 пациентов со II-й стадией первичной глаукомы. На второй день в утреннее время производился забор крови в количестве 2 мл, анализ которой с подсчетом количества изученных клеток крови выполнялся автоматизированной системой Sysmex XN-A₁ (Япония), и расчёт анализируемых индексов. Статистическая обработка полученных данных проведена на ЭВМ и включала применение дискриминантного метода для создания математических моделей, обеспечивающих с 95%-ной безошибочной вероятностью дифференциацию (классификацию) пациентов с I и II стадией первичной глаукомы.

Результаты. Сравнительная оценка индексов слабого иммунного воспаления среди пациентов прогрессировании первой глаукомы относительно пациентов без прогрессирования первичной глаукомы выявила достоверные различия по всем рассматриваемым индексам. В соответствии с наивысшей информативностью индексов SIRI, AISI методом дискриминантного анализа разработана следующая модель: $Y_1 = -12,561 + 0,196X_1 + 0,058X_2$, а для пациентов без прогрессирования первичных глаукомы – модель $Y_2 = -4,768 + 0,085X_1 + 0,024X_2$. Установлено, что дискриминантные модели ошибочно отнесли 13,25% пациентов с прогрессированием первичной глаукомы в группу пациентов без прогрессирования первичной глаукомы. Однако дискриминантные модели классифицировали в группу пациентов без прогрессирования первичной глаукомы (12,81%) с прогрессированием первичной глаукомы.

Заключение. Использование дискриминантного метода и индексов SIRI и AISI позволило разработать дискриминантную модель, позволяющую дифференцировать пациентов с прогрессированием первичной глаукомы от пациентов без прогрессирования первичной глаукомы с требуемым качеством.

Ключевые слова: первичная открытоугольная глаукома; прогрессирование первичной открытоугольной глаукомы; прогнозирование; дискриминантный анализ; клетки крови; индексы системного воспаления.

© Абрамов А. А., Копылов А. Е., Бахарева А. А., Федосеев И. М., Курзин М. Л., Шарапов И. Ю., Шмарова Д. Р., Шорохова А. А., 2026

Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026;16(2):8–20

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

Для цитирования: Использование дискриминантного метода в прогнозировании прогрессирования первичной глаукомы / А. А. Абрамов, А. Е. Копылов, А. А. Бахарева, И. М. Федосеев, М. Л. Курзин, И. Ю. Шарапов, Д. Р. Шмарова, А. А. Шорохова // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 8–20. <https://doi.org/10.21869/2223-1536-2026-16-2-8-20>.

Поступила в редакцию 10.04.2026

Подписана в печать 10.05.2026

Опубликована 30.06.2026

The use of the discriminant method in predicting the progression of primary glaucoma

Anton A. Abramov¹ ✉, Andrey E. Kopylov², Arina A. Bakhareva³,
Ilya M. Fedoseev³, Maxim L. Kurzin², Ilya Yu. Sharapov²,
Diana R. Shmarova³, Anastasia A. Shorokhova³

¹ Skandinavia Clinic
4/1 Ilyushina Str., Saint Petersburg 197372, Russian Federation

² Intersectoral Scientific and Technical Complex "Eye Microsurgery"
named after Academician S. N. Fedorov, Tambov Branch
1 Rasskazovskoe highway, Tambov 392000, Russian Federation

³ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: anton_abramov@mail.ru

Abstract

The purpose of the research is predicting the progression of primary glaucoma by discriminant method.

Methods. The study involved 141 patients with stage I primary glaucoma and 145 patients with stage II primary glaucoma. On the second day, in the morning, 2 ml of blood was taken, the analysis of which, counting the number of blood cells studied, was performed by the automated Sysmex XN-A₁ system (Japan) and the calculation of the analyzed indices. Statistical processing of the obtained data was carried out on a computer and included the use of a discriminant method to create mathematical models that provide 95% error-free differentiation (classification) of patients with stage I and II primary glaucoma.

Results. A comparative assessment of the indices of weak immune inflammation among patients with the progression of the first glaucoma relative to patients without the progression of primary glaucoma revealed significant differences in all the indices under consideration. In accordance with the highest informative value of the SIRI and AISI indexes, the following model was developed by discriminant analysis: $Y_1 = -12,561 + 0,69X_1 + 0,08X_2$, and for patients without progression of primary glaucoma, the model $Y_2 = -4,768 + 0,085X_1 + 0,024X_2$. It was found that discriminant models mistakenly assigned 13,25% of patients with primary glaucoma progression to the group of patients without primary glaucoma progression. However, discriminant models were classified into the group of patients without primary glaucoma progression, 12,81% with primary glaucoma progression.

Conclusion. The use of the discriminant method and the SIRI and AISI indexes allowed us to develop a discriminant model that makes it possible to differentiate patients with primary glaucoma progression from patients without primary glaucoma progression with the required quality.

Keywords: primary open-angle glaucoma; progression of primary open-angle glaucoma; prognosis; discriminant analysis; blood cells; indices of systemic inflammation.

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

For citation: Abramov A.A., Kopylov A.E., Bakhareva A.A., Fedoseev I.M., Kurzin M.L., Sharapov I.Yu., Shmarova D.R., Shorokhova A.A. The use of the discriminant method in predicting the progression of primary glaucoma. *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(2):8–20. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-8-20>.

Received 10.04.2026

Accepted 10.05.2026

Published 30.06.2026

Введение

Глаукома является основной причиной необратимой слепоты во всем мире. По оценкам, в 2020 г. в мире насчитывалось около 70 млн чел. в возрасте старше 40 лет, страдающих первичной открытоугольной глаукомой [1]. Хотя патогенез глаукомной оптической нейропатии сложен и многофакторен, колебания и повышенный уровень внутриглазного давления являются основными триггерами, вызывающими механическое повреждение ганглиозных клеток сетчатки, что приводит к дефектам поля зрения при глаукоме [2]. Лечение, направленное на снижение внутриглазного давления, является единственным доказанным способом замедлить прогрессирование глаукомы. Таким образом, профиль внутриглазного давления для каждого пациента является важной информацией для диагностики и лечения глаукомы. Аппланационная тонометрия, по Гольдману, которая в настоящее время является золотым стандартом, обычно проводится один раз в рабочее время для измерения внутриглазного давления у пациентов с глаукомой. Учитывая, что примерно у 2/3 пациентов с глаукомой пиковое внутриглазное давление наблюдается в нерабочее время, для получения суточного профиля уровней внутриглазного давления и регистрации их колебаний желательны дополнительные измерения внутриглазного давления, такие как домашняя тонометрия [3]. Однако на сегодняшний день не существует эффек-

тивных методов измерения амбулаторного внутриглазного давления в течение 24 часов, за исключением устройств, имплантируемых в глаз [4].

В связи с существующей сложностью измерения и оценки внутриглазного давления, считающегося ведущим фактором прогрессирования первичной глаукомы, в настоящее время шире стали применяться математические методы прогнозирования течения первичной глаукомы [5]. Модели прогнозирования прогрессирования первичной глаукомы стратифицируют пациентов в зависимости от вероятности достижения ими определённых результатов, тем самым выявляя пациентов с повышенным риском развития заболевания [6]. С помощью различных методологий были предприняты попытки разработать модели прогнозирования глаукомы, и эти модели показали многообещающие результаты в прогнозировании развития глаукомы и необходимости хирургического вмешательства при глаукоме [7]. Однако о связи отдельных офтальмологических признаков с более быстрым или медленным прогрессированием глаукомы известно относительно мало [8]. Кроме того, несмотря на растущее количество данных о патогенной роли таких факторов, как слабое иммунное воспаление, данные противоречивы [9].

Хотя воспаление является естественным процессом восстановления тканей, неконтролируемое воспаление может привести к их повреждению. Для более точной оценки воспалительного

статуса человека были разработаны новые лабораторные тесты и индексы [10]. Значительный интерес вызывает оценка маркеров воспаления, связанных с глаукомой. Ряд исследований показал, что такие маркеры воспаления, как NLR и PLR, тесно связаны с неблагоприятными исходами при сердечно-сосудистых заболеваниях, раке и хронической болезни почек [11].

Вместе с тем стратификация риска прогрессирования первичной глаукомы и прогнозирование прогрессирования первичной глаукомы по показателям NRL, PLR и другим параметрам слабого иммунного воспаления на основе дискриминантного метода не выполнялись.

Цель исследования – прогнозирование прогрессирования первичной глаукомы дискриминантным методом.

Материалы и методы

В исследовании приняли участие 141 пациент с I-й стадией первичной глаукомы и 145 пациентов со II-й стадией первичной глаукомы. Обследование пациентов выполнялось по общепринятой методике и включало клиническое и инструментальное исследование. Для диагностики первичной глаукомы использовались гониоскопия, щелевая лампа, периметрия, биомикроскопия для определения полей зрения, остроты зрения без коррекции, прозрачности оптических сред глаза. При диагностике первичной глаукомы учитывались критерии Клинических рекомендаций «Глаукома первичная открытоугольная»¹.

¹ Глаукома первичная открытоугольная: клинические рекомендации. М.: Общероссийская общественная организация «Ассоциация врачей-офтальмологов», 2024. 98 с.

Пациенты сравниваемых групп статистически значимо не различались по основным медико-демографическим показателям, которые могли бы повлиять на результаты исследования. Так, средний возраст в группе с I-й стадией первичной глаукомы составлял $65,27 \pm 2,07$ лет против $66,59 \pm 2,34$ лет ($p > 0,05$), внутриглазное давление $21,72 \pm 1,12$ мм рт. ст. против $23,34 \pm 1,24$ мм рт. ст., доля лиц мужского пола $46,8 \pm 2,24\%$ и $48,3 \pm 2,26\%$ соответственно.

Не установлено статистически значимых различий между рассматриваемыми группами в частоте среди них общесоматических заболеваний, когда индекс коморбидности составлял в группе с I-й стадией первичной глаукомы $3,6 \pm 0,84$ против $3,8 \pm 0,79$ в группе со II-й стадией первичной глаукомы, распространенность артериальной гипертензии $43,2 \pm 2,64\%$ и $41,6 \pm 2,43\%$, ишемической болезни сердца $21,7 \pm 1,83\%$ и $18,9 \pm 1,76\%$, перенесенного острого нарушения мозгового кровообращения $11,4 \pm 1,12\%$ и $10,8 \pm 1,34\%$ соответственно с недостоверным различием во всех случаях ($p > 0,05$).

Критериям включения в выделенные группы являлись наличие I-й и II-й стадии первичной глаукомы. В исследование не включались пациенты с острыми воспалительными заболеваниями, новообразованиями, аллергическими реакциями, сахарным диабетом, моложе 60 лет и старше 74 лет, с аутоиммунной патологией, с другими офтальмологическими заболеваниями.

На второй день в утреннее время производился забор крови в количестве 2 мл, анализ которой с подсчетом количества изученных клеток крови выполнялся автоматизированной системой Sysmex XN-A1 (Япония). В дальнейшем после получения данных о количестве

лейкоцитов, нейтрофилов, лимфоцитов, моноцитов и тромбоцитов производится расчёт анализированных индексов NLR (отношение нейтрофилов к лимфоцитам), PLR (тромбоцитов к лимфоцитам), LMR (лимфоцитов к моноцитам), SIRI (количество нейтрофилов, умноженное на отношение моноцитов и лимфоцитов), SII (количество тромбоцитов, умноженное на отношение нейтрофилов и лимфоцитов). Индекс AISI рассчитывался как произведение абсолютного количества моноцитов, нейтрофилов, тромбоцитов, деленное на количество лимфоцитов.

Статистическая обработка полученных данных проведена на ЭВМ и включала применение дискриминантного метода для создания математических моделей, обеспечивающих с 95% безошибочной вероятностью дифференциацию (классификацию) пациентов с I-й и II-й стадией первичной глаукомы. Первоначально проведен однофакторный анализ оценки статистических различий изученных индексов слабого иммунного воспаления по непараметрическому критерию X_2 . После выделения наиболее информативных индексов слабого иммунного воспаления применялся дискриминантный метод. При этом пациенты с I-й стадией первичной глаукомы

условно обозначались как класс $G_{1:0}$, а пациенты с II стадией первичной глаукомы как класс $G_{2:1}$. Хорошее качество разработанных дискриминантных моделей принималось тогда, когда процент ошибочной классификации не превышал 15% для каждого исследуемого класса. Оценка качества созданных дискриминантных моделей проведена по расстоянию Махаланобиса [12]. Проверка адекватности моделей проведена на обучающей контрольной выборке здоровых пациентов ($n = 96$).

Результаты и их обсуждение

Сравнительная оценка индексов слабого иммунного воспаления среди пациентов прогрессирующей первичной глаукомы относительно пациентов без прогрессирующей первичной глаукомы выявила достоверные различия по всем рассматриваемым индексам (табл. 1). При этом у пациентов с прогрессирующей первичной глаукомы максимально был выше индекс SIRI по отношению к пациентам без прогрессирующей первичной глаукомы – превышение составляло 2,58 раза. Индекс AISI также был значительно выше у пациентов, у которых диагностировано прогрессирующее первичной глаукомы с превышением 2,12 раза такового группы сравнения.

Таблица 1. Показатели индексов слабого иммунного воспаления среди пациентов с прогрессирующим и без прогрессирующей первичной глаукомы ($M \pm SD$, $\times 10^9/l$)

Table 1. Indices of weak immune inflammation among patients with and without progression of primary glaucoma ($M \pm SD$, $\times 10^9/l$)

Индекс слабого иммунного воспаления	Пациенты без прогрессирующей первичной глаукомы	Пациенты с прогрессирующей первичной глаукомы	p
NLR	1,78 $\pm$ 0,12	2,55 $\pm$ 0,14	0,0024
PLR	101,12 $\pm$ 5,95	129,37 $\pm$ 8,12	0,0019
LMR	4,83 $\pm$ 0,36	3,14 $\pm$ 0,29	0,0012
SIRI	0,73 $\pm$ 0,09	1,89 $\pm$ 0,32	0,0010
SII	369,08 $\pm$ 8,97	539,81 $\pm$ 16,41	0,0015
AISI	274,5 $\pm$ 9,48	582,9 $\pm$ 13,6	0,0022

Существенными оказались повышение индексов SII и NLP у пациентов с прогрессированием первичной глаукомы, хотя это различие было меньшим, чем для ранее рассмотренных индексов SIRI и AISI. Наряду с этим прогнозирование первичной глаукомы сопровождалось достоверным снижением индексов LMR, который был при этом в 1,54 раза ниже, чем в группе без признаков прогрессирования первичной глаукомы.

В соответствии с наивысшей информативностью индексов SIRI, AISI методом дискриминантного анализа разработана следующая модель:

$$Y_1 = -12,561 + 0,196X_1 + 0,058X_2,$$

где Y_1 – группа пациентов с прогрессированием первичной глаукомы; X_1 – величина индекса SIRI; X_2 – величина индекса AISI.

Для пациентов без прогрессирования первичных глаукомы модель Y_2 ,

построенная с учётом индексов слабого иммунного воспаления, имеет вид

$$Y_2 = -4,768 + 0,085X_1 + 0,024X_2,$$

где Y_2 – группа пациентов без прогрессирования первичной глаукомы; X_1 – величина индекса SIRI; X_2 – величина индекса AISI.

Адекватность созданных дискриминантных моделей для дифференциации пациентов с прогрессированием первичной глаукомы проведена по расстоянию Махаланобиса (табл. 2). Установлено, что дискриминантные модели ошибочно отнесли 13,25% пациентов с прогрессированием первичной глаукомы в группу пациентов без прогрессирования первичной глаукомы. Однако дискриминантные модели классифицировали в группу пациентов без прогрессирования первичной глаукомы (12,81%) с прогрессированием первичной глаукомы.

Таблица 2. Расстояние Махаланобиса для дискриминантных моделей по показателям слабого иммунного воспаления

Table 2. Mahalanobis distance for discriminant models based on indicators of weak immune inflammation

Код признака	Observed	G_1:0	G_2:1
1	G_1:0	23,612	8,622
2	G_1:0	20,879	8,796
3	G_1:0	21,625	9,012
4	G_1:0	21,786	7,864
5	G_1:0	25,404	11,231
6	G_1:0	19,847	6,742
7	G_1:0	14,976	12,764
8	G_2:1	14,274	8,109
9	G_2:1	16,512	11,257
10	G_2:1	22,843	18,064
11	G_2:1	18,407	12,745
12	G_2:1	16,351	10,109
13	G_2:1	22,549	13,544
14	G_2:1	12,874	17,095

В отличие от полученных нами результатов, в ранее выполненном исследовании [13] дискриминантный анализ использовался для дифференциации первичной глаукомы по комплексу ганглиозных клеток макулы, головки зрительного нерва и слою нервных волокон сетчатки от пациентов с подозрением на глаукому. Установлены статистически значимые различия в средних значениях комплекса ганглиозных клеток макулы, головки зрительного нерва и слоя нервных волокон сетчатки, которые оказались ниже у пациентов с первичной глаукомой. Однако, поскольку средний возраст пациентов в группах оказался неодинаковым: $61,2 \pm 10,5$ лет у пациентов с первичной глаукомой и $54,26 \pm 9,37$ лет ($p < 0,001$) у лиц с подозрением на глаукому, то для исключения влияния возраста проведена корректировка параметров с учётом возраста. После корректировки достоверные различия сохранились для вышеназванных параметров ($p < 0,001$). Использование дискриминантного анализа для дифференциации пациентов с первичной глаукомой от людей с подозрением на глаукому показало, что наилучшей дискриминантной способностью обладает комплекс ганглиозных клеток в нижней височной области и с учётом этого разработана дискриминантная модель $Y = -6,609 + 0,090x_1$, где x_1 – комплекс ганглиозных клеток в нижней височной области.

Дискриминантные модели, созданные другими авторами [14], включали в качестве переменных вертикальное соотношение чашки/диска зрительного нерва, среднюю толщину, толщину нижнего полушария, но их диагностическая способность оказалась ниже ранее рассмотренной, поскольку авторы включили в дискриминантную модель

демографические факторы, рефракционные ошибки. Последние оказались статистически значимыми. Кроме того, не была подтверждена эффективность дискриминантной модели на независимой выборке.

Использовались параметры толщины зрительного нерва, слоя нервных волокон сетчатки и общей толщины макулы для разработки дискриминантной модели, получена достаточная её результативность [13]. Однако окончательная дискриминантная модель не включала толщину макулы и показатели людей с подозрением на глаукому.

По сравнению с нашей дискриминантной моделью рассмотренные модели не включали индексы слабого иммунного воспаления, которые являются более экономичными при определении. Использованные нами индексы применялись другими исследователями для разработки регрессионных моделей. В частности, показана в многомерном регрессионном анализе устойчивая ассоциация между логарифмом индекса SIRI (из-за асимметричного его определения) с развитием первичной глаукомы при ОШ = 1,24 (95% ДИ 1,07-1,44, $p < 0,005$) [5]. Однако авторы считают, что созданная ими регрессионная модель не учитывает вид и не может применяться для дифференциальной диагностики и прогнозирования прогрессирования первичной глаукомы по индексам слабого иммунного воспаления и необходимы дальнейшие исследования.

Важность предиктивного подхода у пациентов с прогрессированием I-й стадии во II-ю стадию первичной глаукомы продемонстрирована в нашем исследовании, в ходе которого установлены не только разнонаправленные изменения в величинах индексов системного

иммунного воспаления, но и прогностическая способность анализируемых индексов, которая оказалась наивысшей для индексов SIRI и SII, которые в других исследованиях до настоящего времени не рассматривались в аспекте прогнозирования, прогрессирования глаукоматозного процесса. Вместе с тем известно об участии индекса PLR в прогрессировании закрытоугольной глаукомы, когда он был значительно выше в группе прогрессирования, чем в группе без прогрессирования названного фенотипа глаукомы [15]. В этом исследовании среднее значение PLR было значительно выше в группе с прогрессированием, чем в группе без прогрессирования. Кроме того, наше исследование показало, что более высокий PLR был фактором риска прогрессирования закрытоугольной глаукомы и что более высокий исходный PLR был связан с предполагаемым прогрессированием потери полей зрения при глаукоме в большой выборке пациентов с закрытоугольной глаукомой. Пациенты с более высоким PLR демонстрировали более быстрое прогрессирование потери полей зрения и с большей вероятностью демонстрировали прогрессирующее повреждение ганглиозного слоя сетчатки. Эта связь также наблюдалась в мужской и женской подгруппах. Результаты показывали, что системное воспаление играет важную роль в возникновении и прогрессировании закрытоугольной глаукомы и PLR может рассматриваться как новый эффективный биомаркер для прогнозирования прогрессирования потери полей зрения у пациентов с глаукомой. Вместе с тем в предыдущих исследованиях авторы выявили значительную разницу в PLR, NLR и LMR между пациентами с первичной открытоугольной глаукомой [16], закрыто-

угольной глаукомой [17] и здоровыми лицами.

Противоречивость информации о связи индексов системного иммунного воспаления и ПОУГ содержится в публикации [18], где указывается о противоречивости связи количества тромбоцитов (PLT), тромбоцитарного индекса (PCT) с риском развития ПОУГ. Показано, что у пациентов с ПОУГ PLT был значительно ниже, чем у здоровых лиц, а PCT недостоверно ниже относительно группы здоровых лиц. Авторы в связи с этим предположили, что активация тромбоцитов в большей степени вовлечена патогенез ПОУГ, поскольку наблюдалась значительно повышенная ширина распределения тромбоцитов и средний объем тромбоцитов при ПОУГ.

В другом исследовании [19] сообщалось, что нарушения функции свёртывания крови в значительной степени связаны с развитием ПЗУГ и могут быть вторичным фактором, повышающим риск развития ПЗУГ, поскольку только у менее чем 2 % пациентов с ПЗУГ наблюдаются отклонения в показателях функции свёртывания крови. Однако оценки показатели достоверности, проанализированные в этом исследовании, достигли статистической значимости, что позволяет по-новому взглянуть на патофизиологические механизмы развития глаукомы. Учитывая, что тромбоциты играют важную роль в каскаде коагуляции и в патофизиологии сосудов, стоит изучить потенциальный механизм нарушения регуляции сосудов при глаукоме. Кроме того, параметры тромбоцитов и функции коагуляции можно легко контролировать в клинических условиях, что заслуживает дальнейшего изучения патогенных или защитных эффектов.

Выводы

У пациентов с прогрессированием первичной глаукомы статистически значимо выше величины индексов слабого иммунного воспаления NLR, PLR, SIRI, SII и AISI и особенно индексов AISI до $582,9 \pm 13,6 \times 10^9/\text{л}$ и SIRI до $1,89 \pm 0,32 \times 10^9/\text{л}$ против $274,5 \pm 9,48 \times 10^9/\text{л}$

и $0,73 \pm 0,09 \times 10^9/\text{л}$. Использование дискриминантного метода и индексов SIRI и AISI позволило разработать дискриминантную модель, позволяющую дифференцировать пациентов с прогрессированием первичной глаукомы от пациентов без прогрессирования первичной глаукомы с требуемым качеством.

Список литературы

1. Prevalence of primary open angle glaucoma in the last 20 years: A meta-analysis and systematic review / N. Zhang, J. Wang, Y. Li [et al.] // Sci. Rep. 2021. Vol. 11, N 1. P. 13762. <https://doi.org/10.1038/s41598-021-92971-w>.
2. Alqawlaq S., Flanagan J. G., Sivak J. M. All roads lead to glaucoma: Induced retinal injury cascades contribute to a common neurodegenerative outcome // Exp. Eye. Res. 2019. N 183. P. 88–97. <https://doi.org/10.1016/j.exer.2018.11.005>.
3. The Icare HOME (TA022) study: Performance of an intraocular pressure measuring device for self-tonometry by glaucoma patients / L. I. Mudie, S. LaBarre, V. Varadaraj [et al.] // Ophthalmology. 2016. Vol. 123, N. 8. P. 1675–1684. <https://doi.org/10.1016/j.ophtha.2016.04.044>.
4. Short-term and long-term variability of intraocular pressure measured with an intraocular telemetry sensor in patients with glaucoma / K. Mansouri, H. L. Rao, R. N. Weinreb [et al.] // Ophthalmology. 2021. Vol. 128, N 2. P. 227–233. <https://doi.org/10.1016/j.ophtha.2020.07.016>.
5. Association of systemic inflammation indices with visual field loss progression in patients with primary angle-closure glaucoma: potential biomarkers for 3P medical approaches / S. Li, Y. Qiu, J. Yu [et al.] // EPMA J. 2021. Vol. 12, N 4. P. 659–675. <https://doi.org/10.1007/s13167-021-00260-3>.
6. Automated Detection of Glaucoma With Interpretable Machine Learning Using Clinical Data and Multimodal Retinal Images / P. Mehta, C. A. Petersen, J. C. Wen [et al.] // Am. J. Ophthalmol. 2021. N 231. P. 154–169. <https://doi.org/10.1016/j.ajo.2021.04.021>.
7. Explainable Machine Learning Model for Glaucoma Diagnosis and Its Interpretation / S. Oh, Y. Park, K. J. Cho [et al.] // Diagnostics (Basel). 2021. Vol. 11, N 3. P. 510. <https://doi.org/10.3390/diagnostics11030510>.
8. The Diagnostic Value of Neutrophil to Lymphocyte Ratio as an Effective Biomarker for Eye Disorders: A Meta-Analysis / M. Shirvani, F. Sougi, A. Nouralishahi [et al.] // Biomed. Res. Int. 2022. N 2022. P. 5744008. <https://doi.org/10.1155/2022/5744008>.
9. Возрастная жизнеспособность в критические периоды жизни пациентов при зрительном дефиците и травмах / М. А. Неудахин, Н. М. Агарков, А. С. О. Ибиев [и др.] // Научные результаты биомедицинских исследований. 2025. Т. 11, № 4. С. 727–741.
10. Glaucoma heritability: molecular mechanisms of disease / R. Zukerman, A. Harris, F. Oddone [et al.] // Genes (Basel). 2021. N 12. P. 1135. <https://doi.org/10.3390/genes12081135>.

11. Association between systemic inflammatory response index and glaucoma incidence from 2005 to 2008 / X. Li, Y. Q. Sun, X. D. Zhong [et al.] // *Front. Med. (Lausanne)*. 2025. N 12. P. 1542073. <https://doi.org/10.3389/fmed.2025.1542073>.
12. Лев И. В., Агарков Н. М., Стародубцева Л. В. Гериатрическая тактика ведения пациентов с диабетической ретинопатией // *Научные результаты биомедицинских исследований*. 2023. Т. 9, № 1. С. 129–141.
13. Linear discriminant score for differentiating early primary open angle glaucoma from glaucoma suspects / G. A. Deshpande, P. K. Bawankule, D. V. Raje [et al.] // *Indian. J. Ophthalmol.* 2019. Vol. 67, N 1. P. 75–81. https://doi.org/10.4103/ijo.IJO_678_18.
14. Evaluation of ganglion cell-inner plexiform layer thickness in the diagnosis of preperimetric glaucoma and comparison to retinal nerve fiber layer / G. A. Deshpande, R. Gupta, P. Bawankule [et al.] // *Indian. J. Ophthalmol.* 2021. Vol. 69, N 5. P. 1113–1119. https://doi.org/10.4103/ijo.IJO_965_20.
15. Karahan M., Kilic D., Guven S. Systemic inflammation in both open-angle and angle-closure glaucoma: role of platelet-to-lymphocyte ratio // *Bratisl. Lek. Listy*. 2021. Vol. 122, N 1. P. 45–48. https://doi.org/10.4149/BLL_2021_005.
16. The diagnostic value of white blood cell, neutrophil, neutrophil-to-lymphocyte ratio, and lymphocyte-to-monocyte ratio in patients with primary angle closure glaucoma / S. Li, W. Cao, J. Han [et al.] // *Oncotarget*. 2017. Vol. 8, N 40. P. 68984–68995. <https://doi.org/10.18632/oncotarget.16571>.
17. Associations between Blood Cell Profiles and Primary Open-Angle Glaucoma: A Retrospective Case-Control Study / B. Tang, S. Li, J. Han [et al.] // *Ophthalmic Res.* 2020. Vol. 63, N 4. P. 413–422. <https://doi.org/10.1159/000504450>.
18. Association between Platelet Parameters and Glaucoma Severity in Primary Open-Angle Glaucoma / Y. Ma, J. Han, S. Li [et al.] // *J. Ophthalmol.* 2019. N 2019. P. 3425023. <https://doi.org/10.1155/2019/3425023>.
19. Association between coagulation function and patients with primary angle closure glaucoma: a 5-year retrospective case-control study / S. Li, Y. Gao, M. Shao [et al.] // *BMJ Open*. 2017. Vol. 7, N 11. P. e016719. <https://doi.org/10.1136/bmjopen-2017-016719>.

References

1. Zhang N., Wang J., Li Y., et al. Prevalence of primary open angle glaucoma in the last 20 years: A meta-analysis and systematic review. *Sci. Rep.* 2021;11(1):13762. <https://doi.org/10.1038/s41598-021-92971-w>.
2. Alqawlaq S., Flanagan J.G., Sivak J.M. All roads lead to glaucoma: Induced retinal injury cascades contribute to a common neurodegenerative outcome. *Exp. Eye. Res.* 2019;(183):88-97. <https://doi.org/10.1016/j.exer.2018.11.005>.
3. Mudie L.I., LaBarre S., Varadaraj V., et al. The Icare HOME (TA022) study: Performance of an intraocular pressure measuring device for self-tonometry by glaucoma patients. *Ophthalmology*. 2016;123(8):1675-1684. <https://doi.org/10.1016/j.ophtha.2016.04.044>.

4. Mansouri K., Rao H.L., Weinreb R.N., et al. Short-term and long-term variability of intraocular pressure measured with an intraocular telemetry sensor in patients with glaucoma. *Ophthalmology*. 2021;128(2):227-233. <https://doi.org/10.1016/j.ophtha.2020.07.016>.
5. Li S., Qiu Y., Yu J., et al. Association of systemic inflammation indices with visual field loss progression in patients with primary angle-closure glaucoma: potential biomarkers for 3P medical approaches. *EPMA J*. 2021;12(4):659-675. <https://doi.org/10.1007/s13167-021-00260-3>.
6. Mehta P., Petersen C.A., Wen J.C., et al. Automated Detection of Glaucoma With Interpretable Machine Learning Using Clinical Data and Multimodal Retinal Images. *Am. J. Ophthalmol.* 2021;(231):154-169. <https://doi.org/10.1016/j.ajo.2021.04.021>.
7. Oh S., Park Y., Cho K.J., et al. Explainable Machine Learning Model for Glaucoma Diagnosis and Its Interpretation. *Diagnostics (Basel)*. 2021;11(3):510. <https://doi.org/10.3390/diagnostics11030510>.
8. Shirvani M., Sougi F., Nouralishahi A., et al. The Diagnostic Value of Neutrophil to Lymphocyte Ratio as an Effective Biomarker for Eye Disorders: A Meta-Analysis. *Biomed. Res. Int.* 2022;(2022):5744008. <https://doi.org/10.1155/2022/5744008>.
9. Nedakhin M.A., Agarkov N.M., Ibiev A.S.O., et al. Age-related viability in critical periods of life of patients with visual deficits and injuries. *Nauchnye rezul'taty biomeditsinskikh issledovaniy = Research Results in Biomedicine*. 2025;11(4):727-741. (In Russ.)
10. Zukerman R., Harris A., Oddone F., et al. Glaucoma heritability: molecular mechanisms of disease // *Genes (Basel)*. 2021;(12):1135. <https://doi.org/10.3390/genes12081135>.
11. Li X., Sun Y.Q., Zhong X.D., et al. Association between systemic inflammatory response index and glaucoma incidence from 2005 to 2008. *Front. Med. (Lausanne)*. 2025;(12):1542073. <https://doi.org/10.3389/fmed.2025.1542073>.
12. Lev I.V., Agarkov N.M., Starodubtseva L.V. Geriatric management of patients with diabetic retinopathy. *Nauchnye rezul'taty biomeditsinskikh issledovaniy = Research Results in Biomedicine*. 2023;9(1):129-141. (In Russ.)
13. Deshpande G.A., Bawankule P.K., Raje D.V., et al. Linear discriminant score for differentiating early primary open angle glaucoma from glaucoma suspects. *Indian. J. Ophthalmol.* 2019;67(1):75-81. https://doi.org/10.4103/ijo.IJO_678_18.
14. Deshpande G.A., Gupta R., Bawankule P., et al. Evaluation of ganglion cell-inner plexiform layer thickness in the diagnosis of preperimetric glaucoma and comparison to retinal nerve fiber layer. *Indian. J. Ophthalmol.* 2021;69(5):1113–1119. https://doi.org/10.4103/ijo.IJO_965_20.
15. Karahan M., Kilic D., Guven S. Systemic inflammation in both open-angle and angle-closure glaucoma: role of platelet-to-lymphocyte ratio. *Bratisl. Lek. Listy*. 2021;122(1):45-48. https://doi.org/10.4149/BLL_2021_005.
16. Li S., Cao W., Han J., et al. The diagnostic value of white blood cell, neutrophil, neutrophil-to-lymphocyte ratio, and lymphocyte-to-monocyte ratio in patients with primary angle closure glaucoma. *Oncotarget*. 2017;8(40):68984-68995. <https://doi.org/10.18632/oncotarget.16571>.
17. Tang B., Li S., Han J., et al. Associations between Blood Cell Profiles and Primary Open-Angle Glaucoma: A Retrospective Case-Control Study. *Ophthalmic Res*. 2020;63(4):413-422. <https://doi.org/10.1159/000504450>.

18. Ma Y., Han J., Li S., et al. Association between Platelet Parameters and Glaucoma Severity in Primary Open-Angle Glaucoma. *J. Ophthalmol.* 2019;(2019):3425023. <https://doi.org/10.1155/2019/3425023>.

19. Li S., Gao Y., Shao M., et al. Association between coagulation function and patients with primary angle closure glaucoma: a 5-year retrospective case-control study. *BMJ Open.* 2017;7(11):e016719. <https://doi.org/10.1136/bmjopen-2017-016719>.

Информация об авторах / Information about the Authors

Абрамов Антон Андреевич, кандидат медицинских наук, врач-офтальмолог, Клиника «Скандинавия», г. Санкт-Петербург, Российская Федерация, e-mail: anton_abramov@mail.ru, ORCID: 0000-0002-4088-6606

Anton A. Abramov, Cand. Sci. (Medical), Ophthalmologist, Skandinavia Clinic, Saint Petersburg, Russian Federation, e-mail: anton_abramov@mail.ru, ORCID: 0000-0002-4088-6606

Копылов Андрей Евгеньевич, кандидат медицинских наук, врач-офтальмолог, заведующий отделением лазерного центра, Межотраслевой научно-технический комплекс «Микрохирургия глаза» имени академика С. Н. Федорова, Тамбовский филиал, г. Тамбов, Российская Федерация, e-mail: kopylovx@mail.ru, ORCID: 0000-0002-3536-1645

Andrey E. Kopylov, Cand. Sci. (Medical), Ophthalmologist, Head of the Department of Laser Center, Intersectoral Scientific and Technical Complex "Eye Microsurgery" named after Academician S. N. Fedorov, Tambov Branch, Tambov, Russian Federation, e-mail: kopylovx@mail.ru, ORCID: 0000-0002-3536-1645

Бахарева Арина Александровна, студент кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: evgeniafornec@gmail.com

Arina A. Bakhareva, Student at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: evgeniafornec@gmail.com

Федосеев Илья Максимович, студент кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: ilya_fedoseev_2020@bk.ru

Илья М. Fedoseev, Student at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: ilya_fedoseev_2020@bk.ru

Курзин Максим Леонидович, врач-офтальмолог I отделения, Межотраслевой научно-технический комплекс «Микрохирургия глаза» имени академика С. Н. Федорова, Тамбовский филиал, г. Тамбов, Российская Федерация, e-mail: kurzin1488@gmail.com, ORCID: 0000-0001-8788-0300

Maxim L. Kurzin, Ophthalmologist of the First Department, Intersectoral Scientific and Technical Complex "Eye Microsurgery" named after Academician S. N. Fedorov, Tambov Branch, Tambov, Russian Federation, e-mail: kurzin1488@gmail.com, ORCID: 0000-0001-8788-0300

Шарапов Илья Юрьевич, врач-офтальмолог детского отделения, Межотраслевой научно-технический комплекс «Микрохирургия глаза» имени академика С. Н. Федорова, Тамбовский филиал, г. Тамбов, Российская Федерация, e-mail: sharap68@gmail.com, ORCID: 0009-0006-9926-9617

Илья. Yu. Sharapov, Ophthalmologist at the Children's Department, Intersectoral Scientific and Technical Complex "Eye Microsurgery" named after Academician S. N. Fedorov, Tambov Branch, Tambov, Russian Federation, e-mail: sharap68@gmail.com, ORCID: 0009-0006-9926-9617

Шмарова Диана Руслановна, студент кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация e-mail: shmarova.diana@mail.ru

Diana R. Shmarova, Student at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation e-mail: shmarova.diana@mail.ru

Шорохова Анастасия Алексеевна, студент кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: shorohova20015@gmail.com

Anastasia A. Shorokhova, Student at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: shorohova20015@gmail.com

<https://doi.org/10.21869/2223-1536-2026-16-2-21-38>



УДК 681.5:004.032.26

Программно-аппаратный комплекс обеспечения функционирования интерфейса типа «мозг-компьютер»

Д. В. Журавлёв¹, А. С. Соловьев², Р. В. Кузьменко^{1,2}, А. В. Калач³ ✉

¹ Воронежский государственный технический университет
ул. 20-летия Октября, д. 84, г. Воронеж 394006, Российская Федерация

² Воронежский институт Федеральной службы исполнения наказаний России
ул. Иркутская, д. 1А, г. Воронеж 394072, Российская Федерация

³ Воронежский государственный университет инженерных технологий
пр-т Революции, д. 19, г. Воронеж 394036, Российская Федерация

✉ e-mail: a_kalach@mail.ru

Резюме

Целью исследования является разработка программно-аппаратного комплекса, позволяющего оптимизировать управление роботизированным устройством по сигналам электроэнцефалограммы на основе распознавания управляющих команд вне зависимости от принципа взаимодействия пользователя с компьютером.

Методы. Представлен программно-аппаратный комплекс, способный функционировать на основе как синхронной, так и асинхронной парадигм интерфейса «мозг-компьютер», предназначенный для внедрения в различные контуры управления сложными человеко-машинными системами. Аппаратные средства включают в себя плату регистрации сигналов электроэнцефалографии, а также нейрогарнитуру с электродами-датчиками. Плата регистрации сигналов электроэнцефалографии Cyton является ключевым элементом аппаратной части разработанного программно-аппаратного комплекса. Это 8-канальное устройство, совместимое с платформой OpenBCI, предназначенное для высокоточной регистрации биопотенциалов мозга, а также сигналов сердечной и мышечной активности. Разработанное на языке Python программное обеспечение позволяет регистрировать сигналы электроэнцефалографии; предварительной обработки сигналов электроэнцефалографии при реализации синхронного и асинхронного интерфейсов; проводить классификацию данных электроэнцефалографии; формировать управляющие сигналы на роботизированное устройство.

Результаты. Для выполнения задачи классификации данных электроэнцефалографии была разработана модель полносвязной искусственной нейронной сети, представляющей собой многослойный перцептрон (Multi-Layer Perceptron или MLP). В синхронном режиме достигнута точность распознавания потенциала P300 на уровне ~ 60 %. В асинхронном режиме точность бинарной классификации моторных образов (воображаемые движения левой и правой рук) составила 65 %. Разработанный комплекс предусматривает возможность работы системы с операторами без этапа предварительного обучения.

Заключение. Разработанный комплекс открывает перспективы для внедрения интерфейса «мозг-компьютер» в критически важные технологические процессы, где требуется высокая надёжность человеко-машинного взаимодействия. Дальнейшее развитие системы может быть направлено на повышение точности классификации, расширение числа распознаваемых команд и оптимизацию аппаратной части для мобильных применений.

Ключевые слова: асинхронный интерфейс «мозг-компьютер»; волна P300; моторные образы; многослойный перцептрон; человеко-машинный интерфейс.

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

Для цитирования: Программно-аппаратный комплекс обеспечения функционирования интерфейса типа «мозг-компьютер» / Д. В. Журавлёв, А. С. Соловьев, Р. В. Кузьменко, А. В. Калач // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 21–38. [https://doi.org/ 10.21869/2223-1536-2026-16-2-21-38](https://doi.org/10.21869/2223-1536-2026-16-2-21-38).

Поступила в редакцию 17.04.2026

Подписана в печать 15.05.2026

Опубликована 30.06.2026

Hardware and software complex ensuring the functioning of the interface "brain-computer"

Dmitry V. Zhuravlev¹, Alexander S. Soloviev²,
Roman V. Kuzmenko^{1,2}, Andrew V. Kalach³ ✉

¹ Voronezh State Technical University
20-letiya Oktyabrya Str. 84, Voronezh 394006, Russian Federation

² Voronezh Institute of the Federal Penitentiary Service of Russia
1A Irkutskaya Str., Voronezh 394072, Russian Federation

³ Voronezh State University of Engineering Technologies
19 Revolyutsii Ave., Voronezh 394036, Russian Federation

✉ e-mail: a_kalach@mail.ru

Abstract

The purpose of the research is to develop a software and hardware complex that allows optimizing the control of a robotic device based on electroencephalogram signals based on the recognition of control commands, regardless of the principle of user interaction with a computer.

Methods. Presented is a software and hardware complex capable of functioning on the basis of both synchronous and asynchronous paradigms of the "brain-computer" interface, designed for introduction into various control loops of complex human-machine systems. The hardware includes an electroencephalography signal recording board as well as a neuroharnithra with sensor electrodes. The Cyton electroencephalography signal registration board is a key element of the hardware of the developed software and hardware complex. This is an 8-channel device compatible with the OpenBCI platform, designed for high-precision registration of brain biopotentials, as well as signals of heart and muscle activity. Software developed in Python allows you to record electroencephalography signals; pre-processing electroencephalography signals when implementing synchronous and asynchronous interfaces; classify electroencephalography data; generate control signals to the robotic device.

Results. To perform the task of classifying electroencephalography data, a model of a fully connected artificial neural network, which is a multilayer perceptron (Multi-Layer Perceptron or MLP), was developed. In synchronous mode, the P300 has a potential recognition accuracy of ~ 60%. In asynchronous mode, the accuracy of the binary classification of motor images (imaginary movements of the left and right hands) was 65%. The developed complex provides the ability to work with operators without a preliminary training stage.

Conclusion. The developed complex opens up prospects for introducing the brain-computer interface into critical technological processes where high reliability of human-machine interaction is required. Further development of the system can be aimed at improving classification accuracy, expanding the number of recognizable commands and optimizing the hardware for mobile applications.

Keywords: asynchronous brain-computer interface; wave P300; motor imagery; multilayer perceptron; human-machine interface.

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

For citation: Zhuravlev D.V., Soloviev A.S., Kuzmenko R.V., Kalach A.V. Hardware and software complex ensuring the functioning of the interface "brain-computer". *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(2):21–38. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-21-38>.

Received 17.04.2026

Accepted 15.05.2026

Published 30.06.2026

Введение

Современные сложные человеко-машинные системы, особенно в сферах эксплуатации критически важного оборудования, предъявляют высокие требования к надежности, эффективности и безопасности управления. Ключевым элементом таких систем является оператор, чье функциональное состояние напрямую влияет на качество принимаемых решений. Традиционные интерфейсы зачастую не учитывают динамику когнитивной нагрузки и психофизиологического статуса человека, что может привести к ошибкам в условиях повышенной ответственности. В этой связи актуальной задачей становится разработка адаптивных систем, способных в реальном времени интегрировать объективные данные о состоянии оператора в контур управления, формируя биологическую обратную связь и создавая новые каналы для взаимодействия.

Перспективным направлением для создания таких адаптивных систем являются неинвазивные интерфейсы «мозг-компьютер» (ИМК), обеспечивающие прямую связь между человеком и машиной, путем преобразования сигналов мозга в команды управления [1]. Электроэнцефалография (ЭЭГ) является широко используемым методом, применяемым в системах ИМК благодаря своей неинвазивности и высокому временному разрешению. Однако ИМК на основе ЭЭГ часто страдают от низкого

отношения «сигнал/шум» и ограниченного пространственного разрешения, главным образом из-за небольшого количества регистрирующих электродов и их неоптимального расположения [2].

Цель данного исследования – решить эти проблемы, предложив структуру, которая улучшает релевантные для задачи сигналы ЭЭГ с использованием подхода оценки источников, управляемого вниманием, на основе грубо определенных областей мозга

Необходимо отметить, что интерфейсы «мозг-компьютер» обладают потенциалом кардинально изменить нашу жизнь в будущем, взаимодействуя с мозгом как «мост» между нами и внешней средой. Для разработки таких устройств у людей необходимо глубокое понимание механизмов работы мозга. В настоящее время исследования мыслительной способности человека достигли существенного прогресса в выявлении критически важных областей мозга и цепей, имеющих значение для двигательной активности [3].

Интерфейсы «мозг-компьютер» могут быть направлены на обнаружение дисфункциональной мозговой сети и изменение ее функции [4]. Этого можно достичь путем регистрации и стимуляции определенной популяции нейронов с помощью внутричерепной электроэнцефалографии и инвазивной или неинвазивной стимуляции мозга [5]. Учитывая, что мультисенсорный ввод связан с

улучшенным кодированием события, одним из способов улучшения двигательной активности с помощью интерфейса «мозг-компьютер» является стимуляция нейронов в нескольких сенсорных модальностях для передачи семантически согласованной мультисенсорной информации во время кодирования [6].

За последние 50 лет были сделаны первые шаги в разработке интерфейсов «мозг-компьютер», главным образом на животных [7]. Однако для понимания достижений в этой области, особенно в отношении потенциала интерфейсов «мозг-компьютер», необходим тщательный анализ литературы [8]. Существующие решения, как правило, узко специализированы [9] и реализуют либо синхронную парадигму (например, на основе вызванных потенциалов P300) [10], требующую внешней стимуляции, либо асинхронную (на основе воображаемых движений) [11], позволяющую оператору инициировать команды произвольно [12]. Каждый тип имеет свои преимущества и ограничения [13], а их жесткое разделение сужает потенциальную область применения ИМК [14]. Создание универсальной платформы, способной гибко работать в обоих режимах [15], представляет собой комплексную научно-техническую проблему. Её решение требует применения методов системного анализа для интеграции аппаратных и программных компонентов, разработки алгоритмов обработки многомерной и нестационарной нейрофизиологической информации [16], а также создания адаптивных классификаторов, устойчивых к индивидуальным особенностям операторов.

Исследование посвящено разработке и апробации именно такого универсального программно-аппаратного комплекса. Основная идея заключается в реализации единой архитектуры нейроклассификатора на основе многослойного персептрона, которая в сочетании с соответствующими методами предварительной обработки эффективно классифицирует как сигналы с волной P300, так и паттерны с воображаемыми моторными образами.

Цель работы – создать гибкий инструмент, позволяющий в зависимости от решаемой задачи и условий эксплуатации выбирать оптимальный режим работы ИМК, тем самым повышая надежность и эффективность управления сложными технологическими процессами за счет прямого учета состояния человека-оператора.

Материалы и методы

Можно выделить основные этапы работы разработанного программно-аппаратного комплекса (ПАК): регистрация сигналов электроэнцефалограммы (ЭЭГ), предварительная обработка данных, формирование входных векторов из данных, содержащих выделенные признаки, классификация данных [17]. Для того чтобы получить данные ЭЭГ, содержащие классифицируемые признаки, проводят сеансы записи биопотенциалов, используя аппаратные средства, включающие электроды-датчики, а также устройства сбора и хранения данных ЭЭГ. Примерами таких устройств могут выступать как профессиональное оборудование, используемое в различных профильных медицинских центрах, так и портативные платы регистрации, доступные ши-

рокому кругу пользователей, такие как плата Cyton от проекта OpenBCI. Предварительная обработка сигналов ЭЭГ заключается в устранении шумов и артефактов, возникших в ходе регистрации биопотенциалов, а также применении методов системного анализа для выделения полезных признаков из непрерывного сигнала ЭЭГ. В этой связи на данном этапе также проводится фильтрация сигналов ЭЭГ в заданном частотном диапазоне. Отметим, что в ходе предварительной обработки сигналов ЭЭГ осуществляется дискретное преобразование аналоговых сигналов ЭЭГ. Широкое применение на этапе предобработки нашел метод общего пространственного паттерна (Common Spatial Pattern или CSP) [18]. Извлечение признаков включает преобразование сырого сигнала эпохи в компактный набор числовых характеристик (признаков), которые наиболее информативны для различия классов (например, «целевой стимул» и «нецелевой» или «воображение движения левой / правой руки»). В современных исследованиях для классификации сигналов ЭЭГ применяют методы машинного и глубокого обучения [19]. Эти алгоритмы предназначены для анализа извлечённых признаков (в нашем случае в зависимости от режима работы – это волна Р300 или моторные образы лево / право). Бинарные классификаторы для режима онлайн обычно строятся на основе таких нересурсозатратных математических моделей, как линейный дискриминантный анализ (LDA) или метод опорных векторов (SVM). Также применяются нейросетевые модели (в частности, многослойный персептрон или MLP) [20].

Основные различия между синхронными и асинхронными интерфейсами «мозг-компьютер» заключаются в принципах взаимодействия с пользователем, способах обработки сигналов и архитектурных требованиях к системе.

Синхронные интерфейсы функционируют в строгом соответствии с внешними стимулами, предъявляемыми пользователю в определённые моменты времени: визуальными, звуковыми или тактильными. Пользователь концентрируется на целевом стимуле, что вызывает в его мозговой активности характерные паттерны, такие как волна Р300. Система анализирует ЭЭГ в привязке к моментам стимуляции и выделяет эти отклики для интерпретации команд. Такой подход обеспечивает высокую степень предсказуемости сигнала, что упрощает его обработку и повышает надёжность классификации. Однако он требует жёсткой синхронизации между человеком и устройством, а также длительного обучения оператора для достижения стабильных результатов.

Асинхронные интерфейсы, напротив, не привязаны к внешним триггерам и непрерывно анализируют мозговую активность в режиме реального времени. Пользователь может формировать управляющие команды в произвольный момент, например, представляя движение левой или правой руки [21]. Необходимо отметить, что система должна распознать эти моторные образы среди фоновой активности, что требует более сложных алгоритмов обработки, мощных вычислительных ресурсов и устойчивых моделей классификации [22]. Преимуществом асинхронных ИМК является их естественность и гибкость,

позволяющая более свободное и интуитивное управление [23].

Важно отметить, что асинхронные системы традиционно требуют длительной тренировки пользователя, однако в представленном исследовании достигнута работоспособность без предварительной адаптации, что является существенным достижением. Таким образом, выбор между синхронным и асинхронным режимом определяется конкретной задачей: синхронные интерфейсы предпочтительны в условиях контролируемого взаимодействия, а асинхронные – при необходимости спонтанного и непрерывного управления внешними устройствами.

В рамках описанного в настоящей работе исследования был разработан ПАК для управления роботизированным устройством по сигналам ЭЭГ на основе распознавания управляющих команд.

Аппаратные средства включают в себя плату регистрации сигналов ЭЭГ, а также нейрогарнитуру с электродами-датчиками. Плата регистрации сигналов ЭЭГ Cyton является ключевым элементом аппаратной части разработанного программно-аппаратного комплекса. Это 8-канальное устройство, совместимое с платформой OpenBCI, предназначенное для высокоточной регистрации биопотенциалов мозга (ЭЭГ), а также сигналов сердечной (ЭКГ) и мышечной (ЭМГ) активности. Отметим, что Cyton имеет возможность осуществлять 16-канальную регистрацию сигналов ЭЭГ с использованием платы увеличения каналов Daisy. Внешний вид модернизированной платы регистрации для 8-канального исполнения, сочетающей в себе модуль реги-

страции и модуль передачи сигналов по радиоканалу стандарта Wi-Fi, представлен в работе [24]. Плата основана на 24-битном аналого-цифровом преобразователе ADS1299, обеспечивающем высокое разрешение и низкий уровень шума, что критически важно для обработки низковольтных биопотенциалов. Каждый канал имеет независимый усилитель биопотенциалов с программируемым коэффициентом усиления и фильтрацией, что позволяет эффективно подавлять помехи и синфазные сигналы. Плата Cyton оснащена микроконтроллером PIC32MX250F128B, обеспечивающим быструю обработку данных, и поддерживает беспроводную передачу информации по Wi-Fi или Bluetooth через дополнительные модули. Частота дискретизации составляет до 250 Гц на канал, что достаточно для анализа широкого спектра паттернов ЭЭГ. Плата совместима с нейрогарнитурами, включая Ultracortex Mark IV, и поддерживает работу как с электродами «мокрого», так и «сухого» типов, а открытая архитектура и поддержка программного обеспечения (ПО) с открытым исходным кодом делают Cyton удобной платформой для исследований в области ИМК для человеко-машинных интерфейсов.

В настоящем исследовании для непосредственной регистрации сигналов ЭЭГ использовались электроды «сухого» типа, которые для удобства располагались в соответствующих отверстиях распечатанной на 3D-принтере нейрогарнитуры. Расположение электродов осуществлялось в отведениях, соответствующих международной системе «10-20» [24].

Разработанное на языке Python ПО, включает в себя следующие программные модули:

- модуль регистрации сигналов ЭЭГ;
- модуль предварительной обработки сигналов ЭЭГ при реализации синхронного ИМК;
- модуль предварительной обработки сигналов ЭЭГ при реализации асинхронного ИМК;
- модуль для проведения классификации данных ЭЭГ;
- модуль для формирования управляющих сигналов на роботизированное устройство;
- модуль для предъявления зрительных стимулов;
- модуль для взаимодействия пульта управления роботизированным устройством и остальными программными модулями.

Для выполнения задачи классификации данных ЭЭГ была разработана модель полносвязной искусственной нейронной сети (ИНС), представляющей собой многослойный персептрон (Multi-Layer Perceptron или MLP). Для разработки единой методики предварительной обработки сигналов ЭЭГ необходимо собрать большую базу данных ЭЭГ сигналов с участием разных испытуемых, формируя таким образом дикторонезависимый набор данных (под дикторонезависимым понимается набор данных, полученный на различных операторах без их предварительной подготовки). Следует также отметить, что технология применения электродов «сухого» типа является новой, в связи с чем при использовании разработанной аппаратуры для снятия сигналов ЭЭГ зачастую возникали артефакты во время

регистрации. Поэтому для получения больших дикторонезависимых наборов данных с использованием профессионального лабораторного оборудования, основанного на технологии электродов «мокрого» типа, нами была взята база данных ЭЭГ от центра биомедицинской визуализации Атинулы А. Мартиноса. Данная база ЭЭГ сигналов собрана с применением оборудования Neuromag Vectorview с использованием 60-ти отведений для локализации электродов «мокрого» типа. В ходе испытаний пациентам через каждые 750 мс предъявляли различные стимулы.

Поскольку использование данных со всех 60-ти каналов ЭЭГ в задаче классификации требует больших вычислительных мощностей, весьма целесообразно сократить количество используемых каналов до 8-ми. Такое число каналов обусловлено тем, что для проверки работоспособности ИМК в асинхронном режиме нами была использована база записей, сформированная с использованием разработанного ПАК. Такая база содержала более 300 образцов записей, сформированных на отдельных операторах в различное время. Все записи были сделаны на ИМК, имеющем 8-канальное исполнение, и содержали по 20 паттернов воображаемых моторных образов движений левой / правой рук оператора.

Сокращение числа каналов до 8-позиции позволило провести обучение искусственной нейронной сети (ИНС) на пользовательском ПК. Предварительная обработка сигналов ЭЭГ заключалась в удалении артефактов записи, а затем непрерывный сигнал ЭЭГ был разделён на сегменты (эпохи), содержащие волну P300 и не содержащие волну P300 для

случая синхронного ИМК. Каждый такой сегмент образовывался за 0,5 с до предъявления стимула и 1 с после предъявления стимула. Далее, были созданы массивы с данными, содержащими сегменты с P300, и с данными, не содержащими P300. В массиве имеется 12 строк, соответствующих 12-ти событиям с волной P300, а также 8 столбцов, соответствующих эпохам с каждого из 8 каналов регистрации ЭЭГ-сигналов. Данные, не содержащие P300, соответствуют событиям № 1, 2, 3, 4, 32. Общее количество таких эпох составило 208. Таким образом, массив с эпохами, не содержащими P300, аналогичен представленному выше, но имеет 208 строк и 8 столбцов.

Далее были созданы два вектора для данных, содержащих P300, и для данных, не содержащих P300. Для этой эпохи, содержащей волну P300 для каждого из 8-ми каналов, записывались в ячейки одной строки массива. Размерность данного массива составляла 12 строк и 1808 столбцов. Строки соответствовали числу событий. Столбцы соответствовали числу отсчетов каждой эпохи для каждого из 8-ми каналов. Таким образом, экспериментально установлено, что одна эпоха содержит $1808 / 8 = 226$ дискретных отсчетов сигнала.

Отметим, что аналогичные операции выполняли и для массива с эпохами, не содержащими волну P300. Затем каждый массив подвергали транспонированию (осуществляли замену строк столбцами) и нормализации данных с помощью встроенной функции пакета Python RobustScaler. После выполнения нормализации к обоим массивам применялось обратное транспонирование.

В конечном итоге данные были разделены на обучающие и тестовые наборы.

Для классификации данных была разработана модель полносвязной ИНС с использованием библиотеки `tensorflow.keras`. Учитывая представленные выше данные, для проведения классификации нам требуется модель ИНС, содержащая в составе входного слоя 1808 искусственных нейронов. Оптимальное количество скрытых слоев устанавливается экспериментальным методом подбора. В настоящем исследовании наилучших результатов удалось достичь при использовании модели ИНС с двумя скрытыми слоями по 128 нейронов в каждом. Функция активации нейронов скрытого слоя – линейная ректификация (ReLU), задаваемая следующим выражением:

$$\text{ReLU}(x) = \max(0, x), \quad (1)$$

где x – входное значение нейрона; $\max(\cdot)$ – функция, которая возвращает максимальное значение из 2-х возможных значений 0 и x (если $x > 0$, то функция возвращает значение x , и функция возвращает значение 0, если $x \leq 0$).

В качестве функции ошибки применялась бинарная кросс-энтропия (Binary Cross Entropy или *BCE*). Математически данная функция задается с помощью выражения

$$BCE = -\frac{1}{N} \sum_{i=1}^N [d_i \log y_i + (1 - d_i) \log(1 - y_i)], \quad (2)$$

где N – количество наблюдений; d_i – бинарная метка (0 или 1) для i -го наблюдения; y_i – предсказанная вероятность того, что наблюдение i принадлежит к определенному классу.

Отметим, что выходные значения для функции *BCE* представляют собой

распределение вероятностных числовых значений, лежащих в диапазоне $[0-1]$. В процессе обучения необходима корректировка весовых значений ИНС. Для задачи оптимизации процесса обучения модели ИНС использовался алгоритм адаптивной оценки момента (Adaptive Momentum), более известный как ADAM [25], основанный на традиционном алгоритме стохастического градиентного спуска.

Для предотвращения эффекта переобучения модели MLP в настоящей работе применялся алгоритм Dropout, который представляет собой метод регуляризации в машинном обучении. Данный подход подразумевает отключение части случайным образом выбранных нейронов в ходе обучения модели ИНС.

В алгоритме Dropout каждый нейрон слоя с вероятностью P «выключается» (его выход обнуляется), а с вероятностью $q = 1 - p$ остаётся активным. Математическое представление алгоритма для i -го нейрона слоя:

$$U_i = \Theta_i \cdot a \left(\sum_{k=1}^H \varpi_k x_k + b \right), \quad (3)$$

где U_i – выходной сигнал нейрона; Θ_i – случайная бинарная переменная Бернулли: $P(\Theta_i = 0) = p$, $P(\Theta_i = 1) = q = 1 - p$; $a(\cdot)$ – функция активации; H – число нейронов в предыдущем слое; ϖ_k – веса связей нейронов; x_k – входные сигналы; b – смещение.

Далее проведем расчёт среднего числа оставшихся нейронов в алгоритме Dropout. Обозначим через n общее число нейронов в рассматриваемом слое. При этом X_i – случайная величина (индикатор состояния i -го нейрона),

будет принимать следующие значения: 1, если нейрон активен, и 0, если выключен. Тогда вероятность выключения нейрона будет $P(X_i = 0) = p$, а вероятность сохранения нейрона будет $P(X_i = 1) = q = 1 - p$.

Обозначим через Y число оставшихся (активных) нейронов в слое после применения Dropout, тогда:

$$Y = \sum_{i=1}^n X_i Z. \quad (4)$$

Сумма Y имеет биномиальное распределение: $Y \approx \text{Binomial}(n, q)$, поэтому среднее число активных нейронов (математическое ожидание) будет равно

$$E[Y] = n \cdot q = n \cdot (1 - p). \quad (5)$$

Таким образом, после применения алгоритма Dropout в слое останется $n \cdot (1 - p)$ нейронов, при этом дисперсия биномиальной случайной величины (числа активных нейронов) равна

$$\text{Var}(Y) = n \cdot q \cdot p = n \cdot (1 - p) p. \quad (6)$$

Теперь проведем расчёт среднего числа отключенных нейронов после применения алгоритма Dropout. Обозначим через Z число отключённых нейронов в слое после применения Dropout:

$$Z = \sum_{i=1}^n X_i. \quad (7)$$

Для биномиального распределения математическое ожидание вычисляли следующим образом:

$$E[Z] = n \cdot p. \quad (8)$$

Таким образом, в среднем при применении Dropout будет отключено $n \cdot p$

нейронов, при этом дисперсия биномиальной случайной величины равна

$$\text{Var}(Z) = n \cdot p \cdot (1 - p) = n \cdot p \cdot q. \quad (9)$$

Следует отметить, что стандартным значением вероятности отключения нейрона принимают $P = 0,5$. Однако точное значение вероятности P вычисляется экспериментальным путем. Оптимальных значений классификации удалось достичь при значении $P = 0,3$. В результате применение алгоритма регуляризации Dropout приводит к минимальным искажениям выходного сигнала

ла используемой в настоящей работе модели MLP. Предварительная обработка сигнала для варианта асинхронного ИМК при классификации моторных образов «лево / право» проводилась аналогично.

Результаты и их обсуждение

Полученные в результате экспериментов средние точности классификации для синхронного и асинхронного режимов работы ПАК приведены ниже (табл. 1).

Таблица 1. Средние точности классификации

Table 1. Average classification accuracy

Режим работы ПАК	Средняя точность классификации, %
Синхронный	60,98
Асинхронный	65,92

Рассмотрим графики распределения средних точностей классификации для синхронного и асинхронного режимов

работы ИМК на протяжении 50-эпох обучения (рис. 1).




Рис. 1. Средняя точность классификации для синхронного и асинхронного режимов работы ИМК, %

Fig. 1. Average classification accuracy for synchronous and asynchronous modes of IMC operation, %

Установлено, что ошибка разработанной модели полносвязной нейронной сети для обучающего и тестового множества данных достигает минимальных значений уже к 10-й эпохе. На этапе тестирования функция ошибки достигает своего минимума к 25-й эпохе, что является хорошим результатом обобщения данных искусственной нейронной сетью при общем количестве эпох обучения, равном 50-ти.

Рассмотренный выше алгоритм Dropout успешно предотвращает переобучение нейронной сети. Для тестирования и практического применения в режиме онлайн разработанного ПАК использовался собственный набор данных ЭЭГ (моторные образы «лево / право»), полученный с помощью аппаратуры регистрации, описанной ранее.

Разработанный ПАК предоставляет оператору возможность самостоятельно выбирать режимы функционирования ИМК. Для работы в режиме синхронного ИМК оператору понадобится виртуальный пульт управления роботом. В режиме синхронного ИМК оператору предстоит мысленно сконцентрироваться на конкретной кнопке пульта управления роботизированного устройства. Головной мозг сформирует волну P300, которая является откликом на подсвечивание выбранной кнопки. Если по результатам бинарной классификации отклик P300 соответствует подсвеченной в настоящий момент кнопке с вероятностью не менее 60 %, ПО автоматически формирует управляющий сигнал для робототехнического устройства. При этом сигнал соответствует привязанно-

му к данной кнопке действию. Управляющие сигналы формируются с использованием интерфейса прикладного программирования (API).

В режиме асинхронного ИМК оператору представляется возможность использовать моторные образы для формирования управляющих команд. Оператор мысленно представляет движения левой или правой руки, а система в ответ формирует одну из 2-х возможных управляющих команд. Отдельно следует отметить, что для работы в режиме асинхронного ИМК оператору не требуется виртуальный пульт управления.

Практическое апробирование разработанного ПАК осуществляли на собственном наборе данных, полученных с использованием ранее описанной регистрирующей аппаратуры и сторонней базы записей. По результатам классификации как в синхронном, так и в асинхронном режимах системой формировались управляющие команды, с помощью которых и осуществлялось управление роботизированным устройством.

Тестирование разработанного ПАК в качестве асинхронного ИМК осуществлялось в режиме онлайн с использованием собственной базы данных ЭЭГ. В данном режиме оператор мысленно представлял движение левой или правой рукой, а система классифицировала моторные образы. Отметим, что точность классификации моторных образов в среднем составила более 65%. В результате успешной классификации и распознавания моторных образов система формировала управляющие команды и осуществляла управление роботом.

Предложенная универсальная методика предварительной обработки ЭЭГ-сигналов применима как для синхронного (P300), так и для асинхронного (моторные образы) варианта ИМК в режимах онлайн и офлайн. Её цель – извлечь информативные, устойчивые к шуму пространственно-временные признаки.

Рассмотрим основные этапы методики.

1. Полосовая фильтрация. Исходный непрерывный сигнал фильтруется для выделения физиологически релевантной полосы частот.

2. Сегментация. Для анализа сигнал разбивается на перекрывающиеся эпохи (окна). Используются сегменты длительностью ~ 4 с с шагом смещения 0,5 с. Это обеспечивает баланс между захватом достаточного количества информации для анализа и поддержанием временного разрешения, необходимого для онлайн-работы.

3. Пространственная фильтрация (CSP). К каждому сегменту применяется метод CSP. Этот этап критически важен для выделения паттернов, ассоциированных с различными ментальными состояниями (например, воображением движений разных рук) или реакцией на стимул (P300). CSP-фильтр максимизирует дисперсию сигнала для одного класса при одновременной минимизации дисперсии для другого, эффективно проецируя многоканальные данные в пространство с лучшей разделимостью классов.

4. Формирование объединённого вектора данных. После пространственной

фильтрации данные для анализа объединяются в единый вектор для последующего детального временного анализа.

5. Детальная временная сегментация и нелинейное преобразование. Объединённый вектор вновь сегментируется на короткие перекрывающиеся окна (длиной ~ 1 с с шагом 0,0625 с). К каждому такому короткому сегменту применяется операция возведения каждого отсчета в квадрат. Данное нелинейное преобразование подчеркивает энергетические характеристики сигнала и позволяет усиливать слабые, но информативные компоненты (такие как P300), одновременно подавляя нормальное распределение шума.

6. Логарифмическое преобразование и нормализация. К результату предыдущего шага применяли операцию логарифмирования, что служит двум целям: стабилизация дисперсии (сжатие динамического диапазона) и приближение распределения признаков к нормальному, что часто повышает эффективность последующих линейных классификаторов.

После проведения предварительной обработки формируется итоговый вектор признаков. Все обработанные короткие сегменты объединяются в единый многомерный вектор признаков. Этот вектор содержит сжатое, но информативное описание пространственно-временной и энергетической структуры исходного ЭЭГ-сегмента.

Далее формируется слой загрузки данных даталоадер (DataLoader) и данные подаются на вход бинарного классификатора (например, многослойного

персептрона, как в нашем случае), который принимает решение о принадлежности сегмента к тому или иному классу.

Выводы

В ходе выполнения исследования был разработан и апробирован универсальный ПАК для управления роботизированными устройствами посредством ИМК двух типов: синхронного и асинхронного. Ключевым достижением стала единая архитектура классификатора на основе многослойного персептрона, способная эффективно обрабатывать разнородные сигналы головного мозга человека-оператора:

- волны Р300 в синхронном режиме (точность распознавания – 60 % в режиме «онлайн»);

- моторные образы (воображаемые движения левой и правой руками) в асинхронном режиме (точность классификации – 65 % в режиме «онлайн»).

Важными практическими результатами разработанного ПАК являются:

- отсутствие необходимости в предварительной тренировке операторов, что подтверждает адаптивность системы к индивидуальным особенностям нейрофизиологических сигналов;

- апробированная методика предварительной обработки ЭЭГ, обеспечивающая устойчивость классификации в условиях реального времени;

- доказанная работоспособность комплекса с обоими типами ИМК, что расширяет сферу его применения при эксплуатации критически важного технологического оборудования;

- реализован комплексный подход к интеграции разработанного ПАК в контуры управления сложных человеко-машинных систем;

- разработаны алгоритмы обработки многомерных временных рядов ЭЭГ;

- продемонстрирована возможность адаптивного принятия решений на основе мониторинга функционального состояния оператора.

Разработанный комплекс открывает перспективы для внедрения ИМК в критически важные технологические процессы, где требуется высокая надёжность человеко-машинного взаимодействия. Дальнейшее развитие системы может быть направлено на повышение точности классификации, расширение числа распознаваемых команд и оптимизацию аппаратной части для мобильных применений.

Список литературы

1. Allison B. Z., Pineda J. A. ERPs evoked by different matrix sizes: implications for a brain computer interface (BCI) system // IEEE Trans. Neural Syst. Rehabil. Eng. 2003. N 11(2). P. 110–113.
2. Filter bank common spatial pattern (FBCSP) in brain-computer interface / K. K. Ang, Z. Y. Chin, H. Zhang, C. Guan // 2008 IEEE International Joint Conference on Neural Networks. Hong Kong: IEEE, 2008. P. 2390–2397. <https://doi.org/10.1109/IJCNN.2008.4634130>.

3. A human memory circuit derived from brain lesions causing amnesia / M. A. Ferguson, C. Lim, D. Cooke [et al.] // *Nat. Commun.* 2019. N 10 (1). P. 3497. <https://doi.org/10.1038/s41467-019-11353-z>.
4. Parvizi J., Kastner S. Promises and limitations of human intracranial electroencephalography // *Nat. Neurosci.* 2018. N 21(4). P. 474–483. <https://doi.org/10.1038/s41593-018-0108-2>.
5. Targeted enhancement of cortical-hippocampal brain networks and associative memory / J. X. Wang, L. M. Rogers, E. Z. Gross [et al.] // *Science*. 2014. N 345 (6200). P. 1054–1057. <https://doi.org/10.1126/science.1252900>.
6. Multisensory processing impacts memory for objects and their sources / S. E. Duarte, A. P. Yonelinas, S. Ghetti [et al.] // *Mem. Cognit.* 2024. N 53 (2). P. 646–665. <https://doi.org/10.3758/s13421-024-01592-x>.
7. Learning to control a brain-machine interface for reaching and grasping by primates / J. M. Carmena, M. A. Lebedev, R. E. Crist [et al.] // *PLoS Biol.* 2003. N 1 (2). P. e42.
8. Musk E. An integrated brain-machine interface platform with thousands of channels // *J. Med. Internet. Res.* 2019. N 21 (10). P. e16194. <https://doi.org/10.2196/16194>.
9. Vidal J. J. Toward direct brain-computer communication // *Annu. Rev. Biophys. Bioeng.* 1973. N 2 (1). P. 157–180. <https://doi.org/10.1146/annurev.bb.02.060173.001105>.
10. Scientific profile of brain-computer interfaces: bibliometric analysis in a 10-year period / K. Hu, C. Chen, Q. Meng [et al.] // *Neurosci. Lett.* 2016. N 635. P. 61–66. <https://doi.org/10.1016/j.neulet.2016.10.022>.
11. A Bibliometric analysis of the application of brain-computer interface in rehabilitation medicine over the past 20 years / J. Huang, L. Huang, Y. Li [et al.] // *J. Multidiscip. Healthc.* 2025. N 18. P. 1297–1317. <https://doi.org/10.2147/JMDH.S509747>.
12. EEG-inception: a novel deep convolutional neural network for assistive ERP-based brain-computer interfaces / E. Santamaria-Vazquez, V. Martinez-Cagigal, F. Vaquerizo-Villar [et al.] // *IEEE Trans. Neural Syst. Rehabil. Eng.* 2020. N 28 (12). P. 2773–2782.
13. Kapsetaki M. E. Scientometric analysis of Greek publications on stereotactic and functional neurosurgery // *Next Res.* 2025. N 2 (3). P. 100531. <https://doi.org/10.1016/j.nexres.2025.100531>.
14. Bibliometric analysis on brain-computer interfaces in a 30-year period / Z. Yin, Y. Wan, H. Fang [et al.] // *Appl. Intell.* 2023. N 53 (12). P. 16205–16225.
15. Sakhavi S., Guan C., Yan S. Learning temporal information for brain-computer interface using convolutional neural networks // *IEEE Trans. Neural Netw. Learn. Syst.* 2018. N 29 (11). P. 5619–5629.
16. Kapsetaki M. E. Brain-computer interfaces for memory enhancement: Scientometric analysis and future directions // *Biomedical Signal Processing and Control*. 2026. Vol. 112, pt. D. P. 108904. <https://doi.org/10.1016/j.bspc.2025.108904>.
17. Neurofeedback & P300 toolbox for neurorehabilitation: measurement and analysis of brain activity, network and cognitive decline-related P300 / E. Lee, Y. Kang, H. Kim, J. Lee // *Biomedical Physics & Engineering Express*. 2025. Vol. 11, N 6. P. 65004. <https://doi.org/10.1088/2057-1976/ae0ad7>.

18. Significance of EEG-electrode combinations while calculating filters with common spatial patterns / D. Wetzel, P.-P. Jacobs, D. Winkler, R. Grunert // *Ger. Med. Sci.* 2024. Vol. 22. <https://doi.org/10.3205/000334>.

19. Review of EEG signal classification / A. R. Chakole [et al.] // *Information and Communication Technology for Intelligent Systems: Proceedings of ICTIS 2018*. Singapore: Springer, 2019. Vol. 2. P. 105–114. https://doi.org/10.1007/978-981-13-1747-7_11.

20. Сравнительный анализ особенностей архитектур систем поддержки принятия решений для адаптации образовательных программ: от RuBERT до онтологически-графовых моделей / А. В. Калач, И. С. Кожевников, А. С. Кравченко [и др.] // *Моделирование систем и процессов*. 2025. Т. 18, № 3. С. 62–70. <https://doi.org/10.12737/2219-0767-2025-18-3-62-70>. EDN ESUQJE.

21. Feature Extraction and Classification of Motor Imagery EEG Signals in Motor Imagery for Sustainable Brain – Computer Interfaces / Y. Lu, W. Wang, B. Lian, C. He // *Sustainability*. 2024. Vol. 16. P. 6627. <https://doi.org/10.3390/su16156627>.

22. Nambiar A., Sivakumar R., Subramaniam S. Detection of Four Class Motor Imagery from EEG Signal for Brain-Computer Interface Applications // *Applied Mathematics, Modeling and Computer Simulation*. 2023. <https://doi.org/10.3233/ATDE231028>.

23. Станкевич Л. А., Журавская А. Управление мобильным роботом на основе нейроинтерфейса // *Экстремальная робототехника*. 2022. № 1 (33). С. 348–354. EDN: RWPBSY.

24. Журавлев Д. В., Голубинский А. Н., Резниченко А. А. Универсальный программно-аппаратный комплекс для управления роботизированными устройствами на основе принципов работы синхронного или асинхронного интерфейсов «мозг-компьютер» // *Журнал радиоэлектроники*. 2025. № 1. С. 9. <https://doi.org/10.30898/1684-1719.2025.1.1>.

25. Kingma D. P. Adam: A method for stochastic optimization // *archive.org*. URL: <https://archive.org/details/arxiv-1412.6980> (дата обращения: 10.03.2026).

References

1. Allison B.Z., Pineda J.A. ERPs evoked by different matrix sizes: implications for a brain computer interface (BCI) system. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2003;(11):110–113.

2. Ang K.K., Chin Z.Y., Zhang H., Guan C. Filter bank common spatial pattern (FBCSP) in brain-computer interface. *IEEE International Joint Conference on Neural Networks*. Hong Kong; IEEE; 2008. P. 2390–2397. <https://doi.org/10.1109/IJCNN.2008.4634130>.

3. Ferguson M.A., Lim C., Cooke D., et al. A human memory circuit derived from brain lesions causing amnesia. *Nat. Commun.* 2019;(10):3497. <https://doi.org/10.1038/s41467-019-11353-z>.

4. Parvizi J., Kastner S. Promises and limitations of human intracranial electroencephalography. *Nat. Neurosci.* 2018;(21):474–483. <https://doi.org/10.1038/s41593-018-0108-2>.

5. Wang J.X., Rogers L.M., Gross E.Z., et al. Targeted enhancement of cortical-hippocampal brain networks and associative memory. *Science*. 2014;(345):1054-1057. <https://doi.org/10.1126/science.1252900>.
6. Duarte S.E., Yonelinas A.P., Gheiti S., et al. Multisensory processing impacts memory for objects and their sources. *Mem. Cognit.* 2024;(53):646-665. <https://doi.org/10.3758/s13421-024-01592-x>.
7. Carmena J.M., Lebedev M.A., Crist R.E., et al. Learning to control a brain-machine interface for reaching and grasping by primates. *PLoS Biol.* 2003;(1):e42.
8. Musk E. An integrated brain-machine interface platform with thousands of channels. *J. Med. Internet. Res.* 2019;(21):e16194. <https://doi.org/10.2196/16194>.
9. Vidal J.J. Toward direct brain-computer communication. *Annu. Rev. Biophys. Bioeng.* 1973;(2):157-180. <https://doi.org/10.1146/annurev.bb.02.060173.001105>.
10. Hu K., Chen C., Meng Q., et al. Scientific profile of brain-computer interfaces: bibliometric analysis in a 10-year period. *Neurosci. Lett.* 2016;(635):61-66. <https://doi.org/10.1016/j.neulet.2016.10.022>.
11. Huang J., Huang L., Li Y., et al. A Bibliometric analysis of the application of brain-computer interface in rehabilitation medicine over the past 20 years. *J. Multidiscip. Healthc.* 2025;(18):1297-1317. <https://doi.org/10.2147/JMDH.S509747>.
12. Santamaria-Vazquez E., Martinez-Cagigal V., Vaquerizo-Villar F., et al. EEG-inception: a novel deep convolutional neural network for assistive ERP-based brain-computer interfaces. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2020;(28):2773-2782.
13. Kapsetaki M.E. Scientometric analysis of Greek publications on stereotactic and functional neurosurgery. *Next Res.* 2025;(2):e 100531. <https://doi.org/10.1016/j.nexres.2025.100531>.
14. Yin Z., Wan Y., Fang H., et al. Bibliometric analysis on brain-computer interfaces in a 30-year period. *Appl. Intell.* 2023;(53):16205-16225.
15. Sakhavi S., Guan C., Yan S. Learning temporal information for brain-computer interface using convolutional neural networks. *IEEE Trans. Neural Netw. Learn. Syst.* 2018;(29):5619-5629.
16. Kapsetaki M.E. Brain-computer interfaces for memory enhancement: Scientometric analysis and future directions. *Biomedical Signal Processing and Control.* 2026;112:108904. <https://doi.org/10.1016/j.bspc.2025.108904>.
17. Lee E., Kang Y., Kim H., Lee J. Neurofeedback & P300 toolbox for neurorehabilitation: measurement and analysis of brain activity, network and cognitive decline-related P300. *Biomedical Physics & Engineering Express.* 2025;11(6):65004. <https://doi.org/10.1088/2057-1976/ae0ad7>.
18. Wetzel D., Jacobs P.-P., Winkler D., Grunert R. Significance of EEG-electrode combinations while calculating filters with common spatial patterns. *Ger. Med. Sci.* 2024;22. <https://doi.org/10.3205/000334>.
19. Chakole A.R., et al. Review of EEG signal classification. *Information and Communication Technology for Intelligent Systems: Proceedings of ICTIS 2018*. Vol. 2. Singapore: Springer; 2019. P. 105–114. https://doi.org/10.1007/978-981-13-1747-7_11.

20. Kalach A.V., Kozhevnikov I.S., Kravchenko A.S., et al. Comparative analysis of the features of the architectures of decision support systems for adapting educational programs: from RuBERT to ontological graph models. *Modelirovanie sistem i processov = Modeling Systems and Processes*. 2025;18(3):62-70. (In Russ.) <https://doi.org/10.12737/2219-0767-2025-18-3-62-70>. EDN ESUQJE.

21. Lu Y., Wang W., Lian B., He C. Feature Extraction and Classification of Motor Imagery EEG Signals in Motor Imagery for Sustainable Brain – Computer Interfaces. *Sustainability*. 2024;16:6627. <https://doi.org/10.3390/su16156627>.

22. Nambiar A., Sivakumar R., Subramaniam S. Detection of Four Class Motor Imagery from EEG Signal for Brain-Computer Interface Applications. *Applied Mathematics, Modeling and Computer Simulation*. 2023. <https://doi.org/10.3233/ATDE231028>.

23. Stankevich L.A., Zhuravskaya A. Control of a mobile robot based on a neurointerface. *Ekstremal'naya robototekhnika = Extreme Robotics*. 2022;(1):348-354. (In Russ.) EDN: RWPBSY.

24. Zhuravlev D.V., Golubinsky A.N., Reznichenko A.A. Universal software and hardware complex for controlling robotic devices based on the principles of operation of synchronous or asynchronous brain-computer interfaces. *Zhurnal radioelektroniki = Journal of Radio Electronics*. 2025;(1):9. <https://doi.org/https://doi.org/10.30898/1684-1719.2025.1.1>. (In Russ.)

25. Kingma D.P. Adam: A method for stochastic optimization. Available at: <https://archive.org/details/arxiv-1412.6980> (accessed 10.03.2026).

Информация об авторах / Information about the Authors

Журавлёв Дмитрий Владимирович,
кандидат технических наук, доцент,
заведующий кафедрой радиоэлектронных
устройств и систем, Воронежский
государственный технический университет,
г. Воронеж, Российская Федерация,
e-mail: ddom1@yandex.ru,
ORCID: 0000-0002-1087-9704

Dmitry V. Zhuravlev, Cand. Sci. (Engineering),
Associate Professor, Head of the Department
of Radioelectronic Devices and Systems,
Voronezh State Technical University,
Voronezh, Russian Federation,
e-mail: ddom1@yandex.ru,
ORCID: 0000-0002-1087-9704

Соловьев Александр Семенович,
доктор технических наук, профессор,
Воронежский институт Федеральной
службы исполнения наказаний России,
г. Воронеж, Российская Федерация,
e-mail: ASoloviev58@yandex.ru,
ORCID: 0000-0002-6150-1090

Alexander S. Soloviev, Dr. Sci. (Engineering),
Professor, Voronezh Institute of the Federal
Penitentiary Service of Russia,
Voronezh, Russian Federation,
e-mail: ASoloviev58@yandex.ru,
ORCID: 0000-0002-6150-1090

Кузьменко Роман Валентинович, доктор физико-математических наук, доцент, профессор кафедры радиоэлектронных устройств и систем, Воронежский государственный технический университет; профессор кафедры математики и естественно-научных дисциплин, Воронежский институт Федеральной службы исполнения наказаний России, г. Воронеж, Российская Федерация, e-mail: roman_kuzmenko@inbox.ru

Калач Андрей Владимирович, доктор химических наук, профессор, заведующий кафедрой информационных технологий, моделирования и управления, Воронежский государственный университет инженерных технологий, г. Воронеж, Российская Федерация, e-mail: a_kalach@mail.ru, ORCID: 0000-0002-8926-3151

Roman V. Kuzmenko, Dr. Sci. (Physical and Mathematical), Associate Professor, Professor at the Department of Radioelectronic Devices and Systems, Voronezh State Technical University; Professor at the Department of Mathematics and Natural Sciences, Voronezh Institute of the Federal Penitentiary Service of Russia, Voronezh, Russian Federation, e-mail: roman_kuzmenko@inbox.ru

Andrew V. Kalach, Dr. Sci. (Chemical), Professor, Head of the Department of Information Technology, Modeling and Management, Voronezh State University of Engineering Technologies, Voronezh, Russian Federation, e-mail: a_kalach@mail.ru, ORCID: 0000-0002-8926-3151

<https://doi.org/10.21869/2223-1536-2026-16-2-39-53>



УДК 616.24-002.2-07:004.9

Разработка и валидация комплекса программ для дистанционной оценки статуса пациентов с хронической обструктивной болезнью легких

Ю. А. Трусов¹ ✉, А. А. Гаранин¹

¹ Самарский государственный медицинский университет Министерства здравоохранения Российской Федерации
ул. Чапаевская, д. 89, г. Самара 443099, Российская Федерация

✉ e-mail: yu.a.trusov@samsmu.ru

Резюме

Цель исследования – проанализировать возможность применения опросников: *Clinical COPD Questionnaire*, *COPD Assessment Test* и *modified Medical Research Council Dyspnoea Scale* – для дистанционной оценки состояния здоровья пациентов с хронической обструктивной болезнью лёгких и их интеграции в программный комплекс, разработанный с целью динамического мониторинга в амбулаторных условиях.

Методы. Разработка настоящего программного комплекса выполнена с использованием языка программирования *Python*. Архитектура комплекса включает в себя модуль автоматизированного расчета баллов в реальном времени, систему обезличивания персональных данных и локальную базу данных. Для обеспечения автономной работы разработана офлайн-версия рассматриваемого комплекса с графическим интерфейсом на базе библиотеки *Tkinter*. В алгоритм заложены математические модели интерпретации шкал, соответствующие международным стандартам.

Результаты. Разработан функциональный программный комплекс, обеспечивающий сбор и структурирование данных о симптомах, функциональном состоянии и психическом статусе пациентов. Комплекс позволяет формировать долгосрочные архивы показателей для оценки течения заболевания. Внутреннее тестирование подтверждает 100%-ную воспроизводимость расчетов и стабильность передачи данных. Интеграция API обеспечивает потенциальную совместимость с государственными медицинскими информационными системами.

Заключение. Разработанный программный комплекс соответствует принципам бережливого производства в здравоохранении и позволяет сократить временные затраты врачей специалистов на 20–30% за счет автоматизации рутинных вычислений. Внедрение системы в амбулаторную практику способствует переходу к проактивной модели ведения ХОБЛ, тем самым обеспечивая раннее выявление обострений и снижение частоты повторных госпитализаций. Адаптация к российским нормативным требованиям делает комплекс перспективным решением для отечественной телемедицины.

Ключевые слова: хроническая обструктивная болезнь легких; телемедицина; дистанционный мониторинг; программный комплекс; медицинские информационные системы.

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

© Трусов Ю. А., Гаранин А. А., 2026

Для цитирования: Трусов Ю. А., Гаранин А. А. Разработка и валидация комплекса программ для дистанционной оценки статуса пациентов с хронической обструктивной болезнью легких // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 39–53. <https://doi.org/10.21869/2223-1536-2026-16-2-39-53>.

Поступила в редакцию 16.04.2026

Подписана в печать 14.05.2026

Опубликована 30.06.2026

Development and validation of a software complex for remote assessment of the status of patients with chronic obstructive pulmonary disease

Yury A. Trusov¹ ✉, Andrey A. Garanin¹

¹ Samara State Medical University of the Ministry of Health of the Russian Federation
89 Chapaevskaya Str., Samara 443099, Russian Federation

✉ e-mail: yu.a.trusov@samsmu.ru

Abstract

The purpose of the research is analyze the possibility of using questionnaires: Clinical COPD Questionnaire, COPD Assessment Test and modified Medical Research Council Dyspnoea Scale - for remote assessment of the health status of patients with chronic obstructive pulmonary disease and their integration into a software package developed for the purpose of dynamic monitoring in an outpatient setting.

Methods. The software system was developed using the Python programming language. Its architecture includes a real-time automated scoring module, a personal data de-identification system, and a local database. To ensure offline functionality, an offline version of the system was developed with a graphical user interface based on the Tkinter library. The algorithm incorporates mathematical models for interpreting the scales in accordance with international standards.

Results. A functional software system was developed that enables the collection and structured storage of data on symptoms, functional status, and mental health status of patients. The system allows for the creation and maintenance of long-term archives of parameters to assess disease progression. Internal testing confirms 100% reproducibility of calculations and stability of data transfer. API integration ensures potential compatibility with state medical information systems.

Conclusion. The developed software system aligns with the principles of lean healthcare and can reduce specialist physician time expenditure by 20–30% through the automation of routine calculations. Implementation of the system into outpatient practice facilitates a transition to a proactive model of COPD management, thereby enabling early detection of exacerbations and reducing the rate of rehospitalizations. Adaptation to Russian regulatory requirements positions the system as a promising solution for national telemedicine.

Keywords: chronic obstructive pulmonary disease; telemedicine; remote monitoring; software complex; medical information systems.

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

For citation: Trusov Y.A., Garanin A.A. Development and validation of a software complex for remote assessment of the status of patients with chronic obstructive pulmonary disease. *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(2):39–53. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-39-53>.

Received 16.04.2026

Accepted 14.05.2026

Published 30.06.2026

Введение

Хроническая обструктивная болезнь легких (ХОБЛ) является одной из актуальных задач здравоохранения по причине её высокой распространенности, хронического и рецидивирующего течения заболевания с периодическими обострениями, что в совокупности создает дополнительную экономическую нагрузку. Согласно определению Global Initiative for Chronic Obstructive Lung Disease (GOLD 2023), ХОБЛ представляет собой гетерогенное состояние легких, характеризующееся следующими симптомами: одышкой, кашлем, отхождением мокроты и стойкой бронхиальной обструкцией [1]. Клиническая картина ХОБЛ характеризуется хроническим бронхитом и эмфиземой с симптомами стойкого кашля, одышки и снижения трудоспособности, что ведет к значительному ухудшению качества жизни и существенному социально-экономическому бремени. По данным Всемирной организации здравоохранения (ВОЗ), в 2021 г. летальность по причине ХОБЛ во всем мире составила около 3,5 млн человек, при этом сохраняется тенденция к росту данного показателя в связи со старением населения и воздействием факторов окружающей среды [2].

Высокая распространенность ХОБЛ считается одним из основных факторов, который определяет прогноз течения заболевания и стоимость лечения, а также не менее значимым фактором является риск повторных госпитализаций на фоне обострений. По данным метаанализа, проведенного Ruan H. et al., уровень ремиссий после обострения ХОБЛ достигает 11% в течение 30 дней и 37% в течение года [3]. Описанные факторы оказывают высокую нагрузку на систему обязательного медицинского страхования (ОМС), что делает актуальным

поиск технологий для оптимизации расходов средств и времени, которые соответствуют целям национальных проектов, направленных на повышение эффективности и доступности медицинской помощи [4]. Своевременное выявление и профилактика острых обострений (АЕСОПД) являются важным аспектом ведения пациентов, так как частые эпизоды обострения способствуют снижению функции легких и повышению риска летального исхода [2].

Несмотря на существующие данные, доказывающие эффективность данных технологий, отечественная практика дистанционного динамического наблюдения за больными с ХОБЛ характеризуется отсутствием систематизации. Мониторинг пациентов в РФ основан на эпизодических коммуникациях, включающих телефонные звонки, что не позволяет проводить объективную количественную оценку динамики состояния пациента с использованием валидированных шкал [4]. Внедрение программ самостоятельного наблюдения для снижения бремени ХОБЛ является сложной задачей ресурсов для решения вопросов лечения [5]. Отсутствие объединенного цифрового сервиса затрудняет аудит качества оказания медицинской помощи, а также формирование базы данных для внедрения принципов бережливого производства в рутинную клиническую практику. Исходя из приведенных выше данных, на сегодняшний день существует потребность в разработке и внедрении системы дистанционного динамического мониторинга за пациентами, которая должна включать в себя валидированные методы оценки и преемственность наблюдения, а также соответствовать государственным стандартам оказания медицинской помощи.

Цель исследования – проанализировать возможность применения опросников: CCQ (Clinical COPD Questionnaire), CAT (COPD Assessment Test) и mMRC (modified Medical Research Council Dyspnoea Scale) – для дистанционной оценки состояния здоровья пациентов с ХОБЛ и их интеграции в программный комплекс, разработанный с целью динамического мониторинга в амбулаторных условиях.

Материалы и методы

На сегодняшний день для комплексной оценки состояния пациентов с ХОБЛ применяется несколько валидированных инструментов, а именно: клинический опросник ХОБЛ (Clinical COPD Questionnaire, CCQ) – валидированный инструмент для самостоятельной оценки своего состояния пациентами, который позволяет количественно оценивать роль симптомов заболевания на физическое, эмоциональное состояние пациента и его бытовую активность; тест оценки ХОБЛ (COPD Assessment Test, CAT) – стандартизированный опросник, направленный на комплексную оценку симптомов ХОБЛ и их влияние на качество жизни пациента, а также модифицированная шкала одышки, разработанная координационным советом по исследованиям и разработкам в области медицинской науки (modified Medical Research Council Dyspnoea Scale, mMRC), – количественная шкала для оценки тяжести одышки, отражающая влияние симптома на бытовую активность пациента.

Описанные инструменты дополняют друг друга и позволяют проводить динамическое наблюдение за состоянием пациентов, оценку эффективности проводимой терапии, коррекцию терапевтической тактики и прогнозирование течения заболевания. Данные инструменты прошли международную валида-

цию и рекомендованы к применению в клинической практике.

На платформе научно-практического центра дистанционной медицины Самарского государственного медицинского университета введен в разработку программный комплекс, основной функцией которого является удаленная оценка состояния пациентов с ХОБЛ исходя из данных, полученных на основе опросников CCQ, CAT и mMRC, и представляющий собой веб-приложение, функционирующее в любом браузере после его успешной интеграции в web-среду и включающее три основных модуля: программный калькулятор для оценки баллов по CCQ, CAT и mMRC в режиме реального времени, онлайн-комплекс для передачи, обработки и хранения данных на удаленном сервере, а также базу данных для локального хранения информации. Реализация проекта выполнена с использованием языка программирования Python для разработки алгоритмов обработки данных.

Опросник CCQ включает в себя 10 компонентов (Q1-Q10), каждый из которых оценивается по шкале от 0 до 6 баллов. Перед расчетом показателей баллы, полученные при прохождении теста респондентами, преобразуются с использованием ключа опросника. Общий показатель и домены вычисляются с использованием общего алгоритма:

$$\text{\$ Показатель} = \frac{\text{Сумма баллов по вопросам домена}}{\text{Количество вопросов в домене}} \text{\$},$$

где сумма баллов – сумма значений ответов на вопросы, входящие в домен или общий опросник. Таким образом, общий показатель представляет собой значение от 0 (отсутствие проявлений симптомов) до 6 (максимальная их выраженность). Критерии, оцениваемые для расчета общего показателя, выглядят следующим образом:

Симптомы (Symptoms): $\$ \text{Symptoms} = \frac{(Q1 + Q2 + Q5 + Q6)}{4} \$$;

Функциональное состояние (Functional state): $\$ \text{Functional} = \frac{(Q7 + Q8 + Q9 + Q10)}{4} \$$;

Психическое состояние (Mental state): $\$ \text{Mental} = \frac{(Q3 + Q4)}{2} \$$;

Общий балл CCQ: $\$ \text{CCQ} = \frac{(Q1 + Q2 + Q3 + Q4 + Q5 + Q6 + Q7 + Q8 + Q9 + Q10)}{10} \$$.

Опросник САТ включает в себя 8 компонентов, каждый из которых оценивается от 0 до 5 баллов. Перед расчетом показателей ответы респондентов также преобразуются в соответствии с заданным ключом для данного опросника.

Общий показатель вычисляется по следующему общему алгоритму:

$\$ \text{Показатель} = \text{Сумма} \backslash \text{баллов} \backslash \text{по} \backslash \text{всем} \backslash 8 \backslash \text{вопросам} \$$,

где сумма баллов – сумма значений, складывающаяся из ответов на вопросы, входящие в опросник. Общий показатель, который можно получить по опроснику САТ составляет от 0 (отсутствие симптомов) до 40 (максимальная выраженность симптомов). Показатели для расчета общей суммы:

Кашель (Cough): $\$ Q1 \$$ (балл от 0 до 5);

Мокрота (Phlegm): $\$ Q2 \$$ (балл от 0 до 5);

Тяжесть в груди (Chest tightness): $\$ Q3 \$$ (балл от 0 до 5);

Одышка при подъеме по лестнице (Breathlessness going up hills/stairs): $\$ Q4 \$$ (балл от 0 до 5);

Ограничение активности (Activity limitation at home): $\$ Q5 \$$ (балл от 0 до 5);

Выход из дома (напряжение, тяжесть, страх) (Confidence leaving home): $\$ Q6 \$$ (балл от 0 до 5);

Сон (Sleep): $\$ Q7 \$$ (балл от 0 до 5);

Энергичность (Energy): $\$ Q8 \$$ (балл от 0 до 5).

Общий балл САТ: $\$ \text{CAT} = Q1 + Q2 + Q3 + Q4 + Q5 + Q6 + Q7 + Q8 \$$.

Шкала mMRC включает один компонент (оценка одышки), оцениваемый по шкале от 0 до 4 баллов. Перед расчетом показатель также преобразуется в соответствии с ключом. Общий показатель вычисляется напрямую как выбранный уровень одышки:

$\$ \text{Показатель} = \text{Уровень} \backslash \text{одышки} \$$,

где уровень одышки – значение от 0 (одышка только при интенсивной нагрузке) до 4 (одышка в покое или при минимальной активности). Показатель шкалы mMRC представляет собой значение от 0 (минимальная одышка) до 4 (максимальная одышка). Критерии расчета показателя выглядят следующим образом:

0: Одышка только при интенсивной физической нагрузке;

1: Одышка при быстрой ходьбе по ровной поверхности или подъеме на небольшой уклон;

2: Необходимость остановок при ходьбе в своем темпе;

3: Остановка при ходьбе из-за одышки каждые ~100 метров или нескольких минут ходьбы по ровной поверхности;

4: Одышка при бытовой активности, затруднения при одевании / раздевании, затруднения при выходе из дома.

Также был разработан функционал «обезличивания» данных с целью поддержания конфиденциальности пациентов.

Результаты и их обсуждение

В настоящем исследовании авторами был разработан программный комплекс, интегрирующий в себя опросники CCQ, САТ и mMRC (рис. 1–4). Разрабо-

танный программный комплекс включает в себя: программу-калькулятор, который позволяет высчитывать полученное количество баллов для оценки статуса пациентов непосредственно при работе с пациентом в режиме реального времени, программы с аппаратным онлайн-комплексом, которая позволяет передавать, обрабатывать и сохранять информацию на удаленном сервере в региональном центре дистанционной медицины, с возможностью интеграции в профильное учреждение, а также программы с офлайн-базой, которая позволяет собирать весь массив данных непосредственно в пространственной памяти электронной вычислительной машине (ЭВМ), на которой происходит внесение данных.




Рис. 1. Главное меню программы с выбором опросника (CCQ, CAT, mMRC)

Fig. 1. Main menu of the software with questionnaire selection (CCQ, CAT, mMRC)

В основе программного комплекса лежит алгоритм, написанный на языке программирования Python, который собирает, систематизирует, статистически обрабатывает и хранит информацию о пациентах на локальном или облачном сервере. При необходимости передачи данных, например при сборе статистической информации в центре дистанционной медицины, электронный помощник «обезличивает» данные о пациенте с целью безопасного хранения массива данных.




Рис. 2. Окно ввода данных опросника CAT: вопрос Q1 «Кашель» с визуальным ползунком для оценки выраженности симптома от 0 до 5 баллов¹

Fig. 2. Data entry window for the CAT questionnaire: question Q1 "Cough" with a visual slider for assessing symptom severity from 0 to 5 points¹




Рис. 3. Результаты опроса по шкале mMRC: отражение выбранного уровня одышки (в примере – уровень 3) с кнопкой «Назад» для возврата к выбору опросника или повторному прохождению

Fig. 3. Results of the mMRC scale: display of the selected dyspnea level (in the example, level 3) with a "Back" button to return to questionnaire selection or to retake the assessment

Программа интегрируема в интерфейс любого браузера, который назначен по умолчанию у пользователя на компьютере. При этом специалист может проводить серию исследований на

¹ Интерфейс программы позволяет проходить все 8 вопросов.

группе пациентов, формируя тем самым базу данных на своем компьютере, а затем проводить анализ состояния пациентов в конкретной когорте больных или в популяции. Помимо вышеописанного программа позволяет удаленно оценивать статус пациентов стороннему наблюдателю, у которого имеются для этого права и доступ к облаку хранения данных, с любой точки, подключенной к сети Интернет, что позволяет проводить массовый удаленный мониторинг пациентов с ХОБЛ в любой точке нашей страны.




Рис. 4. Результаты опроса по опроснику CCQ: вывод результатов по доменам (Симптомы: 0,50; Психическое состояние: 1,00; Функциональное состояние: 2,25) и общему баллу (1,30)¹

Fig. 4. Results of the CCQ questionnaire: domain-specific scores (Symptoms: 0.50; Mental State: 1.00; Functional State: 2.25) and total score (1.30)¹

Офлайн-версия разработанного комплекса (интегрируемая в веб-платформу и проходящая клиническую валидацию) реализована в виде самостоятельного приложения с графическим интерфейсом с использованием библиотеки Tkinter (Python) для демонстрации функционала. Данная версия автономна

и работает без сети Интернет, включая: выбор опросника, поле ввода ответов с помощью ползунка (scale), а также функцию расчета результатов в реальном времени и отображение результатов.

Пользователь выбирает один из трех инструментов оценки статуса пациента с ХОБЛ и проходит последовательно каждый из предложенных опросников, результаты которых экспортируются в базу данных.

В результате проведения опроса на экран выводится результат анкетирования обследуемого, рассчитанный с помощью интегрированных в ядро программы математических формул в соответствии с алгоритмами интерпретации результатов опросников CCQ, CAT и mMRC (см. рис. 2, 4). Основным преимуществом настоящего программного комплекса является интеграция валидированных шкал CCQ, CAT и mMRC. Это обеспечивает высокую степень достоверности получаемых данных. Программа гарантирует воспроизводимость результатов и предоставляет возможность обращения к электронному архиву показателей, полученных ранее, для оценки их в динамике. Офлайн-версия комплекса успешно прошла внутреннее тестирование на воспроизводимость расчетов и удобство использования и в настоящее время проходит валидацию интегрированной онлайн-версии на веб-платформе научно-практического центра дистанционной медицины.

Разработанный программный комплекс представляет собой практический подход к оптимизации ведения больных в амбулаторных условиях и интегрирует в себя валидированные

¹ Позволяет врачу-специалисту интерпретировать выраженность симптомов и степень ограничений жизнедеятельности пациента.

международные опросники Clinical COPD Questionnaire (CCQ), COPD Assessment Test (CAT) и modified Medical Research Council Dyspnoea Scale (mMRC) в единую цифровую платформу, оснащенную модулями для расчета показателей в реальном времени, безопасного хранения и последующего анализа данных. Полноценная оценка симптомов на сегодняшний день является важной составляющей процесса лечения в сравнении с простым измерением выраженности нарушений функции дыхания [6].

Для системы здравоохранения преимущества настоящего комплекса заключаются в реализации принципов бережливого производства, при которой автоматизация рутинного сбора данных позволяет сократить временные затраты труда специалиста на 20-30% за счет автоматизированной обработки данных. Отсутствие взаимодействия систем внутри медицинских организаций и между ними часто приводит к дополнительным финансовым затратам и повторным обследованиям, что говорит о необходимости разработки единой системы обмена данными [7]. Использование автоматизированных систем позволяет проводить профилактику повторных госпитализаций путем раннего выявления рецидивов, что подтверждается корреляцией показателей CCQ с риском обострений. При этом установлено, что общий балл CCQ, в частности его функциональный и симптоматический домены, является независимым фактором риска повторных госпитализаций в течение 3 лет. Функциональный домен CCQ (Q10) имеет наиболее высо-

кую точность в прогнозировании повторных госпитализаций в сравнении с симптоматическим доменом (Q1-Q5) [8]. Прогностическая способность функционального домена значительно выше, чем у симптоматического или ментального доменов, и его использование в качестве дополнения к наблюдению динамики обострений существенно повышает точность предсказательных моделей [9]. Данная система снижает экономическую нагрузку на систему ОМС за счет интеграции в рамки проектов, направленных на повышение доступности оказания медицинской помощи. Помимо этого, программный комплекс позволяет проводить аудит качества на основе собираемой базы данных.

В контексте работы врачей-специалистов настоящий комплекс стандартизирует процедуру оценки путем автоматизации расчета баллов по включенным опросникам в полном соответствии со стандартными операционными процедурами (СОП). Наглядная демонстрация визуализации динамики состояния в реальном времени через графический интерфейс Tkinter является инструментом для принятия обоснованных решений о коррекции терапии, что подтверждается корреляцией CAT с SGRQ ($r = 0,652$) и CCQ с SGRQ ($r = 0,621$), которые демонстрируют надежность инструмента для применения в клинической практике [10]. Опросники CAT и CCQ также демонстрируют значимую корреляцию с индексом BODE и показателями объема форсированного выдоха (ОФВ1), что подтверждает их статус как чувстви-

тельных и надежных инструментов для планирования лечения [6].

Для пациентов преимущества заключаются в упрощенной коммуникации с лечащим врачом, при интеграции данного комплекса в веб-платформы, доступные в любом браузере, повышает приверженность лечению путем самостоятельного контроля течения симптомов. Аналогичный эффект наблюдается при использовании мобильных приложений, целью которых является мониторинг оксигенотерапии, где показатель САТ снижается в среднем на 5 баллов (с 27 до 22), что повышает качество жизни и снижает показатель одышки по шкале Borg на 3,5 пункта [11]. Такой метод самостоятельной оценки симптомов повышает контроль за состоянием со стороны пациентов, что особенно важно в амбулаторных условиях, в которых традиционные методы не обеспечивают непрерывного динамического наблюдения. Данный подход соответствует проактивной модели профилактики обострений заболевания, что позволяет снизить риск повторных госпитализаций на 19% у пациентов из группы высокого риска, согласно данным ассоциаций САТ с выраженностью симптомов [12].

При сравнении с зарубежными аналогами, такими как myCOPD и COPD Navigator [13], которые интегрируют в себя функции самостоятельного контроля и модуль обучения, но при этом ориентированы на англоязычную аудиторию с акцентом на применение технологий виртуальной реальности или планшетов (такие технологии демонстрируют улучшение результатов в те-

сте 6-минутной ходьбы (6MWD) на 47 м и САТ на 2,91 пункта [14]), разработанный комплекс адаптирован к российским нормативным требованиям. Это позволяет интегрировать данный комплекс в отечественные медицинскими информационными системами через унифицированный API, что обеспечивает преемственность с региональными лечебными заведениями. Внедрение подобных связующих программ важно для обеспечения обмена данными между мобильными приложениями и электронными медицинскими записями [15].

К ограничениям настоящего комплекса можно отнести проблему цифрового разрыва, особенно выраженную среди пациентов пожилого возраста и жителей сельских регионов, у которых низкая цифровая грамотность и плохая интернет-инфраструктура могут снижать уровень приверженности [16]. Однако данное ограничение можно преодолеть за счет возможности привлечения родственников или реализации гибридного режима, при котором опрос проводится медицинской сестрой по телефону с последующим внесением данных в систему через программный комплекс, что аналогично подходам в исследованиях с применением VR, в которых гетерогенность нивелируется за счет персонализации [17]. Адаптация цифровых технологий для работы в условиях низкой пропускной способности сети и участие социальных работников являются реализуемыми путями преодоления цифровых сложностей в здравоохранении [16]. Необходимость глубокой интеграции с медицинскими

информационными системами решается путем разработки API и установления партнерских отношений с ведущими разработчиками в России, что в перспективе позволит синхронизировать данные с результатами спирометрии и пульсоксиметрии для комплексной оценки. Программа является инструментом поддержки принятия решений, а не заменой заключению специалиста, поскольку субъективность шкал (например, CCQ с порогом 1,4, который лучше прогнозирует $SGRQ \geq 25$, чем порог 1,0) требует обязательной интеграции с объективными клиническими данными для снижения гетерогенности оценки [18].

Разработанный комплекс соответствует современным концепциям менеджмента качества, обеспечивая постоянный мониторинг основных показателей состояния пациента (KPI), таких как CAT и mMRC, и формирует основу для реализации PDCA-цикла (цикла Деминга) при ведении пациентов с хроническими заболеваниями. Эффективность данного подхода подтверждается улучшением качества жизни на 16,5% у пациентов из группы риска и снижением частоты осложнений на 67% [12], что подчеркивает научную новизну его применения в российских условиях и потенциал для снижения частоты обострений путем интеграции с программами реабилитации, в которых комбинация с физическими тренировками снижает количество госпитализаций и улучшает переносимость физических нагрузок [14]. Несмотря на необходимость дальнейших клинических испытаний для подтверждения

минимальной клинически значимой разницы (MCID, 2 пункта для CAT по якорному методу), система предоставляет перспективную технологию для развития телемедицинских технологий [19], а корреляции показателей CCQ и CAT с индексом BODE ($r = 0,80$ и $0,66$ соответственно) демонстрирует их прогностическую ценность для оценки клинических исходов у пациентов с ХОБЛ [20].

Выводы

Разработанный программный комплекс для дистанционной оценки статуса пациентов с ХОБЛ представляет собой методологически обоснованное решение, интегрирующее в себя международные инструменты для мониторинга (CCQ, CAT, mMRC) в единую цифровую платформу. Он обеспечивает стандартизированное, автоматизированное и динамическое наблюдение в амбулаторных условиях, способствуя реализации принципов бережливого производства и преемственности оказания медицинской помощи. Настоящий комплекс демонстрирует потенциал, который позволяет снизить нагрузку на систему здравоохранения за счет профилактики обострений и оптимизации временных затрат медицинского персонала. Адаптация к российским нормативным требованиям и возможность интеграции с отечественными медицинскими информационными системами через API позволяют преодолевать фрагментированность существующих методов в направлении наблюдения за пациентами с ХОБЛ. Несмотря на существующие ограничения, связанные с

цифровым разрывом, и необходимость дальнейшей клинической валидации MCID, внедрение данного комплекса имеет перспективы для развития персо-

нализированной телемедицины, аудита качества на основе сбора данных и проведения популяционных исследований в Российской Федерации.

Список литературы

1. Alghamdi S. M. Content, Mechanism, and Outcome of Effective Telehealth Solutions for Management of Chronic Obstructive Pulmonary Diseases: A Narrative Review // Healthcare. 2023. N 11(24). P. 3164. <https://doi.org/10.3390/healthcare11243164>.
2. Artificial Intelligence Methods and Digital Intervention Strategies for Predicting and Managing Chronic Obstructive Pulmonary Disease Exacerbations: An Umbrella Review / M. Pozza, N. Navarin, V. Sakkalis, S. Gabrielli // Healthcare. 2025. N 13(23). P. 3037. <https://doi.org/10.3390/healthcare13233037>.
3. Readmission rate for acute exacerbation of chronic obstructive pulmonary disease: a systematic review and meta-analysis / H. Ruan, H. Zhang, J. Wang, H. Zhao, W. Han, J. Li // Respir. Med. 2023. N 206. P. 107090. <https://doi.org/10.1016/j.rmed.2022.107090>.
4. Телемедицина в пульмонологии: достижения и перспективы / Л. Ю. Шван, И. В. Губарева, О. В. Фатенков, Е. Ю. Губарева, Д. О. Фатенков // Ульяновский медико-биологический журнал. 2024. № 4. С. 6–24. <https://doi.org/10.34014/2227-1848-2024-4-6-24>.
5. Effectiveness of Mobile Health–Based Self-Management Programs on Health-Related Outcomes in Patients With Chronic Obstructive Pulmonary Disease: Systematic Review and Meta-Analysis / G. N. Prawesti, P. Lo, M. A. Sarasmita, H. Y. Chen // JMIR Mhealth Uhealth. 2025. N 13. P. e74967. <https://doi.org/10.2196/74967>.
6. Kaur A., Goyal A., Pandhi N. To Study the Correlation of Chronic Obstructive Pulmonary Disease (COPD) Assessment Test, Clinical COPD Questionnaire, and BODE Index in Patients of Stable COPD // Assam. J. Intern. Med. 2022. N 12(1). P. 18–23. https://doi.org/10.4103/ajom.ajom_21_21.
7. Literature Review: Clinical Data Interoperability Models / R. Ait Abdelouahid, O. Debauche, S. Mahmoudi, A. Marzak // Information. 2023. N 14(7). P. 364. <https://doi.org/10.3390/info14070364>.
8. Predictive Value of CCQ and its Subdomains for Hospitalized Exacerbations in Chronic Obstructive Pulmonary Disease: A 3-Year Observational Prospective Study / Z. Zhou, W. Cheng, C. Liu [et al.] // J. Gen. Intern. Med. 2025. N 40. P. 1550–1558. <https://doi.org/10.1007/s11606-024-09067-0>.
9. Predictive Value of CCQ and its Subdomains for Hospitalized Exacerbations in Chronic Obstructive Pulmonary Disease: A 3-Year Observational Prospective Study /

Z. Zhou, W. Cheng, C. Liu [et al.] // J. Gen. Intern. Med. 2025. N 40. P. 1550–1558. <https://doi.org/10.1007/s11606-024-09067-0>.

10. Psychometric Analysis of Clinical Chronic Obstructive Pulmonary Disease Questionnaire and Chronic Obstructive Pulmonary Disease Assessment Test and Its Correlation with St. George Respiratory Questionnaire in Chronic Obstructive Pulmonary Disease Patients / S. A. Ali, H. Saniya, K. Naseeruddin [et al.] // Indian. J. Respir. Care. 2022. N 11. P. 224–229. https://doi.org/10.4103/ijrc.ijrc_89_22.

11. The COPD assessment test: a systematic review / N. Gupta, L. M. Pinto, A. Morogan, J. Bourbeau // Eur. Respir. J. 2014. N 44(4). P. 873–884. <https://doi.org/10.1183/09031936.00025214>.

12. Комплексная оценка степени тяжести хобл на амбулаторно-поликлиническом приеме / А. А. Низов, А. Н. Ермачкова, В. Н. Абросимов, И. Б. Пономарева // Российский медико-биологический вестник имени академика И. П. Павлова. 2019. Т. 27, № 1. С. 59–65. <https://doi.org/10.23888/PAVLOVJ201927159-65>.

13. Development of a Standard Set of Outcome Domains and Proposed Measures for Chronic Obstructive Pulmonary Disease in Primary Care Physical Therapy Practice in the Netherlands: a Modified RAND/UCLA Appropriateness Method / A. C. Verburg, S. A. van Dulmen, H. Kiers, J. H. Ypinga, M. W. Nijhuis-van der Sanden, P. J. van der Wees // Int. J. Chron. Obstruct. Pulmon. Dis. 2019. N 14. P. 2649–2661. <https://doi.org/10.2147/COPD.S219851>.

14. Efficacy and Acceptability of a Mobile App for Monitoring the Clinical Status of Patients With Chronic Obstructive Pulmonary Disease Receiving Home Oxygen Therapy: Randomized Controlled Trial / A. Naranjo-Rojas, L. Á. Perula-de Torres, F. E. Cruz-Mosquera, G. qMolina-Recio // J. Med. Internet. Res. 2025. N 27. P. e65888. <https://doi.org/10.2196/65888>.

15. Ndlovu K., Scott R. E., Mars M. Interoperability opportunities and challenges in linking mhealth applications and eRecord systems: Botswana as an exemplar // BMC Med. Inform. Decis. Mak. 2021. N 21. P. 246. <https://doi.org/10.1186/s12911-021-01606-7>.

16. Mbanugo O. J. The new normal-chronic disease management and digital healthcare practice in rural and low internet environments. GSC Biological and Pharmaceutical Sciences. 2020. N 13(1). P. 279–300. <https://doi.org/10.30574/gscbps.2020.13.1.0315>.

17. The cutoff point of clinical chronic obstructive pulmonary disease questionnaire for more symptomatic patientsn / Y. S. Jo, S. Park, D. K. Kim [et al.] // BMC Pulm. Med. 2018. N 18. P. 38. <https://doi.org/10.1186/s12890-018-0601-0>.

18. Качество жизни больных хронической обструктивной болезнью легких с различным риском развития обострений / Е. Г. Кулик, В. И. Павленко, С. В. Нарышкина, О. М. Гончарова // Бюллетень физиологии и патологии дыхания. 2020. Вып. 75. С. 47–52. <https://doi.org/10.36604/1998-5029-2020-75-47-52>.

19. Correlation of chronic obstructive pulmonary disease assessment test and clinical chronic obstructive pulmonary disease questionnaire score with BODE index in patients of stable chronic obstructive pulmonary disease / S. Singh, M. K. Daga, H. S. Hira, L. Kumar, G. Mawari // *Lung. India*. 2018. N 35(6). P. 494–498. https://doi.org/10.4103/lungindia.lungindia_93_18.

20. Synergistic effects of virtual reality and traditional treatment methods in the management of chronic obstructive pulmonary disease: a systematic review and meta-analysis of randomized controlled trials / W. Qi, F. Song, M. Li [et al.] // *PeerJ*. 2025. N 13. P. e20047. <https://doi.org/10.7717/peerj.20047>.

References

1. Alghamdi S.M. Content, Mechanism, and Outcome of Effective Telehealth Solutions for Management of Chronic Obstructive Pulmonary Diseases: A Narrative Review. *Healthcare*. 2023;(11):3164. <https://doi.org/10.3390/healthcare11243164>.

2. Pozza M., Navarin N., Sakkalis V., Gabrielli S. Artificial Intelligence Methods and Digital Intervention Strategies for Predicting and Managing Chronic Obstructive Pulmonary Disease Exacerbations: An Umbrella Review. *Healthcare*. 2025;(13):3037. <https://doi.org/10.3390/healthcare13233037>.

3. Ruan H., Zhang H., Wang J., Zhao H., Han W., Li J. Readmission rate for acute exacerbation of chronic obstructive pulmonary disease: a systematic review and meta-analysis. *Respir. Med.* 2023;(206):107090. <https://doi.org/10.1016/j.rmed.2022.107090>.

4. Shvan L.Yu., Gubareva I.V., Fatenkov O.V., Gubareva E.Yu., Fatenkov D.O. Telemedicine in pulmonology: achievements and prospects. *Ul'yanovskii mediko-biologicheskii zhurnal = Ulyanovsk Me-Wild-Biological Journal*. 2024;(4):6-24. (In Russ.) <https://doi.org/10.34014/2227-1848-2024-4-6-24>.

5. Prawesti G.N., Lo P., Sarasmita M.A., Chen H.Y. Effectiveness of Mobile Health-Based Self-Management Programs on Health-Related Outcomes in Patients With Chronic Obstructive Pulmonary Disease: Systematic Review and Meta-Analysis. *JMIR Mhealth Uhealth*. 2025;(13):e74967. <https://doi.org/10.2196/74967>.

6. Kaur A., Goyal A., Pandhi N. To Study the Correlation of Chronic Obstructive Pulmonary Disease (COPD) Assessment Test, Clinical COPD Questionnaire, and BODE Index in Patients of Stable COPD. *Assam. J. Intern. Med.* 2022;(12):18-23. https://doi.org/10.4103/ajom.ajom_21_21.

7. Ait Abdelouahid R., Debauche O., Mahmoudi S., Marzak A. Literature Review: Clinical Data Interoperability Models. *Information*. 2023;(14):364. <https://doi.org/10.3390/info14070364>.

8. Zhou Z., Cheng W., Liu C., et al. Predictive Value of CCQ and its Subdomains for Hospitalized Exacerbations in Chronic Obstructive Pulmonary Disease: A 3-Year Observa-

tional Prospective Study. *J. Gen. Intern. Med.* 2025;(40):1550-1558. <https://doi.org/10.1007/s11606-024-09067-0>.

9. Zhou Z., Cheng W., Liu C., et al. Predictive Value of CCQ and its Subdomains for Hospitalized Exacerbations in Chronic Obstructive Pulmonary Disease: A 3-Year Observational Prospective Study. *J. Gen. Intern. Med.* 2025;(40):1550-1558. <https://doi.org/10.1007/s11606-024-09067-0>.

10. Ali S.A., Saniya H., Naseeruddin K., et al. Psychometric Analysis of Clinical Chronic Obstructive Pulmonary Disease Questionnaire and Chronic Obstructive Pulmonary Disease Assessment Test and Its Correlation with St. George Respiratory Questionnaire in Chronic Obstructive Pulmonary Disease Patients. *Indian. J. Respir. Care.* 2022;(11):224-229. https://doi.org/10.4103/ijrc.ijrc_89_22.

11. Gupta N., Pinto L.M., Morogan A., Bourbeau J. The COPD assessment test: a systematic review. *Eur. Respir. J.* 2014;(44):873-884. <https://doi.org/10.1183/09031936.00025214>.

12. Nizov A.A., Ermachkova A.N., Abrosimov V.N., Ponomareva I.B. Comprehensive assessment of the severity of COPD at an outpatient clinic. *Rossiiskii mediko-biologicheskii vestnik imeni akademika I. P. Pavlova = Russian Medical and Biological Bulletin named after Academician I.P. Pavlov.* 2019;27(1):59-65. (In Russ.) <https://doi.org/10.23888/PAVLOVJ201927159-65>.

13. Verburg A.C., van Dulmen S.A., Kiers H., Ypinga J.H., Nijhuis-van der Sanden M.W., van der Wees P.J. Development of a Standard Set of Outcome Domains and Proposed Measures for Chronic Obstructive Pulmonary Disease in Primary Care Physical Therapy Practice in the Netherlands: a Modified RAND/UCLA Appropriateness Method. *Int. J. Chron. Obstruct. Pulmon. Dis.* 2019;(14):2649-2661. <https://doi.org/10.2147/COPD.S219851>.

14. Naranjo-Rojas A., Perula-de Torres L.Á., Cruz-Mosquera F.E., Molina-Recio G. Efficacy and Acceptability of a Mobile App for Monitoring the Clinical Status of Patients With Chronic Obstructive Pulmonary Disease Receiving Home Oxygen Therapy: Randomized Controlled Trial. *J. Med. Internet. Res.* 2025;(27):e65888. <https://doi.org/10.2196/65888>.

15. Ndlovu K., Scott R.E., Mars M. Interoperability opportunities and challenges in linking mhealth applications and eRecord systems: Botswana as an exemplar. *BMC Med. Inform. Decis. Mak.* 2021;(21):246. <https://doi.org/10.1186/s12911-021-01606-7>.

16. Mbanugo O.J. The new normal-chronic disease management and digital healthcare practice in rural and low internet environments. *GSC Biological and Pharmaceutical Sciences.* 2020;(13):279-300. <https://doi.org/10.30574/gscbps.2020.13.1.0315>.

17. Jo Y.S., Park S., Kim D.K., et. al. The cutoff point of clinical chronic obstructive pulmonary disease questionnaire for more symptomatic patients. *BMC Pulm. Med.* 2018;(18):38. <https://doi.org/10.1186/s12890-018-0601-0>.

18. Kulik E.G., Pavlenko V.I., Naryshkina S.V., Goncharova O.M. Quality of life of patients with chronic obstructive pulmonary disease with various risks of exacerbations. *Byulleten' fiziologii i patologii dykhaniya = Bulletin of Physiology and Respiratory Pathology*. 2020;(75):47-52. (In Russ.) [https://doi.org/ 10.36604/1998-5029-2020-75-47-52](https://doi.org/10.36604/1998-5029-2020-75-47-52).
19. Singh S., Daga M.K., Hira H.S., Kumar L., Mawari G. Correlation of chronic obstructive pulmonary disease assessment test and clinical chronic obstructive pulmonary disease questionnaire score with BODE index in patients of stable chronic obstructive pulmonary disease. *Lung. India*. 2018;(35):494-498. https://doi.org/10.4103/lungindia.lungindia_93_18.
20. Qi W., Song F., Li M., et al. Synergistic effects of virtual reality and traditional treatment methods in the management of chronic obstructive pulmonary disease: a systematic review and meta-analysis of randomized controlled trials. *PeerJ*. 2025;(13):e20047. <https://doi.org/10.7717/peerj.20047>.

Информация об авторах / Information about the Authors

Трусов Юрий Александрович, врач-кардиолог-клиник, ассистент кафедры пропедевтической терапии с курсом кардиологии, Самарский государственный медицинский университет Министерства здравоохранения Российской Федерации, г. Самара, Российская Федерация, e-mail: yu.a.trusov@samsmu.ru, ORCID: 0000-0001-6407-3880

Yury A. Trusov, Cardiologist at the Clinics, Assistant at the Department of Propedeutic Therapy with a Course in Cardiology, Samara State Medical University of the Ministry of Health of the Russian Federation, Samara, Russian Federation, e-mail: yu.a.trusov@samsmu.ru, ORCID: 0000-0001-6407-3880

Гаранин Андрей Александрович, кандидат медицинских наук, доцент, директор научно-практического центра дистанционной медицины, Самарский государственный медицинский университет Министерства здравоохранения Российской Федерации, г. Самара, Российская Федерация, e-mail: a.a.garanin@samsmu.ru, ORCID: 0000-0001-6665-1533

Andrey A. Garanin, Cand. Sci. (Medical), Associate Professor, Director of the Scientific and Practical Center for Distance Medicine, Samara State Medical University of the Ministry of Health of the Russian Federation, Samara, Russian Federation, e-mail: a.a.garanin@samsmu.ru, ORCID: 0000-0001-6665-1533

<https://doi.org/10.21869/2223-1536-2026-16-2-54-75>



УДК 004.42, 004.75

Биотехническая система управления реабилитацией верхних конечностей на основе мониторинга косвенного критерия биотехнического резонанса

Е. В. Петрунина¹, Д. А. Ермаков², М. К. Скворцов²,
В. Э. Дрейзин², С. А. Филист², О. В. Шаталова² ✉

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

² Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: Shatolg@mail.ru

Резюме

Целью исследования является повышение эффективности реабилитации двигательных функций верхних конечностей посредством синхронизации реальной и воображаемой двигательной активности и сервоприводов узлов и механизмов, осуществляющих техническую поддержку реабилитационного процесса.

Методы. Разработан прототип биотехнической системы для управления реабилитацией нарушений двигательных функций верхних конечностей, отличающийся включением в прямую цепь контура управления модулей анализа электроэнцефалограммы, электромиограммы и показаний динамометра, а в цепь биологической обратной связи – модуля управления виртуальной реальностью, позволяющий адаптировать локальные параметры процедуры реабилитации под текущее функциональное состояние пациента. Разработан алгоритм управления процедурой реабилитации верхних конечностей, отличающийся мониторингом косвенного критерия биотехнического резонанса посредством анализа расстояний в кластерном пространстве, построенном в координатах показаний динамометра и мышечной усталости, позволяющий управлять глобальными параметрами процедуры реабилитации с дискретностью равной одному пачу.

Результаты. Проведены экспериментальные исследования биотехнической системы при мониторинге косвенного критерия биотехнического резонанса, которые показали, что полученные при мониторинге биотехнического резонанса результаты превосходят результаты реабилитации известным методом: на шкале MBI – на 6%, на шкале MFT – на 20%, на шкале мышечной силы – на 13%, на шкале ARAT – на 23%, на шкале FMA – на 12% и на шкале Эшворта – на 13%.

Заключение. В данной статье представлено решение задачи синхронизации двигательной активности верхних конечностей человека и ассистирующих робототехнических устройств. Результаты исследования могут быть использованы для построения биотехнических систем реабилитации нарушений двигательной активности с управлением процедурой реабилитации посредством мониторинга биотехнического резонанса.

Ключевые слова: биотехническая система; реабилитация постинсультных больных; электроэнцефалограмма; электромиограмма; воображаемые движения; алгоритм; косвенный критерий биотехнического резонанса.

Финансирование: Работа выполнена в рамках реализации программы развития ФГБОУ ВО «Юго-Западный государственный университет» программы стратегического академического лидерства «Приоритет-2030».

Конфликт интересов: Филист А. Б. является членом редакционной коллегии журнала «Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение» с 2015 г., но не имеет никакого отношения к решению опубликовать эту статью. Шаталова О. В. является членом редакционной коллегии журнала «Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение» с 2022 г., но не имеет никакого отношения к решению опубликовать эту статью. Статья прошла принятую в журнале процедуру рецензирования. Об иных конфликтах интересов авторы не заявляют.

Для цитирования: Биотехническая система управления реабилитацией верхних конечностей на основе мониторинга косвенного критерия биотехнического резонанса / Е. В. Петрунина, Д. А. Ермаков, М. К. Скворцов, В. Э. Дрейзин, С. А. Филист, О. В. Шаталова // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 54–75. <https://doi.org/10.21869/2223-1536-2025-15-4-54-75>.

Поступила в редакцию 07.04.2026

Подписана в печать 06.05.2026

Опубликована 30.06.2026

Biotechnical system for managing upper limb rehabilitation based on monitoring an indirect criterion of biotechnical resonance

Elena V. Petrunina¹, Dmitriy A. Ermakov², Mihail K. Skvortsov²,
Valery E. Drejzin², Sergey A. Filist², Olga V. Shatalova² ✉

¹ Moscow Polytechnic University
38 Bolshaya Semenovskaya Str., Moscow 107023, Russian Federation

² Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: Shatolg@mail.ru

Abstract

The purpose of the research is to improve the effectiveness of upper limb motor function rehabilitation by synchronizing real and imagined motor activity with the servo drives of the units and mechanisms that provide technical support for the rehabilitation process.

Methods. A prototype biotechnical system for managing the rehabilitation of upper limb motor function disorders was developed. This system incorporates EEG, EMG, and dynamometer analysis modules into the control loop's forward loop, and a virtual reality control module into the biofeedback loop, enabling adaptation of local rehabilitation procedure parameters to the patient's current functional state. An algorithm for controlling upper limb rehabilitation was developed, featuring monitoring of an indirect biotechnical resonance criterion through distance analysis in a cluster space constructed using dynamometer readings and muscle fatigue coordinates, enabling global rehabilitation procedure parameters to be controlled with a granularity of one patch.

Results. Experimental studies of a biotechnical system monitoring the indirect criterion of biotechnical resonance were conducted. These studies demonstrated that the results obtained through biotechnical resonance monitoring exceed those of the established rehabilitation method by 6% on the MBI scale, 20% on the MFT scale, 13% on the muscle strength scale, 23% on the ARAT scale, 12% on the FMA scale, and 13% on the Ashworth scale.

Conclusion. This article presents a solution to the problem of synchronizing the motor activity of human upper limbs and assistive robotic devices. The results of the study can be used to develop biotechnical rehabilitation systems for motor disorders with rehabilitation procedure control through biotechnical resonance monitoring.

Keywords: biotechnical system; rehabilitation of post-stroke patients; electroencephalogram; electromyogram; motor imagery; algorithm; indirect biotechnical resonance criterion.

Funding: The work was carried out within the framework of the development program of the Federal State Budgetary Educational Institution of Higher Education "Southwest State University" of the strategic academic leadership program "Priority – 2030."

Conflict of interest: Filist A. B. is a member of the editorial board of the journal "Series: Management, computing, computer science. Medical instrumentation" since 2015, but has nothing to do with the decision to publish this article. Shatalova O. V. is a member of the editorial board of the journal "Series: Management, Computer Engineering, Computer Science. Medical device-structure" since 2022, but has nothing to do with the decision to publish this article. The article passed the peer review procedure adopted in the journal. The authors are not for other conflicts of interest.

For citation: Petrunina E.V., Ermakov D.A., Skvortsov M.K., Drejzin V.E., Filist S.A., Shatalova O.V. Biotechnical system for managing upper limb rehabilitation based on monitoring an indirect criterion of biotechnical resonance. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika.*

Введение

Нейромышечная связь — это способность мозга эффективно посылать сигналы мышцам, чтобы они сокращались нужным образом. Она позволяет человеку управлять движениями, чувствовать тело и выполнять даже самые сложные действия. Это постоянный «диалог»: мозг управляет телом, а тело в ответ сообщает, как выполняется команда. Развивая эту связь, можно точнее включать нужные мышцы, получать более высокие результаты и снижать риск травм.

При реабилитации постинсультных больных с нарушениями двигательной активности (ДА) требуется восстановить нейромышечные связи. С этой целью во многих медицинских системах реабилитации используют виртуальную реальность (VR). Но для VR, кроме биотехнических обратных связей (БТОС), необходима биологическая обратная связь (БОС), которая позволяет пациенту контролировать свой результат выполнения задания. С учётом того, что при необходимости возможна помощь при выполнении задания со стороны, например, экзоскелета, на термине БОС возможны завышенные результаты, которые играют роль дополнительной стимуляции достижения биотехнического резонанса.

На сегодняшний день опубликовано значительное количество клинических исследований, подтверждающих эффективность использования интерфейса мозг-компьютер (ИМК) для вос-

становления двигательной функции верхней конечности у пациентов с инсультом. Например, метаанализ 21 рандомизированного контролируемого исследования (общее число участников 650 человек) был проведен Chen и Yun [1]. Авторы исследования провели всесторонний поиск в 6 электронных базах данных с момента их создания до 16 октября 2025 г., включая PubMed (через Национальную медицинскую библиотеку), Embase (через Ovid), Центральный регистр контролируемых исследований Кокрейна (через Wiley), Scopus (через Elsevier), Web of Science Core Collection (через Clarivate Analytics) и Wanfang Data. Эти платформы были выбраны для обеспечения широкого охвата международной литературы. Поиск во всех базах данных проводился индивидуально; поиск по нескольким базам данных на одной платформе не выполнялся.

Критерии включения исследования в метаанализ были следующими:

- 1) популяция: взрослые (>18 лет) с диагнозом хронического инсульта (>6 месяцев после инсульта), демонстрирующие стабильные жизненные показатели и бодрствующее сознание;
- 2) вмешательство: получение любой формы тренировки на основе ИМК;
- 3) контрольная группа: получение либо плацебо-интервенции с использованием ИМК, либо традиционной реабилитационной терапии (например, физиотерапия, трудотерапия и тренировка на беговой дорожке);

4) результаты: оценка с использованием шкалы Фугл-Мейера для оценки состояния верхних конечностей (FMA-UE), теста Action Research Arm Test (ARAT), модифицированной шкалы Эшворта (MAS), модифицированного индекса Бартеля (MBI) и журнала двигательной активности (MAL);

5) дизайн исследования: рандомизированные контролируемые исследования (РКИ).

Метаанализ показал следующие результаты:

- улучшение моторной функции (по шкале FMA-UE): средняя разница составила 2,50 балла по сравнению с контрольными группами, при использовании подтипа ИМК с функциональной электростимуляцией (ФЭС) улучшение достигало 5 баллов;

- улучшение активности в повседневной жизни (по шкале MBI): средняя разница 8,38 балла.

Анализ подгрупп показал, что ФЭС в сочетании с ИМК привела к наибольшему улучшению восстановления двигательных функций (по шкале FMA-UE: средняя разница 5).

Эффект на мышечный тонус и мелкую моторику (по шкале ARAT) не достиг статистической значимости.

Согласно данному метаанализу, оптимальный протокол тренировки составил 30-минутные сессии 4-5 раз в неделю в течение 2 недель (всего 10-12 занятий).

В исследовании Sieghartsleitner и соавторов [2] с участием 19 пациентов с хроническим инсультом было показано улучшение по шкале FMA-UE в среднем на 4,2 балла после 25 сессий ИМК-тренинга.

Пациенты проходили тренировку с использованием системы ИМК на основе мысленного представления информации (MI), реалистичного 3D-аватара для визуальной обратной связи и ФЭС (рис. 1). Во время терапии пациенты носили беспроводные ЭЭГ-шапочки, соответствующие размеру их головы, с 16 активными электродами, охватывающими сенсомоторную кору. Референтный электрод был установлен на правой мочке уха, а заземляющий электрод – в зоне AFz.




Рис. 1. Схема системы интерфейса мозг-компьютер, используемой для лечения конечностей, включая оператора и пациента, используемая в исследовании [2]

Fig. 1. Schematic diagram of the brain-computer interface system used for limb treatment, including operator and patient, used in the study [2]

Во время терапии верхних конечностей пациенты сидели на стуле перед экраном компьютера, опираясь обеими предплечьями на стол, а пары поверхностных электродов ФЭС были прикреплены к разгибателям левого и правого запястья.

Другой метаанализ был проведен Ali и соавторами [3]. В это исследование было включено 17 работ, оценивающих эффективность реабилитации на основе ИМК в отношении восстановления двигательных функций верхних конечностей, измеренных с помощью шкалы оценки верхних конечностей FMA-UE. Метаанализ с использованием модели случайных эффектов показал объединенную среднюю разницу в 3,26 балла, что указывает на статистически значимое улучшение двигательной функции у пациентов, получающих вмешательства на основе ИМК, по сравнению с контрольной группой. Тест на общий эффект подтвердил надежность этого результата. Эти результаты показывают, что вмешательства с использованием ИМК приводят к клинически значимым улучшениям в восстановлении двигательных функций, с размерами эффекта, превышающими минимально клинически значимую разницу для FMA-UE в реабилитации после инсульта. В этом исследовании как рандомизированные контролируемые исследования, так и исследования осуществимости на отдельных субъектах внесли свой вклад в объединенную оценку, подчеркивая надежность систем ИМК в гетерогенных популяциях, включая ишемический инсульт, хронический гемипарез и травму спинного мозга.

Следующее рассматриваемое исследование – это работа ReHand-BCI [4]. Система ReHand-BCI состояла из этапов сбора данных, обработки дан-

ных, обратной связи и компьютерного монитора для предоставления инструкций пациенту. На этапе сбора данных 16 активных электродов, расположенных в позициях F3, FC3, C5, C3, C1, CP3, P3, FCz, Cz, F4, FC4, C6, C4, C2, CP4 и P4 системы 10–10, были закреплены на шапочке для записи ЭЭГ. Референтный электрод был размещен в правой мочке уха, а заземляющий электрод – в позиции AFz. Усилитель регистрировал ЭЭГ с частотой 256 Гц и 24-битным разрешением АЦП. Этап обработки данных работал в двух режимах: калибровочном (офлайн) и терапевтическом (онлайн). В режиме калибровки использовались предварительно записанные данные ЭЭГ с предыдущего сеанса терапии, за исключением первого сеанса терапии, для которого использовалась запись базового уровня ЭЭГ.

Предварительно записанные данные ЭЭГ были отфильтрованы полосовым фильтром с помощью банка фильтров и режекторным фильтром на частоте 60 Гц с использованием КИХ-фильтров 30-го порядка. Затем были извлечены признаки логарифмической дисперсии с помощью алгоритма Common Spatial Patterns (CSP) с использованием 1-секундных окон из каждого канала. После этого соответствующие извлеченные признаки CSP были выбраны с помощью оптимизации роя частиц (PSO) и использованы для обучения классификатора линейного дискриминантного анализа (LDA). С помощью выбранных для каждого пациента частотных диапазонов, вычисленных пространственных фильтров и коэффициентов LDA, полученных в режиме калибровки, режим терапии мог классифицировать 1-секундные окна, полученные в режиме онлайн, как двигательную активность руки либо период покоя с открытыми глазами (покой).

Этап обработки был реализован на рабочей станции Precision 5820 через графический пользовательский интерфейс, запрограммированный на MATLAB. Этап обратной связи включал в себя роботизированный ортез для руки, подключенный через Bluetooth к этапу обработки, который обеспечивал пассивное сгибание или разгибание пальцев парализованной руки пациентов. Ортез активировался двигательной активностью руки пациентов в экспериментальной группе и случайным образом активировался для пациентов в контрольной группе. Предварительная версия ReHand-BCI была оценена в пилотном исследовании с участием пациентов, перенесших инсульт, а этап обратной связи системы был протестирован на здоровой популяции перед использованием в исследовании.

Каждый пациент прошел 30 запланированных сеансов терапии с использованием ИМК или плацебо-ИМК в зависимости от назначенной группы. Пять сеансов проводились в неделю в течение 6 недель. В каждом сеансе терапии пациенты выполняли 80 попыток, разделенных на 4 серии по 20 попыток в каждой. Пациентам разрешалось отдыхать не менее 1 минуты между сериями. Сеансы терапии с использованием ИМК и плацебо-ИМК проводились в одной и той же звукоизолированной комнате и одной и той же группой исследователей для каждого пациента. Во время терапии пациенты сидели в удобном кресле. Система ReHand-BCI была настроена таким образом, что роботизированный ортез был закреплен на парализованной руке пациента, а шапочка для ЭЭГ была надета на голову пациента. Компьютерный монитор ReHand-BCI располагался перед пациентами на расстоянии примерно 1,5 м, а бейсбольный мяч находился под парализованной

рукой пациента, закрепленный на одном из подлокотников кресла. На каждом сеансе пациентам предлагалось выполнить ряд заданий, составляющих пробный этап, в соответствии с визуальными и звуковыми подсказками, отображаемыми на мониторе. Сначала на мониторе появлялся белый крест, который отображался в течение 4 секунд; в это время пациентам было предписано наблюдать за белым крестом, не выполняя никакой другой физической или умственной деятельности, включая период отдыха. Через три секунды после начала проб из динамиков монитора раздавался звуковой сигнал, предупреждающий пациента о предстоящем задании на МИ. Через четыре секунды после начала пробы на мониторе появлялась белая стрелка, указывающая на парализованную руку пациента, что означало начало МИ парализованной руки. Стрелка отображалась на мониторе в течение 1,5 секунды, а затем исчезала, оставляя черный экран еще на 3,5 секунды.

Пациентам было предложено попытаться удерживать бейсбольный мяч под парализованной рукой в течение 1,5 секунды появления стрелки и 3,5 секунды черного экрана, что соответствовало периоду минимального индуцированного движения (МИ). В экспериментальной группе в течение периода МИ ортез обеспечивал пассивное сгибание пальцев на 25% от их максимального смещения (приблизительно 1,38 см) всякий раз, когда система классифицировала как МИ в одном из четырех 1-секундных окон, составляющих первые 4 секунды периода МИ. Таким образом, за одно испытание можно было вызвать максимум четыре сгибания. В контрольной группе движение ортеза не зависело от распознавания системой МИ руки и обеспечивалось случайным образом в соответствии со случайным распределе-

нием, которое варьировалось от 55 до 85% вероятности активации ортеза в период МИ, причем эта вероятность менялась в каждом сеансе. Эта вероятность была рассчитана на основе диапазона наблюдаемых показателей работы ИМК, достигнутых в ходе предварительного исследования у участников, перенесших инсульт. После периода МИ монитор становился серым, и если участник выполнял сгибание пальцев в течение этого периода, ортез выполнял движение разгибания пальцев, при этом пациентам предлагалось попытаться открыть и расслабить парализованные руки. Этот

период длился с 9-й по 14-ю секунду испытания. Наконец, через 14 секунд после начала испытания монитор становился синим, и пациентам разрешалось двигаться, моргать и расслабляться [5]. Синий экран на мониторе случайным образом появлялся на 4-6 секунде, чтобы предотвратить привыкание. В конце каждого сеанса пациенту показывалось лицо разных цветов и с улыбающимися выражениями, указывающее на степень успеха в управлении ортезом во время сеанса [6]. На рисунке 2 показана временная структура испытаний, полученных в ходе терапии.




Рис. 2. Структура исследования для вмешательства с использованием ИМК и плацебо-ИМК в исследовании [6]

Fig. 2. Study design for the BCI and placebo-BCI intervention in the study [6]

В итоге экспериментальная группа (ИМК + роботизированный ортез) показала статистически значимое улучшение по шкале ARAT (медиана с 8,5 до 20 баллов), в то время как в контрольной группе (имитация ИМК) достоверных изменений по данной шкале не наблюдалось.

Учитывая вышесказанное, необходим критерий, обеспечивающий оценку нейромышечной связи. В качестве такого критерия используем показатель

биотехнического резонанса (БТР), который показывает, как изменяется нейромышечная связь в результате эндогенных и экзогенных воздействий на пациента, осуществляемых во время сеанса реабилитации. Основная задача БТР – обеспечить объективный критерий повышения качества нейромышечной связи. В качестве такого критерия будем использовать два показателя: прямой и косвенный показатели БТР. Для их обоснования рассмотрим меха-

низм использования VR в ходе реабилитационной процедуры.

Рассмотрим схему процесса реабилитации (рис. 3). Вначале определяем базовый уровень пациента. Пациент прикладывает максимальное усилие к динамометру, при этом фиксируется пиковое показание динамометра и од-

новременно записываются ЭЭГ и ЭМГ. По результатам показаний, полученных в этом режиме, составляется план процедуры реабилитации, которая состоит из выполнения движений, выводимых на терминал VR в виде клипов, и периода отдыха, который также представлен в сцене VR.



Рис. 3. Схема процедуры реабилитации

Fig. 3. Rehabilitation procedure diagram

По анализу показаний в базовом уровне задается цель. Цель – это показание динамометра в конце процедуры. В начале процедуры считывается начальное показание динамометра, по показанию электромиограммы оценивается тонус мышц-сгибателей, задаются показания динамометра в конце процедуры или на определенном этапе, а также соответствующий темп сжимания кисти с соответствующими периодами отдыха. Цель высвечивается на терминале VR. На терминале VR также высвечивается текущее достижение пациента. Причем это достижение может не соответствовать действительности. Снижение или повышение текущего результата по сравнению с реальным можно использовать в качестве дополнительного стимула достижения цели.

Таким образом, косвенным критерием БТР является увеличение показаний динамометра по сравнению с исходными показаниями, а также стабилизация результата при снижении асси-

стирующего момента на серводвигателях экзоскелета. Прямой критерий БТР в данной работе не рассматривается.

Материалы и методы

В процессе исследования создан прототип БТС со стимулами, возбуждаемыми посредством программируемой VR¹. Структурная схема БТС представлена ниже (рис. 4). Стимулирующая VR

¹ Патент 2766764 Российская Федерация, МПК А 61 В 5/313 (2021.01), А 61 В 5/389 (2021.01), А 61 F 4/00 (2006.01). Способ оценки мышечной усталости на основе контроля паттернов синергии и устройство для его осуществления / Филист С. А., Трифонов А. А., Кузьмин А. А., Сафронов Р. И. Петрунина Е. В.; заявитель и патентообладатель Федеральное государственное бюджетное образовательное учреждение высшего образования «Юго-Западный государственный университет» (ЮЗГУ). № 2021105609; заявл. 04.03.21; опубл. 15.03.22, Бюл. № 8. 17 с. : ил.

возбуждает моторные нейроны, которые, в свою очередь, стимулируют потенциалы двигательных единиц (ДЕ) мышц, адаптируемых к данной VR [7]. В структуре БТС выделим блок формирования VR, каналы формирования ЭЭГ, ЭМГ и динамометра, которые дешифрируются в блоке управления (контроллере)¹.

При обеспечении БТР в процессе реабилитации ДФ верхних конечностей полагаем, что имеем возможность контролировать ЭЭГ, ЭМГ и показания динамометра. Для оценки косвенного критерия БТР будем использовать соотношение между показателем усталости мышц-сгибателей и достижения цели, т. е. показаний динамометра, выводимых на терминал VR в качестве цели. Полагаем, что процесс реабилитации реализуется в виде пачей (см. рис. 3). Для определения мышечной усталости (МУ) используют ЭМС. Дискретизированный ЭМС сегментируют на основе пороговой обработки и формируют временную последовательность сегментов ЭМС².

¹ Патент 2830938 Российская Федерация, МПК G 16 Н 20/00 (2018.01), А 61 В 5/05 (2006.01), G 06 Т 15/00 (2011.01). Способ реабилитации пациентов с нарушением двигательной активности с использованием персонализированного контента клипов виртуальной 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. 14 с.: ил.

² Патент 2766764 Российская Федерация, МПК А 61 В 5/313 (2021.01), А 61 В 5/389 (2021.01), А 61 F 4/00 (2006.01). Способ оценки мышечной усталости на основе контроля

Так как у постинсультных больных ЭМС достаточно мал, то вместо него используем сигнал RMS , определяемый по формуле

$$RMS_m = \sqrt{\frac{1}{n} \sum_{k=m-n}^m \text{ЭМС}_k^2}, \quad (1)$$

где n – число дискретных отсчетов ЭМС_k , которые накапливаются в памяти персонального компьютера до текущего отсчета m .

В процессе мониторинга МУ последовательно, в порядке поступления, определяют вейвлет-преобразование каждого сегмента для последующего исследования их энергетической эволюции и построения дескрипторов для классификатора МУ [8]. На основе ее анализа формируют два вектора дескрипторов³, первый из которых определяется путем вычисления общей энтропии вейвлетов в строках (масштабах) вейвлет-плоскости, а второй определяется путем вычисления общей энтропии вейвлетов в столбцах вейвлет-плоскости, при этом во вто-

паттернов синергии и устройство для его осуществления / Филист С. А., Трифонов А. А., Кузьмин А. А., Сафронов Р. И., Петрунина Е. В.; заявитель и патентообладатель Федеральное государственное бюджетное образовательное учреждение высшего образования «Юго-Западный государственный университет» (ЮЗГУ). № 2021105609; заявл. 04.03.21; опубл. 15.03.22, Бюл. № 8. 17 с.: ил.

³ Патент 2839398 Российская Федерация, МПК А 61 В 5/00 (2006.01). Способ классификации мышечной усталости на основе анализа вейвлет-преобразования сегментов двигательной активности электромиосигнала / Филист С. А., Пшеничный А. Е., Петрунина Е. В., Кузьмин А. А., Ермаков Д. А.; заявитель и патентообладатель Федеральное государственное бюджетное образовательное учреждение высшего образования «Юго-Западный государственный университет» (ЮЗГУ). № 2024131858; заявл. 23.10.24; опубл. 30.04.25, Бюл. № 13. 27 с.: ил.

рой вектор дескрипторов включают только компоненты, которые превышают пороговое значение. Пороговое значение установлено таким образом, что-

бы оно принимало максимальное значение порога, не приводящее к пропуску индексов внутри оставшейся последовательности компонентов вектора [8].




Рис. 4. Структурная схема прототипа биотехнической системы

Fig. 4. Structural diagram of the prototype biotechnical system

Для определения косвенного критерия синхронизации построим кластерное пространство в координатах показаний динамометра F и МУ. МУ измеряется в процентах, т. е. её шкалу можно привести к диапазону $(0, 1)$. Шкалу динамометра можем также привести к диапазону $(0, 1)$, нормируя его показания на целевое показание $F_{ц}$. В таком случае получаем двумерное кластерное пространство в квадранте с координатами диагонали $(0,0); (1,1)$ (рис. 5).

Учитывая, что координаты цели при реабилитации пациента должны стремиться от точки $(1,0)$ к точке $(0,1)$, эффективность реабилитации в контрольной точке (КТ) можно оценить по изменению текущего состояния пациен-

та до точек с координатами $(0,1)$ и с координатами $(1,0)$. Таким образом, условие биотехнического резонанса, согласно косвенному критерию, примет вид

$$K_K = \sum_{k=1}^K \text{sign}(K_k) > 0, \quad (2)$$

где K – число КТ в паче.

$$K_k = \sqrt{(1 - y_{2k})^2 + y_{1k}^2} - \sqrt{(y_{2k}^2 + (1 - y_{1k})^2)}. \quad (3)$$

Если не взвешивать параметры y_1 и y_2 , то эффективность реабилитации оценивают по координате пациента в пространстве этих признаков. На рисунке 5 в качестве примера представлены образы функционального состояния (ФС) одного и того же пациента в этом кластерном пространстве в КТ $k-1$ и k .




Рис. 5. Двумерное кластерное пространство для оценки динамики реабилитации пациента по косвенному критерию биотехнического резонанса

Fig. 5. Two-dimensional cluster space for assessing the dynamics of patient rehabilitation using the indirect criterion of biotechnical resonance

Многократное определение расстояния диагностируемой точки от точек, соответствующих центрам кластеров, используем для оценки эффективности проводимой реабилитации. Движение точки в сторону точки $(0,1)$ говорит об эффективности реабилитации, и наоборот. Различным глобальным параметрам реабилитации будут соответствовать и различные скорости движения точки к цели. Задавшись КТ, вычисляем «траекторию» ФС пациента в кластерном пространстве по отношению к процессу восстановления двигательных функций паретичных конечностей [9]. Из (2) следует, что для поддержки БТР согласно косвенному критерию необходимо удерживать текущую координату КТ выше диагонали с координатами $(0,0)$; $(1,1)$. Так как в течение процедуры реабилитации МУ растет, сила сжатия пружины динамометра снижается, т. е. точка (y_1, y_2) движется в сторону кластера $(1,0)$, необходимы средства для воз-

вращение её в область БТР. В БТС имеется две такие возможности. Первая возможность – включение ассистирующей поддержки от экзоскелета при его наличии. Эта поддержка приведет не только к изменению ординаты КТ, но и уменьшит её абсциссу. Вторая возможность поддержки БТР заключается в изменении глобальных параметров VR.

Рассмотрим схему алгоритма, обеспечивающего БТР на основе косвенного критерия (рис. 6).

Для запуска процесса реабилитации необходимо задать глобальные параметры, к которым отнесем целевой показатель силы сжатия кисти $F_{ц}$, число КТ в паче K (блок 1) и число пачей N в процедуре реабилитации. В блоке 2 устанавливается счётчик пачей. В блоке 3 задаются глобальные параметры VR. Часть этих параметров относятся к формирователю стимулов: время сжатия кулака T_1 , время релаксации T_2 , число тестовых движений K в паче.




Рис. 6. Схема алгоритма управления реабилитацией посредством косвенного критерия биотехнического резонанса

Fig. 6. Diagram of the algorithm for managing rehabilitation using an indirect criterion of biotechnical resonance

Цикл, организованный посредством блоков 4–10, осуществляет вычисление косвенного критерия БТР согласно (2). В блоке 4 задаются исходные параметры цикла, в блоке 5 реализуется задержка между снятиями показателей в двух смежных КТ. В блоке 7 снимаются показания ЭМГ, по которым вычисляется МУ (y_1) и y_2 – показания динамометра, и вычисляется показатель [формула (3)], указывающий, лежит ли текущая координата КТ выше или ниже диагонали, разделяющей кластеры ФС. В блоке 8 вычисляется косвенный критерий БТР в КТ. В блоке 9 проверяется условие прохода всех КТ в паче.

В блоке 10 осуществляем переход на следующую КТ. По завершении цикла значение косвенного критерия БТР в паче заносится в память компьютера в блоке 11. В блоке 12 инкриминируется счетчик пачей. В блоке 13 проверяется условие завершения сеанса реабилитации. Если сеанс реабилитации не завершён, т. е. остались еще пачи, то в блоке 14 проверяется условие БТР по косвенному критерию в случае, если все КТ были пройдены (проверка в блоке 9).

Если условие БТР не выполнено, то осуществляется переход на блок 15, в котором имеются три варианта достижения БТР, в зависимости от того, какова была попытка его достичь в предшествующем паче. Если в предшествующем паче условие БТР было выполнено, то для достижения БТР в блоке 17 формируется ассистирующая поддержка посредством серводвигателей экзоскелета и осуществляется переход к следующему пачу. Ассистирующая поддержка F_A в k -й КТ вычисляется как

$$F_{Ak} = (MU_k - F_k) \cdot \varepsilon, \quad (4)$$

где $\varepsilon = 1 \dots 1,2$ – эмпирический коэффициент, предусматривающий учет снижения величины косвенного критерия БТР в следующем паче.

Если в предшествующей КТ ассистирующий фактор был уже использован, то переход осуществляется по ветви 2 на блок 18, который предусматривает коррекцию глобальных параметров VR, выражающихся в снижении частоты кадров клипа, иллюстрирующего процесс сжатия кисти. Если в предшествующей КТ параметры VR уже корректировались, то блок 15 осуществляет переход на блок 19, в котором предусмотрено как увеличение ассистирующей силы, так и снижение частоты кадров VR.

Результаты и их обсуждение

Объектом данного исследования стала экспериментальная группа в составе 42 пациентов с парезом верхней конечности и давностью заболевания от 3-х недель до 6 месяцев. Предмет исследования – двигательная функция верхней конечности пациентов, перенесших инсульт на фоне применения технологий VR с системой мониторинга косвенного критерия БТР.

Экспериментальные исследования проводились на базе клинического научно-медицинского центра «Авиценна» г. Курска с использованием роботизированной перчатки «Аника» и программного обеспечения, устанавливаемого на персональный компьютер. На рисунке 7 приведена фотография пациента в процессе реабилитации на этом роботизированном комплексе с прикрепленным к паретичной конечности роботизированным устройством.




Рис. 7. Реабилитационный комплекс с мониторингом косвенного критерия биотехнического резонанса

Fig. 7. Rehabilitation complex with monitoring of indirect criterion of biotechnical resonance

Критерии включения в экспериментальную группу:

- парез верхней конечности (лёгкой и средней степени) после ишемического или геморрагического инсульта;
- давность до 6 месяцев на момент включения;
- возраст 25–75 лет.

Критерии не включения:

- эпилепсия;
- эндогенные психические расстройства;
- декомпенсированные хронические заболевания;
- выраженное снижение слуха и зрения.

Критерии исключения:

- наличие выраженных двигательных, чувствительных и нейропсихологических (памяти, внимания, регуляции произвольной деятельности, апраксии, планирования, зрительного восприятия,

сенсорная афазия) нарушений, препятствующих взаимодействию с системой VR [10].

Критерии выбывания:

- повторный инсульт;
- обострение хронических заболеваний;
- инфекционные осложнения [10].

Из экспериментальной группы были выделены основная группа и группа сравнения (контрольная группа). Обе группы подбирались одинаковыми по демографическим показателям и по функциональному состоянию паретичных конечностей. В основной группе пациенты вводились в БТР посредством VR БТОС. У пациентов основной группы к паретичной руке прикреплялось роботизированная перчатка комплекса «Аника», а сила сжатия кулака контролировалась динамометром, подключённым к персональному компьютеру. Участникам было поручено двигать паретичной рукой в соответствии с целью, визуальной представленной на экране перед ними. Если пациент не мог выполнять движения сам, робот оказывал помощь и активно направлял руку пациента к цели. В контрольной группе пациенты получали занятия на роботизированном реабилитационном комплексе для функциональной терапии верхних конечностей «Аника» по стандартной программе реабилитации.

Программа реабилитации включала 12 сеансов в течение 4 недель. Всем пациентам в 1-е, 10-е, 20-е и 28-е сутки проводилась оценка ФС при помощи следующих шкал:

1. Оценка повседневной бытовой активности пациента проводилась по стобалльному индексу активности в повседневной жизни (индекс Бартеля) [11]. Модифицированный индекс Бар-

теля суммирует показатели по десяти областям повседневной деятельности (ADL) в баллы от 0 до 100, где более высокие баллы отражают большую независимость. К распространенным областям повседневной деятельности относятся: кормление, купание, уход за собой, одевание, контроль за кишечником (дефекация), контроль за мочевым пузырем (мочеиспускание), использование туалета, перемещение, мобильность, ходьба по лестнице. Опорные точки пунктов модифицированного индекса Бартеля описывают уровень необходимой помощи – от зависимого до независимого с использованием вспомогательных средств или без них, поэтому оценка отражает то, что человек фактически делает в повседневной жизни. Пороговые значения позволяют быстро оценить функциональную зависимость: 0–20 – полная зависимость; 21–60 – тяжелая зависимость; 61–90 – умеренная зависимость; 91–99 – легкая зависимость; 100 – независимость. Для более полной клинической картины следует сопоставить эти диапазоны с пояснительными записями о безопасности, поддержке со стороны лиц, осуществляющих уход, и потребностях в оборудовании.

2. Для оценки мышечной силы отдельных мышц и групп мышц использовалась шестибальная шкала оценки мышечной силы – от 5 до 0. Баллом 5 оценивается отсутствие пареза, парез оценивается как легкий при соответствии силы 4 баллам, умеренный – 3 баллам, выраженный – 2 баллам, грубый – 1 баллу и при параличе – 0 баллов [12].

3. Для оценки двигательной функции руки использовался тест ARAT [13]. При этом использовалась только

его восемнадцатибальная шкала «Шаровой захват», включающая шесть тестовых движений кистью, успешность выполнения каждого из которых оценивалось от нуля до трех баллов.

4. Для оценки функции пораженной руки использовали тест Френчай (MFT – Modified Frenchay Test) [14].

5. Для выявления и оценки спастичности использовалась модифицированная шкала Эшворта [13]. Максимальное количество баллов (4) соответствует значительному повышению мышечного тонуса. Отсутствие повышенного мышечного тонуса соответствует 0 баллов. Методика проведения оценки состоит в выполнении максимально возможного разгибания всех пальцев одновременно из позиции максимально возможного сгибания.

6. Оценка сенсомоторной функции по шкале Фугл-Майера для оценки верхней конечности (FMA-UE) [10].

Участникам эксперимента в основной группе было поручено сжимать динамометр паретичной рукой в соответствии с целью, визуально представленной на экране перед ними. Робототехническое устройство вмешивается в стимулированное движение пациента только тогда, когда пациент не может завершить желаемое движение [15]. Пациент инициирует движение самостоятельно, однако возможны неконтролируемые движения.

Если пациент не мог выполнять движения сам, экзоскелет оказывал помощь и активно сжимал кисть руку пациента, помогая ему достичь целевых показателей [16]. Чтобы обеспечить эффективность реабилитационных процедур, запуск пластических механизмов мозга [17] по перестройке сенсомоторной системы должен совершаться только в моменты, когда мозг наиболее восприимчив

к принятию периферийных сигналов, производимых движениями экзоскелета. Увеличение амплитуды RMS ЭМГ является запускающим сигналом для экзоскелета. Однако этот сигнал не может ис-

пользоваться у полностью парализованных больных [15].

Рассмотрим показатели клинической оценки в группах до и после реабилитации (табл. 1).

Таблица 1. Динамика показателей функционального состояния пациента и функции верхней конечности в основной и контрольной группах в различные сроки реабилитации

Table 1. Dynamics of the patient's functional state indicators and upper limb function in the main and control groups at different stages of rehabilitation

Шкала	1-е сутки		28-е сутки	
	основная группа	группа сравнения	основная группа	группа сравнения
Оценка уровня бытовой активности по индексу Бартеля	73,50 ± 33,88	74,36 ± 4,82	85,11 ± 14,47	81,20 ± 5,12
Модифицированный Френчай тест (MFT)	2,58 ± 0,07	2,47 ± 0,11	3,81 ± 0,12	3,14 ± 0,11
Шестибалльная шкала оценки мышечной силы	3,41 ± 0,32	3,53 ± 0,24	4,32 ± 2,39	4,53 ± 1,20
Тест для оценки двигательной функции руки (ARAT)	18,28 ± 2,18	19,30 ± 4,82	26,80 ± 2,20	23,90 ± 3,24
Шкала Fugl-Meyer (FMA)	52,20 ± 5,26	54,10 ± 6,49	62,84 ± 3,80	58,62 ± 5,70
Модифицированная шкала Эшворта (MAS)	1,50 ± 0,14	1,52 ± 0,09	1,05 ± 0,13	1,26 ± 0,16

Сравнительная оценка эффективности реабилитации на различных шкалах, полученная на основе таблицы 1 в ос-

новной и контрольной группах, приведена ниже (табл. 2).

Таблица 2. Сравнительная оценка эффективности реабилитации на различных шкалах в основной и контрольной группах

Table 2. Comparative assessment of the effectiveness of rehabilitation on various scales in the main and control groups

Шкалы	МΔ		МΔ%	
	основная группа	группа сравнения	основная группа	группа сравнения
Оценка уровня бытовой активности по индексу Бартеля	11,60	6,84	15,8	9,1
Модифицированный Френчай тест (MFT)	1,23	0,67	47,6	27,3
Шестибалльная шкала оценки мышечной силы	0,91	0,50	26,6	14,2
Тест для оценки двигательной функции руки (ARAT)	8,52	4,60	46,6	23,8
Шкала Fugl-Meyer (FMA)	10,64	4,52	20,3	8,3
Модифицированная шкала Эшворта (MAS)	– 0,45	-0,26	30,0	17,1

У группы с мониторингом косвенного показателя БТР было большее улучшение по всем шкалам, по сравнению с группой, которая получила реабилитацию с роботизированным устройством без использования управления посредством мониторинга БТР. Так, двигательные навыки при проведении модифицированного Френчай-теста достоверно значимо ($p < 0,05$) улучшились только у пациентов основной группы. Тест для оценки двигательной функции руки ARAT и шкала Fugl-Meyer также показали преимущество реабилитации в условиях мониторинга БТР.

Выводы

1. Введено понятие биотехнического резонанса, позволяющее оценить способность мозга человека управлять телом (группой мышц), а также способностью мышц выполнять команды мозга и сообщать о качестве их выполнения.

2. Разработан алгоритм управления процедурой реабилитации верхних конечностей, отличающийся мониторингом косвенного критерия биотехнического резонанса, основанного на анализе расстояний в кластерном простран-

стве, построенном в координатах показаний динамометра F и мышечной усталости, и позволяющий управлять глобальными параметрами процедуры реабилитации с дискретностью равной одному пачу.

3. Проведены экспериментальные исследования биотехнической системы при мониторинге косвенного критерия биотехнического резонанса, которые показали, что полученные при мониторинге биотехнического резонансы результаты превосходят результаты реабилитации известным методом: на шкале MBI – на 6%, на шкале MFT – на 20%, на шкале мышечной силы – на 13%, на шкале ARAT – на 23%, на шкале FMA – на 12% и на шкале Эшворта – на 13%.

Полученные в результате исследования данные позволяют сделать заключение, что использование при реабилитации верхних конечностей мониторинга и управления биотехническим резонансом позволяет повысить эффективность использования персонифицированной биотехнической системы для восстановления двигательных функций верхних конечностей у пациентов, перенесших ишемический инсульт.

Список литературы

1. Chen H., Yun G. Efficacy of Brain-Computer Interface Therapy for Upper Limb Rehabilitation in Chronic Stroke: Systematic Review and Meta-Analysis of Randomized Controlled Trials // J. Med. Internet. Res. 2026. Vol. 28. P. e79132. <https://doi.org/10.2196/79132>.
2. Upper extremity training followed by lower extremity training with a brain-computer interface rehabilitation system / S. Sieghartsleitner, M. Sebastián-Romagosa, W. Cho, J. Grünwald, R. Ortner, J. Scharinger, K. Kamada, C. Guger // Front. Neurosci. 2024. Vol. 18. P. 1346607. <https://doi.org/10.3389/fnins.2024.1346607>.

3. Brain-Computer Interfaces in the Rehabilitation of Stroke and Spinal Cord Injury: A Systematic Review and Meta-Analysis of Clinical Efficacy / U. Ali, J. Khan, M. Ahsan [et al.] // *Cureus*. 2025. Vol. 17, N. 10. P. e94833. <https://doi.org/10.7759/cureus.94833>.

4. Advantages of Virtual Reality in the Rehabilitation of Balance and Gait: Systematic Review / P. D. Cano, P. Siemonsma, R. Inzelberg, G. Zeilig, M. Plotnik // *Neurology*. 2018. Vol. 90, N. 22. P. 1017-1025. <https://doi.org/10.1212/WNL.0000000000005603>.

5. Воображение движения и его практическое применение / О. А. Мокиенко, Л. А. Черникова, А. А. Фролов, П. Д. Бобров // *Журнал высшей нервной деятельности имени И. П. Павлова*. 2013. Т. 63, № 2. С. 195–204. <https://doi.org/10.7868/S0044467713020056>.

6. The ReHand-BCI trial: a randomized controlled trial of a brain-computer interface for upper extremity stroke neurorehabilitation / J. Cantillo-Negrete, M. E. Rodríguez-García, P. Carrillo-Mora, O. Arias-Carrión, E. Ortega-Robles, M. A. Galicia-Alvarado, R. Valdés-Cristerna, A. G. Ramirez-Nava, C. Hernandez-Arenas, J. Quinzaños-Fresnedo, M. D. R. Pacheco-Gallegos, N. Marín-Arriaga, R. I. Carino-Escobar // *Front Neurosci*. 2025. Vol. 19. P. 1579988. <https://doi.org/10.3389/fnins.2025.1579988>.

7. Петрунина Е. В., Томакова Р. А., Филист С. А. Гибридные методы и модели для биотехнических систем с адаптивным управлением диагностическими и реабилитационными процессами: монография. Курск: Университетская книга, 2022. 249 с.

8. Гибридный метод контроля мышечной усталости в робототехнической системе / А. А. Кузьмин, Р. А. Томакова, Е. В. Петрунина, Д. А. Ермаков, С. Кадырова // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2023. Т. 13, № 3. С. 64–81. <https://doi.org/10.21869/2223-1536-2023-13-3-64-81>.

9. Нейронечеткие сети для систем дистанционного мониторинга амбулаторных пациентов с заболеваниями органов дыхания / А. В. Бутусов, А. Х. Алавси Хайдер, Р. А. Карачевцев, А. Ю. Сухомлинов, С. А. Филист // *Моделирование, оптимизация и информационные технологии*. 2023. Т. 11, № 3. С. 1–16. <https://doi.org/10.26102/2310-6018/2023.42.3.016>.

10. Клиническая эффективность технологий виртуальной реальности в восстановлении функции верхней конечности после инсульта / Н. И. Слепнева, В. Д. Даминов, Э. В. Новак, О. Э. Карпов // *Вестник Национального медико-хирургического центра имени Н. И. Пирогова*. 2021. Т. 16, № 2. С. 80–85. https://doi.org/10.25881/20728255_2021_16_2_80.

11. Живолупов С. А., Самарцев И. Н., Сыроежкин Ф. А. Современная концепция нейропластичности (теоретические аспекты и практическая значимость) // *Журнал неврологии и психиатрии имени С. С. Корсакова*. 2013. Т. 113, № 10. С. 102–108.

12. Brain-Computer Interfaces in the Rehabilitation of Stroke and Spinal Cord Injury: A Systematic Review and Meta-Analysis of Clinical Efficacy / U. Ali, J. A. Khan, Md T. Ahsan, B. Altaf [et al.] // *Cureus*. 2025. Vol. 17, N 10. P. e94833. <https://doi.org/10.7759/cureus.94833>.

13. Yozbatiran N., Der-Yeghiaian L., Cramer S. C. A Standardized Approach to Performing the Action Research Arm Test // *Neurorehabil. Neural Repair*. 2008. Vol. 22, N 1. P. 78–90. <https://doi.org/10.1177/1545968307305353>.
14. Association between lesion location and sensorimotor rhythms in stroke – a systematic review with narrative synthesis / I. Kancheva, S. M. A. van der Salm, N. F. Ramsey, M. J. Vansteensel // *Neurological Sciences*. 2023. Vol. 44. P. 4263–4289. <https://doi.org/10.1007/s10072-023-06982-8>.
15. Роботизированные устройства в реабилитации после инсульта / А. А. Фролов, И. Б. Козловская, Е. В. Бирюкова, П. Д. Бобров // *Журнал высшей нервной деятельности имени И. П. Павлова*. 2017. Т. 67, № 4. С. 394–413. <https://doi.org/10.7868/S004446771704-0017>.
16. Предварительные результаты контролируемого исследования эффективности технологии ИМК-экзоскелет при постинсультном парезе руки / А. А. Фролов, О. А. Мокиенко, Р. Х. Люкманов, Л. А. Черникова, С. В. Котов [и др.] // *Вестник Российского государственного медицинского университета*. 2016. № 2. С. 17–25.
17. Изменения гемодинамической активности мозга при воображении движений в результате тренировки испытуемых на управление интерфейсом мозг – компьютер / А. А. Фролов, Д. Гусек, А. В. Сильченко, Я. Тинтера, Я. Рыдло // *Физиология человека*. 2016. Т. 42, № 1. С. 5–18. <https://doi.org/10.7868/S0131164616010082>.

References

1. Chen H., Yun G. Efficacy of Brain-Computer Interface Therapy for Upper Limb Rehabilitation in Chronic Stroke: Systematic Review and Meta-Analysis of Randomized Controlled Trials. *J. Med. Internet. Res.* 2026;28:e79132. <https://doi.org/10.2196/79132>.
2. Sieghartsleitner S., Sebastián-Romagosa M., Cho W., Grünwald J., Ortner R., Schäringer J., Kamada K., Guger C. Upper extremity training followed by lower extremity training with a brain-computer interface rehabilitation system. *Front. Neurosci.* 2024;18:1346607. <https://doi.org/10.3389/fnins.2024.1346607>.
3. Ali U., Khan J., Ahsan M., et al. Brain-Computer Interfaces in the Rehabilitation of Stroke and Spinal Cord Injury: A Systematic Review and Meta-Analysis of Clinical Efficacy. *Cureus*. 2025;17(10):e94833. <https://doi.org/10.7759/cureus.94833>.
4. Cano P.D., Siemonsma P., Inzelberg R., Zeilig G., Plotnik M. Advantages of Virtual Reality in the Rehabilitation of Balance and Gait: Systematic Review. *Neurology*. 2018;90(22):1017-1025. <https://doi.org/10.1212/WNL.0000000000005603>.
5. Mokiyenko O.A., Chernikova L.A., Frolov A.A., Bobrov P.D. Imagination of movement and its practical application. *I.P. Pavlov Journal of Higher Nervous Activity*. 2013;63(2):195-204. (In Russ.) <https://doi.org/10.7868/S0044467713020056>.
6. Cantillo-Negrete J., Rodríguez-García M.E., Carrillo-Mora P., Arias-Carrión O., Ortega-Robles E., Galicia-Alvarado M.A., Valdés-Cristerna R., Ramirez-Nava A. G., Hernan-

dez-Arenas C., Quinzaños-Fresnedo J., Pacheco-Gallegos M.D.R., Marín-Arriaga N., Carino-Escobar R.I. The ReHand-BCI trial: a randomized controlled trial of a brain-computer interface for upper extremity stroke neurorehabilitation. *Front Neurosci.* 2025;19:1579988. <https://doi.org/10.3389/fnins.2025.1579988>.

7. Petrunina E.V., Tomakova R.A., Filist S.A. Hybrid methods and models for biotechnical systems with adaptive control of diagnostic and rehabilitation processes. Kursk: Universitetskaya kniga; 2022. 249 p. (In Russ.)

8. Kuzmin A.A., Tomakova R.A., Petrunina E.V., Ermakov D.A., Kadyrova S. Hybrid Method for Controlling Muscle Fatigue in the Robotic System. *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.* 2023;13(3):64–81. (In Russ.) <https://doi.org/10.21869/2223-1536-2023-13-3-64-81>.

9. Butusov A.V., Alawsi Hayder A.H., Karachevtsev R.A., Sukhomlinov A.Yu., Filist S.A. Neural Fuzzy Networks for Remote Monitoring Systems for Outpatients with Respiratory Diseases. *Modelirovanie, optimizaciya i informacionnye tehnologii = Modeling, Optimization and Information Technology.* 2023;11(3):1–16. (In Russ.) <https://doi.org/10.26102/2310-6018/2023.42.3.016>.

10. Slepneva N.I., Daminov V.D., Novak Eh.V., Karpov O.E. The Clinical Efficacy of Virtual Reality Technologies in Restoring Functional Abilities of the Upper Limb after Stroke. *Vestnik Nacional'nogo mediko-hirurgicheskogo Centra imeni N.I. Pirogova = Bulletin of Pirogov National Medical & Surgical Center.* 2021;(16)2:80-85. (In Russ.) https://doi.org/10.25881/20728255_2021_16_2_80.

11. Zhivolupov S.A., Samartsev I.N., Syroezhkin F.A. Contemporary conception of neuroplasticity (theoretical aspects and practical significance). *Zhurnal nevrologii i psikiatrii im. S.S. Korsakova = S.S. Korsakov Journal of Neurology and Psychiatry.* 2013;113(10):102-108. (In Russ.)

12. Ali U., Khan J.A., Ahsan Md T., Altaf B., et al. Brain-Computer Interfaces in the Rehabilitation of Stroke and Spinal Cord Injury: A Systematic Review and Meta-Analysis of Clinical Efficacy. *Cureus.* 2025;17(10):e94833. <https://doi.org/10.7759/cureus.94833>.

13. Yozbatiran N., Der-Yeghiaian L., Cramer, S.C.A Standardized Approach to Performing the Action Research Arm Test. *Neurorehabil. Neural Repair.* 2008;22(1):78–90. <https://doi.org/10.1177/1545968307305353>.

14. Kancheva I., van der Salm S.M.A., Ramsey N.F., Vansteensel M.J. Association between lesion location and sensorimotor rhythms in stroke – a systematic review with narrative synthesis. *Neurological Sciences.* 2023;44:4263–4289. <https://doi.org/10.1007/s10072-023-06982-8>.

15. Frolov A.A., Kozlovskaja I.B., Biryukova E.V., Bobrov P.D. Robotic Devices in Poststroke Rehabilitation. *Zhurnal vysshej nervnoj deyatel'nosti imeni I.P. Pavlova =*

I.P. Pavlov *Journal of Higher Nervous Activity*. 2017;67(4):394-413. (In Russ.) <https://doi.org/10.7868/S004446771704-0017>.

16. Frolov A.A., Mokienko O.A., Lyukmanov R.Kh., Chernikova L.A., Kotov S.V., et al. Preliminary Results of a Controlled Study of BCI-Exoskeleton Technology Efficacy in Patients with Poststroke Arm Paresis. *Vestnik rossiiskogo gosudarstvennogo meditsinskogo universiteta = Bulletin of the Russian State Medical University*. 2016;(2):17-25. (In Russ.).

17. Frolov A.A., Husek D., Silchenko A.V., Tintera Y., Rydlo J. The Changes in the Hemodynamic Activity of the Brain during Moroe Imagery Training with the Use of Brain – Computer Interface. *Fiziologiya Cheloveka = Human Physiology*. 2016;42(1):5-18. (In Russ.) <https://doi.org/10.7868/S0131164616010082>.

Информация об авторах / Information about the Authors

Петрунина Елена Валерьевна, кандидат технических наук, доцент, Московский политехнический университет, г. Москва, Российская Федерация, e-mail: petrunina@mggeu.ru, ORCID: 0000-0003-3661-0778

Elena V. Petrunina, Cand. Sci. (Engineering), Associate Professor, Moscow Polytechnic University, Moscow, Russian Federation, e-mail: petrunina@mggeu.ru, ORCID: 0000-0003-3661-0778

Ермаков Дмитрий Андреевич, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: dmitriyermakov98@yandex.ru, ORCID: 0009-0003-9426-7741

Dmitry A. Ermakov, Postgraduate at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: dmitriyermakov98@yandex.ru, ORCID: 0009-0003-9426-7741

Скворцов Михаил Константинович, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: m.k.skvortsov@gmail.com, ORCID: 0009-0006-4962-1125

Mikhail K. Skvortsov, Postgraduate at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: m.k.skvortsov@gmail.com, ORCID: 0009-0006-4962-1125

Дрейзин Валерий Элеazarович, доктор технических наук, профессор, ведущий инженер Регионального центра нанотехнологий, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: drezin-ve@yandex.ru, Researcher ID: G-4715-2013, ORCID: 0000-0003-4818-565X

Valery E. Drejzin, Dr. Sci. (Engineering), Professor, Leading Engineer of the Regional Nanotechnology Center, Southwest State University, Kursk, Russian Federation, e-mail: drezin-ve@yandex.ru, Researcher ID: G-4715-2013, ORCID: 0000-0003-4818-565X

Филист Сергей Алексеевич, доктор технических наук, профессор, профессор кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: SFilist@gmail.com, Researcher ID: O-4610-2015, ORCID: 0000-0003-1358-671X

Sergey A. Filist, Dr. Sci. (Engineering), Professor, Professor at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: SFilist@gmail.com, Researcher ID: O-4610-2015, ORCID: 0000-0003-1358-671X

Шаталова Ольга Владимировна, доктор технических наук, доцент, профессор кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: shatolg@mail.ru, Researcher ID: C-3687-2015, ORCID: 0000-0002-0901-9272

Olga V. Shatalova, Dr. Sci. (Engineering), Associate Professor, Professor at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: shatolg@mail.ru, Researcher ID: C-3687-2015, ORCID: 0000-0002-0901-9272

<https://doi.org/10.21869/2223-1536-2026-16-2-76-90>



УДК 004.9

Обнаружение и классификация перегрузок многомашиных вычислительных систем

Ю. С. Бехтин¹, К. С. Баланев¹, А. В. Титова² ✉

¹ Национальный исследовательский университет «МЭИ»
ул. Красноказарменная, д. 14/1, г. Москва 111250, Российская Федерация

² Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: nyatarr@yandex.ru

Резюме

Цель исследования – разработать критерии обнаружения и классификации перегрузок, возникающих в многомашиных вычислительных системах, по данным сетевого трафика с опорой на анализ его регулярного тренда и последующую вероятностную интерпретацию перегрузочного состояния.

Методы. В качестве метода выделения регулярного тренда сетевого трафика используется вейвлет-регрессионная обработка временного ряда, обеспечивающая подавление высокочастотных возмущений и сохранение регулярной составляющей. Для выявления интервалов перегрузки применяется байесовский обнаружитель импульсных сигналов, формирующий сглаженную импульсную последовательность апостериорных вероятностей превышения нормального режима. Для количественного описания каждого перегрузочного эпизода введена параметрическая модель импульса на основе гауссовой аппроксимации, позволяющая связать перегрузку с тремя измеримыми характеристиками: амплитудой, длительностью и интегральной площадью. Дополнительно предложены нормализованные показатели параметров относительно статистики нормального режима и интегральный критерий отклонения, обеспечивающий оценку выраженности перегрузочного состояния.

Результаты. Получены критерии и правила классификации перегрузок по пяти типам: импульсная, фоновая, прогрессирующая, периодическая и атакующая. Результаты имитационного моделирования на данных с различными режимами нагрузки показали работоспособность предложенного подхода: перегрузочные эпизоды выделяются устойчиво, а типизация соответствует ожидаемой структуре сценариев. Выявлены особенности реакции вероятностного обнаружителя на плавно нарастающую нагрузку, способную проявляться как последовательность локальных импульсов.

Заключение. Разработанная методика обеспечивает переход от визуальной интерпретации выходного сигнала байесовского обнаружителя к количественной оценке и типизации перегрузок и может применяться в задачах автоматизированного мониторинга сетевого трафика и поддержки решений по управлению качеством обслуживания в многомашиных вычислительных системах.

Ключевые слова: сетевой трафик; перегрузка; вейвлет-регрессия; вероятностное реле; критерии классификации; апостериорная вероятность; классификация аномалий.

Финансирование: Данная работа финансировалась за счет средств бюджета в рамках государственного задания Министерства науки и высшего образования РФ № FSWF-2025-0010 «Разработка научно-технических основ создания программных и аппаратных решений для управления объектами энергетики с использованием цифровых двойников и технологий искусственного интеллекта».

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

Для цитирования: Бехтин Ю. С., Баланев К. С., Титова А. В. Обнаружение и классификация перегрузок многомашинных вычислительных систем // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 76–90. <https://doi.org/10.21869/2223-1536-2026-16-2-76-90>.

Поступила в редакцию 02.04.2026

Подписана в печать 01.05.2026

Опубликована 30.06.2026

Detection and classification of network congestions in multi-machine computing systems

Yuri S. Bekhtin¹, Kirill S. Balanев¹, Anna V. Titova² ✉

¹ National Research University "Moscow Power Engineering Institute"
14/1 Krasnokazarmennaya Str., Moscow 111250, Russian Federation

² Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: nyatarr@yandex.ru

Abstract

The purpose of the research is to develop criteria for detecting and classifying overloads occurring in multi-machine computing systems based on network traffic data based on an analysis of its regular trend and subsequent probabilistic interpretation of the overload state.

Methods. The wavelet regression processing of the time series is used as a method for detecting the regular trend of network traffic, which ensures the suppression of high-frequency disturbances and the preservation of the regular component. To identify overload intervals, a Bayesian pulse signal detector is used, which generates a smoothed pulse sequence of a posteriori probabilities of exceeding the normal mode. To quantify each overload episode, a parametric pulse model based on Gaussian approximation is introduced, which makes it possible to associate overload with three measurable characteristics: amplitude, duration, and integral area. Additionally, normalized parameter indicators relative to normal mode statistics and an integral deviation criterion are proposed, which provides an assessment of the severity of the overload condition.

Results. Criteria and rules for classifying overloads into five types are obtained: impulse, background, progressive, periodic and attacking. The results of simulation modeling on data with different load modes showed the efficiency of the proposed approach: overload episodes are consistently highlighted, and the typing corresponds to the expected structure of scenarios. The features of the probabilistic detector's response to a smoothly increasing load, which can manifest itself as a sequence of local pulses, are revealed.

Conclusion. The developed technique provides a transition from visual interpretation of the Bayesian detector output signal to quantification and typification of congestion and can be used in tasks of automated monitoring of network traffic and support for quality-of-service management solutions in multi-machine computing systems.

Keywords: network traffic; overload; wavelet regression; probabilistic relay; classification criteria; posterior probability; anomaly classification.

Funding: This work was financed from the budget within the framework of the state task of the Ministry of Science and Higher Education of the Russian Federation No. FSWF-2025-0010 "Development of scientific and technical foundations for creating software and hardware solutions for managing energy facilities using digital twins and artificial intelligence technologies".

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

For citation: Bekhtin Y.S., Balanov K.S., Titova A.V. Detection and classification of network congestions in multi-machine computing 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*. 2026;16(2):76-90. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-76-90>.

Received 02.04.2026

Accepted 01.05.2026

Published 30.06.2026

Введение

Проблема обнаружения и классификации перегрузок многомашинных вычислительных систем (МВС) сохраняет свою актуальность на фоне роста объёмов данных и усложнения архитектуры распределённых сетей. Перегрузка МВС, как, впрочем, и любой компьютерной сети, проявляется в виде изменения интенсивности транзакций, роста задержек и увеличения вероятности потерь пакетов, что приводит к деградации качества обслуживания и снижению устойчивости МВС. Очевидно, мониторинг сетевого трафика МВС в реальном масштабе времени теоретически позволяет не только выявлять факты перегрузки, но количественно и качественно оценивать её выраженность. Однако применяемые в настоящее время на практике известные методы обнаружения перегрузок, которые можно условно разделить на несколько классов, не являются в достаточной степени эффективными.

К числу основных методов относятся алгоритмы управления сетевыми очередями, такие как Random Early Detection (RED), использующие вероятностный сброс пакетов при превышении порогов средней длины очереди [1]. Развитие этого направления привело к появлению модифицированных версий RED, например Adaptive Dual RED (AD-RED), где вероятностная функция сброса формируется на основе комби-

нации квадратичного и экспоненциального законов [2]. Параллельно развивается линия исследований, посвящённых применению методов машинного обучения для активного управления очередями, что позволяет строить адаптивные модели регулирования, согласованные с динамикой трафика [3].

На транспортном уровне перегрузки фиксируются конечными детекторами TCP, основанными на потерях пакетов (TCP Reno, Cubic) или задержках (TCP Vegas, FAST), что позволяет регулировать скорость передачи, однако в таком случае перегрузка фиксируется с опозданием [4]. Сравнительные исследования показывают, что взаимодействие различных алгоритмов TCP с AQM-механизмами (включая RED, CoDel и их модификации) остаётся предметом активного изучения, в т. ч. в условиях высокоскоростных сетей [5].

Другой широко применяемый класс методов связан с использованием статистического контроля процесса (Statistical Process Control, SPC), включая карты Шухарта, кумулятивные суммы (CUSUM) и экспоненциально взвешенные скользящие средние (EWMA). Эти подходы позволяют строить контрольные границы для временных рядов сетевого трафика и выявлять отклонения от нормального режима [6]. Развитие данного направления связано с сочетанием классических статистических методов и нейросетевых моделей, например в комбинированных алгоритмах

CUSUM, где традиционная статистика дополняется прогнозирующими компонентами, обученными на больших массивах сетевых данных [7].

В последние годы внимание исследователей сосредоточено на вероятностных методах обнаружения изменений параметров временных рядов, включая Bayesian Online Change Point Detection (BOCPD), Page-Hinkley и Generalized Likelihood Ratio (GLR). Эти алгоритмы позволяют выявлять структурные изменения и формировать динамические пороговые значения, что делает их более адаптивными к изменчивой нагрузке [8]. Появились и новые вариации BOCPD, использующие авторегрессионные модели и байесовскую фильтрацию для повышения точности онлайн-детекции [9], а также методы обнаружения изменений в сетевых процессах с пропусками данных, что делает их применимыми к телеметрическим системам [10].

Таким образом, существующие методы анализа сетевого трафика демонстрируют разнообразные подходы к предварительному обнаружению перегрузок, формируя при этом набор эмпирических и статистически обоснованных критериев. Эти результаты создают основу для разработки собственных критериев, согласованных с вейвлет-регрессионным методом [11] и вероятностным реле (байесовский обнаружитель), где перегрузка проявляется в виде импульсной последовательности. Таким образом, задача настоящего исследования заключается не в замещении существующих решений, а в адаптации их принципов к особенностям предложенного метода, что обеспечивает возможность формализованной классификации перегрузочных состояний по

предлагаемому авторами методу. В задачу исследования входит систематизация существующих подходов, определение параметров сетевого трафика и формализация критериев, позволяющих классифицировать различные виды перегрузок сети.

Цель исследования заключается в разработке формализованных критериев обнаружения и классификации перегрузок в многомашинных вычислительных системах на основе анализа временных рядов сетевого трафика и вероятностной интерпретации перегрузочного состояния.

Для достижения поставленной цели в работе решаются следующие задачи:

- выделение регулярной составляющей сетевого трафика при подавлении высокочастотных возмущений;
- формирование вероятностного индикатора перегрузки на основе байесовского обнаружения изменений;
- параметризация перегрузочных эпизодов по амплитудно-временным характеристикам;
- разработка критериев и правил классификации перегрузок по характеру их проявления в сетевом трафике;
- экспериментальная проверка работоспособности предложенного подхода на смоделированных данных.

Материалы и методы

В ранее выполненных исследованиях авторами была предложена методика анализа сетевого трафика, основанная на применении регрессионного анализа в вейвлет-области [12]. Основная идея заключалась в применении стационарного вейвлет-преобразования (Stationary Wavelet Transform, SWT) для выделения трендовой компоненты временного ряда интенсивности тра-

фика и подавления высокочастотных возмущений. На первом этапе исходный временной ряд $x(t)$ (рис. 1), представляющий данные о сетевой нагрузке (это может быть как количество запросов, так и скорость передачи данных, выполняемых в определенный промежуток времени), подвергался многоуровневой вейвлет-декомпозиции до глубины $L = 3$. Для каждого уровня декомпозиции вычислялись коэффициенты аппроксимации A_L и детализации

D_i , где $i = 1, 2, 3$. Полученные коэффициенты детализации аппроксимировались полиномиальными функциями третьей степени по методу наименьших квадратов, что позволило сгладить локальные всплески в деталях. Обратное преобразование (Inverse SWT) восстанавливало трендовую компоненту $\tilde{x}(t)$, характеризующую поведение сетевой нагрузки при устранении случайных выбросов и высокочастотных шумов (см. рис. 1).




Рис. 1. Работа вейвлет-регрессионного метода

Fig. 1. Operation of the wavelet regression method

Дальнейший этап обработки заключался в подаче восстановленного тренда $\tilde{x}(t)$ на вход вероятностного реле, представляющего собой байесовской обнаружитель импульсных сигналов. Вероятностное реле функционировало как нелинейный оператор адаптивного усиления, вычисляя для каждой

точки сигнала апостериорную вероятность перегрузочного состояния. Усиление выполнялось в зависимости от степени отклонения текущего значения тренда от априорного распределения нормального режима и от вероятности перехода системы в перегруженное состояние (см. рис. 1). Таким образом, ве-

роятностное реле выполняло роль динамического фильтра, который выделял участки сигнала с высокой вероятностью перегрузки.

В результате применения данного механизма исходный тренд преобразуется в импульсную последовательность – гладкую во времени функцию $p(t)$, интерпретируемую как апостериорную вероятность перегрузочного состояния. По определению вероятности $0 \leq p(t) \leq 1$; следовательно, амплитуда каждого импульса

$$A = \max_{t \in [t_1, t_2]} p(t) \quad (1)$$

и ограничена сверху единицей ($A \leq 1$). Чем ближе A к 1, тем выше степень уверенности в перегрузке в соответствующий момент времени; при этом амплитуды, близкие к 0, отражают нормальный режим. Визуальный анализ $p(t)$ позволяет различать периоды нормальной работы и перегрузки, однако наличие численных параметров импульсов, как амплитуда $A \in [0, 1]$, длительность $\Delta t = t_2 - t_1$ и интегральная площадь

$$S = \int_{t_1}^{t_2} p(t) dt, \quad (2)$$

позволяет разработать систему критериев, которая позволит на основе этих параметров оценивать степень и вид перегрузки МВС.

Разработка критериев оценки перегрузок для метода вейвлет-регрессии с вероятностным реле

Метод вейвлет-регрессии [13] с последующим применением вероятностного реле позволяет выделять участки сетевого трафика, соответствующие потенциальным перегрузочным состояни-

ям. На выходе реле формируется импульсная последовательность [14] – сглаженный сигнал с локализованными пиками, отражающими высокую апостериорную вероятность превышения нормального режима. Несмотря на хорошую визуальную интерпретируемость, дальнейшее применение метода в автоматизированных системах требует перехода от качественного описания к количественной классификации перегрузок.

В отличие от физических процессов, где амплитуда импульса может служить прямым показателем интенсивности события, в предлагаемом методе величина пиков ограничена значениями вероятности. Апостериорная вероятность, формируемая реле, по определению не превышает 1 и в типичных случаях варьируется в диапазоне 0,2–0,95. Следовательно, при разработке критериев оценки необходимо использовать нормализованные характеристики импульсов, совместимые с вероятностной природой выходного сигнала.

Основной задачей настоящего раздела является формализация параметров выходной импульсной последовательности, обеспечивающая методику для оценки степени, длительности и характера перегрузки. Задача решается на основе методов статистического контроля процессов [15], вероятностной детекции изменений [16] и параметрического моделирования [17], что позволяет обосновать выбор пороговых значений и гарантировать согласованность методологии с общепринятыми средствами анализа сетевых аномалий.

Для формализации импульсов на выходе вероятностного реле целесообразно использовать параметрическую аппроксимацию. Анализируя форму выходных пиков, можно заключить, что

наибольшее соответствие наблюдаемым кривым демонстрирует гауссова модель, обладающая хорошей локализацией во времени и симметричной формой. Такая аппроксимация ранее применялась в задачах анализа агрегированных сетевых аномалий [18] и обеспечивает аналитическую трактовку параметров, отражающих характеристики перегрузки.

Импульс $I(t)$ приближён функцией нормального распределения:

$$I(t) = A \cdot \exp\left(-\frac{(t-t_0)^2}{2\sigma^2}\right), \quad (3)$$

где $A \in (0,1]$ – амплитуда, соответствующая максимальной апостериорной вероятности перегрузочного состояния; t_0 – момент времени максимальной интенсивности; σ – дисперсия, определяющая длительность импульса.

Ширина импульса Δt на уровне половины амплитуды определяется как

$$\Delta t = 2\sqrt{2\ln 2} \cdot \sigma, \quad (4)$$

а интегральная площадь S под кривой

$$S = \int_{-\infty}^{\infty} I(t)dt \approx A \cdot \sigma \cdot \sqrt{2\pi}. \quad (5)$$

Поскольку амплитуда A ограничена сверху значением 1 (по определению вероятности), следует отказаться от традиционной трактовки A как интенсивности в абсолютных величинах. Вместо этого предлагается рассматривать нормализованные значения амплитуды относительно порога обнаружения перегрузки.

В качестве порогового значения амплитуды предлагается использовать уровень τ_{hi} , который соответствует высокой степени уверенности в перегрузочном состоянии. Такой выбор согласуется с практикой применения байесовских методов обнаружения измене-

ний во временных рядах [19], где значения апостериорной вероятности выше 0,8 рассматриваются как свидетельство существенного отклонения от нормального режима. Кроме того, эмпирические наблюдения показали, что в нормальных условиях уровень пиков редко превышает 0,6, в то время как в периоды перегрузки наблюдаются устойчивые превышения 0,8–0,9.

Оставшиеся параметры импульса – длительность Δt и площадь S – нормализуются по отношению к статистике нормального режима. Для нормализации предварительно вычисляются средние значения и стандартные отклонения параметров по выборке интервалов, классифицированных как нормальные по амплитуде ($A < 0,5$):

$$z_{\Delta t} = \frac{\Delta t - \mu_{\Delta t}}{\sigma_{\Delta t}}, \quad z_S = \frac{S - \mu_S}{\sigma_S}, \quad (6)$$

где $\mu_{\Delta t}$, μ_S – средние значения; $\sigma_{\Delta t}$, σ_S – стандартные отклонения соответствующих параметров при нормальной работе сети.

Далее определяется интегральный критерий отклонения:

$$K = \sqrt{(z_{\Delta t})^2 + (z_S)^2}. \quad (7)$$

На основе нормализованных параметров импульса и интегрального отклонения K можно выделить пять основных типов перегрузочных состояний (табл. 1), различающихся по форме и динамике проявления в сетевом трафике. Каждый тип соответствует определённому сочетанию амплитудных и временных характеристик импульса и отражает специфическое поведение системы в условиях нагрузки.

Предложенная классификация опирается на логическую интерпретацию выходного сигнала вероятностного ре-

ле, где амплитуда отражает уверенность в перегрузке, длительность характеризует её временное развитие, а площадь – общее воздействие на систему. Классификационные признаки согласованы с подходами, использованными в работах по анализу временных структур трафика и выявлению сетевых аномалий [20].

Использование нормализованных параметров обеспечивает устойчивость классификации к масштабным изменениям в структуре нагрузки, а параметр K служит универсальной метрикой для первичного выделения аномальных состояний. Дальнейшая идентификация вида перегрузки осуществляется на основе анализа формы и структуры импульса в пределах превышения $K > 2,5$,

что согласуется с классической стратегией многоуровневой фильтрации [21].

Результаты и их обсуждение

Для проверки применимости разработанного метода к задаче обнаружения и классификации перегрузок были проведены экспериментальные исследования на смоделированных данных, имитирующих различные режимы работы МВС. Целью эксперимента являлась оценка способности метода выделять перегрузочные состояния с учётом их формы и динамики, а также проверка предложенных критериев классификации на основе параметров импульсной последовательности.

Таблица 1. Классификация типов перегрузок МВС по параметрам импульсной последовательности

Table 1. Classification of MCS overload types by pulse sequence parameters

Тип перегрузки	Амплитуда	Нормализованная длительность	Нормализованная площадь	Дополнительные признаки	Интерпретация
Импульсная	$A \geq 0,8$	$z_{\Delta t} < 1$	$z_S < 1$	Изолированный пик	Кратковременный, но интенсивный перегрузочный всплеск
Фоновая	$0,6 \geq A \geq 0,8$	$z_{\Delta t} \geq 1,5$	$z_S \geq 1,5$	Отсутствие чётких границ, плато-образный участок	Длительное насыщение канала
Прогрессирующая	A растёт во времени	$z_{\Delta t} \uparrow$	$z_S \uparrow$	Серия импульсов с увеличением параметров	Постепенное накопление нагрузки
Периодическая	$A \approx \text{const}$	$z_{\Delta t} \approx \text{const}$	$z_S \approx \text{const}$	Повторение пиков через равные интервалы τ	Циклический характер нагрузки
Атакующая	$A \geq 0,9$	Любое	$z_S \gg 2$	Снижение разнообразия трафика, высокая автокорреляция	Внешнее воздействие (например, DDoS атака)

Смоделированный набор данных (рис. 2) включал чередующиеся участки с различными типами нагрузок, соответствующими основным классам перегрузок: нормальное состояние, импульсная, фоновая, прогрессирующая, периодическая и атакующая перегрузки. Интенсивность трафика в каждом сегменте формировалась с использованием регулируемых стохастических и детерминированных компонентов, отражающих особенности соответствующего режима. Для нормального сегмента использовался слабокоррелированный шум с

постоянным средним значением. Импульсные перегрузки реализовывались в виде резких одиночных всплесков. Фоновые перегрузки моделировались как устойчиво повышенный уровень интенсивности, сохраняющийся длительное время. Прогрессирующая перегрузка была задана в виде монотонно возрастающей функции интенсивности, периодическая – как синусоидальное изменение, а атакующая – как последовательность равномерно распределённых пиков высокой амплитуды и плотности, с пониженной вариативностью.




Рис. 2. Смоделированный набор данных

Fig. 2. The simulated data set

Для обработки тестовых данных применялась методика, описанная в предыдущих разделах: извлечение трендовой компоненты с помощью стацио-

нарного вейвлет-преобразования (рис. 3), подача регулярного тренда на вероятностное реле и последующее формирование импульсной последовательности.




Рис. 3. Выделение регулярного тренда трафика

Fig. 3. Highlighting the regular traffic trend

Каждый обнаруженный пик был аппроксимирован гауссовой функцией и охарактеризован по трём основным параметрам: амплитуде A , длительности Δt и площади S . Для оценки степени отклонения от нормального режима использовались нормализованные значения параметров и интегральный крите-

рий K , построенный по евклидовой норме в пространстве $(z_{\Delta t}, z_S)$.

В результате обработки смоделированного временного ряда были обнаружены 22 перегрузочных импульса. Таблица 2 содержит выборочные сводные данные по результатам проведенного эксперимента.

Таблица 2. Параметры обнаруженных перегрузок и результаты их классификации

Table 2. Parameters of detected overloads and the results of their classification

i	L	R	t_0	Амп- литуда	Ширина импульса	Нормализо- ванная дли- тельность	Нормали- зованная площадь	Тип перегрузки
0	296	298	297	0,65	10	0,50	-1,36	Прогрессирующая
1	362	369	364	0,81	10	0,50	0,56	Импульсная пере- грузка
2	433	439	434	0,78	10	0,50	0,18	Прогрессирующая
3	482	489	484	0,81	11	0,75	0,57	Импульсная пере- грузка
4	775	1013	778	0,79	244	59,00	75,25	Фоновая пере- грузка
.....								
17	2024	2031	2026	0,82	11	0,75	0,64	Атакующая
18	2408	2413	2410	0,69	10	0,50	-0,34	Фоновая пере- грузка
19	2454	2461	2456	0,79	12	1,00	0,57	Прогрессирующая
20	2502	2509	2504	0,80	12	1,00	0,57	Импульсная пере- грузка
21	2551	2555	2552	0,66	10	0,50	-0,73	Фоновая пере- грузка

Результаты визуализированы ниже (рис. 4). График иллюстрирует форму выходного сигнала вероятностного реле

$V(t)$, пороговые уровни τ_{mid} и τ_{hi} , а также классифицированные импульсы с подписями соответствующих типов.




Рис. 4. Визуализация работы вероятностного реле и результатов обнаружения и классификации

Fig. 4. Visualization of the probabilistic relay operation and the results of detection and classification

Анализ классификации показал высокую степень соответствия между обнаруженными импульсами и ожидаемыми типами перегрузок. Тем не менее при сопоставлении с реальной структурой нагрузки были выявлены отдельные расхождения, отражающие особенности работы вероятностного реле.

Наиболее заметное расхождение наблюдалось в сегменте с прогрессирующей перегрузкой [1250–1500], где интенсивность возрастает монотонно. Вероятностное реле в таких случаях реагирует не на общий тренд, а на локальные изменения – точки ускоренного роста или кратковременные скачки, что приводит к разбиению прогрессирующего сегмента на серию отдельных импульсов, каждый из которых классифицируется изолированно. Несмотря на то, что суммарная форма соответствует плавному нарастанию нагрузки, итоговая классификация фиксирует импульсные или фоновые состояния, не отражая факта накопления трафика.

Причины указанных расхождений связаны с конструктивной особенностью вероятностного реле. Оно функционирует как нелинейный усилитель локальных отклонений и имеет повышенную чувствительность к резким из-

менениям. При этом длительные и плавные отклонения от нормы воспринимаются как малозначимые и могут быть отфильтрованы. Таким образом, метод демонстрирует высокую эффективность при обнаружении кратковременных, периодических и атакующих перегрузок, но требует дополнительной адаптации для корректного выявления прогрессирующих перегрузок.

Выводы

В рамках настоящего исследования разработаны формализованные критерии оценки перегрузок сетевого трафика, возникающих в многомашиных вычислительных системах. Критерии основаны на количественной интерпретации выходного сигнала вероятностного реле, представляющего собой последовательность апостериорных вероятностей превышения нормального режима. Аппроксимация импульсных участков гауссовыми функциями позволила осуществить параметризацию каждого перегрузочного состояния по трём измеримым характеристикам – амплитуде, длительности и площади, что обеспечило основу для последующей классификации.

Введена система нормализованных показателей и интегральный критерий

отклонения, устойчивый к масштабным колебаниям трафика.

Разработанная система классификации включает пять основных типов перегрузок, соответствующих характерным сценариям работы МВС. Проведённые эксперименты на смоделированных данных показали высокую согласованность между классификацией и

реальной структурой нагрузки, подтвердив применимость предложенных критериев в условиях изменяющейся сетевой динамики. Полученные результаты могут быть использованы в системах автоматизированного мониторинга и анализа трафика, а также в задачах прогнозирования и адаптивного управления качеством обслуживания.

Список литературы

1. Петушков Г. В. Оценка производительности вычислительной системы // Известия Юго-Западного государственного университета. 2025. Т. 29, № 2. С. 201–220.
2. Hassan S. O. AD-RED: A new variant of random early detection AQM algorithm // Journal of High Speed Networks. 2024. Vol. 30, N 1. P. 53–67.
3. Тоорчинеzhad M. P., Ahmadi M. Machine learning approaches for active queue management: A survey, taxonomy, and future directions // arXiv.org. URL: <https://arxiv.org/abs/2410.02563> (дата обращения: 15.03.2026).
4. Технологии оптимизации сетевого трафика / Д. В. Гадасин, А. Д. Кобелькова, А. А. Родина, М. А. Сурова // Системы синхронизации, формирования и обработки сигналов. 2025. Т. 16, № 3. С. 9–16.
5. Muhammad S., Chaudhery T. J., Noh Y. Study on performance of AQM schemes over TCP variants in different network environments // IET Communications. 2021. N 15. P. 93–111. <https://doi.org/10.1049/cmu2.12061>.
6. Математическое моделирование системы автоматического регулирования численным интегрированием / В. А. Хандожко, О. Н. Федонин, В. П. Матлахов, А. В. Хандожко // Известия Юго-Западного государственного университета. 2025. Т. 29, № 2. С. 55–70.
7. Neural network-based CUSUM for online change-point detection / T. Gong, J. Lee, X. Cheng, Y. Xie // arXiv.org. URL: <https://arxiv.org/abs/2210.17312> (дата обращения: 15.03.2026).
8. Performance measurement of Bayesian online changepoint detection and its application / M. Shimono [et al.] // Second International Conference on Advanced Robotics, Automation Engineering, and Machine Learning (ARAEML 2025). SPIE, 2025. Vol. 13815. P. 83–103.
9. Tsaknaki I.-Y., Lillo F., Mazzarisi P. Bayesian Autoregressive Online Change-Point Detection with Time-Varying Parameters // arXiv.org. URL: <https://arxiv.org/abs/2407.16376> (дата обращения: 15.03.2026).
10. Online Bayesian changepoint detection for network Poisson processes with community structure / J. Corneek [et al.] // Statistics and Computing. 2025. Vol. 35, N 3. P. 1–29.
11. Bekhtin Y. S., Balanev K. S. Simulation Modeling Network Traffic Behavior Using Regression Analysis in Wavelet Domain // 2024 6th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE). Moscow: IEEE, 2024. P. 1–6.

12. Stability Appraisal of the Wavelet-and-Regression Method for Unsteady Network Traffic Trend Highlighting / Y. S. Bekhtin, K. S. Balanov, E. A. Dubrovskaya, A. V. Pavlovich // 2025 7th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE). Moscow: IEEE, 2025. P. 1–5.

13. Клименко А. Б. Методика выбора способа управления распределенными информационными системами в условиях высокой динамики сетевой инфраструктуры // Известия Юго-Западного государственного университета. 2022. Т. 26, № 1. P. 57–72.

14. RouteNet-Fermi: Network Modeling With Graph Neural Networks / M. Ferriol-Galmés [et al.] // IEEE/ACM Transactions on Networking. 2023. Vol. 31, N 6. P. 3080–3095.

15. Bicski B., Pekar A. Early Detection of Network Service Degradation: An Intra-Flow Approach // 2024 20th International Conference on Network and Service Management (CNSM). Prague: IEEE, 2024. P. 1–5.

16. Graf F., Watteyne T., Villnow M. Monitoring Performance Metrics in Low-Power Wireless Systems // ICT Express. 2024. Vol. 10, N 5. P. 989–1018.

17. Espinal A., Sanchez Padilla V. Queuing Delay Reduction based on Network Traffic Patterns: A Predictive QoS Framework For Point-To-Point Communications // Transport and Telecommunication Journal. 2025. Vol. 26, N 3. P. 237–249.

18. Ali S. Hong, Cheung T. Congestion or No Congestion: Packet Loss Identification and Prediction Using Machine Learning // 2024 International Conference on Platform Technology and Service (PlatCon). Jeju, 2024. P. 72–76.

19. Jin Q. Optimized transmission of multi-path low-latency routing for electricity internet of things based on SDN task distribution // PLoS One. 2025. N 20(2). P. 1–23. <https://doi.org/10.1371/journal.pone.0314253>.

20. Alauthman A., Al-Hyari A. Analysis of LTE/5G network performance parameters in smartphone use cases: a study of packet loss, delay and slice types // International Journal of Computer Networks & Communications (IJCNC). 2025. Vol. 17, N 4. P. 75–93.

21. A Comparative Study of TCP and UDP Performance Using NS-3 Simulation / G. Gaoyang, C. Zhiyi, F. Qamar, A. Hafizah Mohd Aman // Asia-Pacific Journal of Information Technology and Multimedia. 2025. N 14(1). P. 1–19.

References

1. Petushkov G.V. Computational system performance evaluation. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2025;29(2):201-220. (In Russ.)

2. Hassan S.O. AD-RED: A new variant of random early detection AQM algorithm. *Journal of High Speed Networks*. 2024;30(1):53-67.

3. Toopchinezhad M.P., Ahmadi M. Machine learning approaches for active queue management: A survey, taxonomy, and future directions. Available at: <https://arxiv.org/abs/2410.02563> (accessed 15.03.2026).

4. Gadasin D.V., Kobelkova A.D., Rodina A.A., Surova M.A. Network traffic optimization technologies. *Sistemy sinkhronizatsii, formirovaniya i obrabotki signalov = Synchronization Systems, Signal Generation and Processing*. 2025;16(3):9–16. (In Russ.)

5. Muhammad S., Chaudhery T.J., Noh Y. Study on performance of AQM schemes over TCP variants in different network environments. *IET Communications*. 2021;(15):93-111. <https://doi.org/10.1049/cmu2.12061>.
6. Khandozhko V.A., Fedonin O.N., Matlakhov V.P., Khandozhko A.V. Mathematical modeling of automatic control system by numerical integration. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2025;29(2):55-70. (In Russ.)
7. Gong T., Lee J., Cheng X., Xie Y. Neural network-based CUSUM for online change-point detection. Available at: <https://arxiv.org/abs/2210.17312> (accessed 15.03.2026).
8. Shimono M., et al. Performance measurement of Bayesian online changepoint detection and its application. In: *Second International Conference on Advanced Robotics, Automation Engineering, and Machine Learning (ARAEML 2025)*. Vol. 13815. SPIE; 2025. P. 83–103.
9. Tsaknaki I.-Y., Lillo F., Mazzarisi P. Bayesian Autoregressive Online Change-Point Detection with Time-Varying Parameters. Available at: <https://arxiv.org/abs/2407.16376> (accessed 15.03.2026).
10. Corneck J., et al. Online Bayesian changepoint detection for network Poisson processes with community structure. *Statistics and Computing*. 2025;35(3):1-29.
11. Bekhtin Y.S., Balanev K.S. Simulation Modeling Network Traffic Behavior Using Regression Analysis in Wavelet Domain. In: *2024 6th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE)*. Moscow: IEEE; 2024. P. 1–6.
12. Bekhtin Y.S., Balanev K.S., Dubrovskaya E.A., Pavlovich A.V. Stability Appraisal of the Wavelet-and-Regression Method for Unsteady Network Traffic Trend Highlighting. In: *2025 7th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE)*. Moscow: IEEE; 2025. P. 1–5.
13. Klimenko A.B. A Technique of the Distributed Information Systems Control Method Choice under the High Network Dynamics Conditions. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2022;26(1):57-72. (In Russ.)
14. Ferriol-Galmés M., et al. RouteNet-Fermi: Network Modeling With Graph Neural Networks. *IEEE/ACM Transactions on Networking*. 2023;31(6):3080-3095.
15. Bicski B., Pekar A. Early Detection of Network Service Degradation: An Intra-Flow Approach. In: *2024 20th International Conference on Network and Service Management (CNSM)*. Prague: IEEE; 2024. P. 1–5.
16. Graf F., Watteyne T., Villnow M. Monitoring Performance Metrics in Low-Power Wireless Systems. *ICT Express*. 2024;10(5):989-1018.
17. Espinal A., Sanchez Padilla V. Queuing Delay Reduction based on Network Traffic Patterns: A Predictive QoS Framework For Point-To-Point Communications. *Transport and Telecommunication Journal*. 2025;26(3):237-249.
18. Ali I., Hong S., Cheung T. Congestion or No Congestion: Packet Loss Identification and Prediction Using Machine Learning. In: *2024 International Conference on Platform Technology and Service (PlatCon)*. Jeju; 2024. P. 72–76.

19. Jin Q. Optimized transmission of multi-path low-latency routing for electricity internet of things based on SDN task distribution. *PLoS One*. 2025. P. 1–23. <https://doi.org/10.1371/journal.pone.0314253>.
20. Alauthman A., Al-Hyari A. Analysis of LTE/5G network performance parameters in smartphone use cases: a study of packet loss, delay and slice types. *International Journal of Computer Networks & Communications (IJCNC)*. 2025;17(4):75–93.
21. Gaoyang G., Zhiyi C., Qamar F., Hafizah Mohd Aman A. A Comparative Study of TCP and UDP Performance Using NS-3 Simulation. *Asia-Pacific Journal of Information Technology and Multimedia*. 2025;(14):1-19.

Информация об авторах / Information about the Authors

Бехтин Юрий Станиславович, доктор технических наук, профессор кафедры прикладной математики и искусственного интеллекта, Национальный исследовательский университет «МЭИ», г. Москва, Российская Федерация, e-mail: yuri.bekhtin@yandex.ru, ORCID: 0000-0001-9963-7244, Author ID: 518783

Yuri S. Bekhtin, Dr. Sci. (Engineering), Professor at the Department of Applied Mathematics and Artificial Intelligence, National Research University "Moscow Power Engineering Institute", Moscow, Russian Federation, e-mail: yuri.bekhtin@yandex.ru, ORCID: 0000-0001-9963-7244, Author ID: 518783

Баланев Кирилл Сергеевич, аспирант, Национальный исследовательский университет «МЭИ», г. Москва, Российская Федерация, e-mail: balanev.kirill@yandex.ru, ORCID: 0009-0002-9722-7262, Author ID: 1204517

Kirill S. Balanev, Postgraduate, National Research University "Moscow Power Engineering Institute", Moscow, Russian Federation, e-mail: balanev.kirill@yandex.ru, ORCID: 0009-0002-9722-7262, Author ID: 1204517

Титова Анна Владимировна, кандидат технических наук, доцент, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: nyatarr@yandex.ru, ORCID: 0000-0002-1619-2938, Author ID: 1169728

Anna V. Titova, Cand. Sci. (Engineering), Associate Professor, Southwest State University, Kursk, Russian Federation, e-mail: nyatarr@yandex.ru, ORCID: 0000-0002-1619-2938, Author ID: 1169728

Автономное управление движением уретероскопа при проведении операции методом ретроградной интраренальной хирургии

С. Ф. Яцун¹ ✉, Е. Д. Тисцов¹, Д. И. Ефремов¹, Г. А. Фурсов¹

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

✉ e-mail: teormeh@inbox.ru

Abstract

Цели исследования – изучить движение дистального конца уретероскопа во время проведения операции методом ретроградной интраренальной хирургии, разработать алгоритм автономного движения дистального конца уретероскопа из исходного положения в заданную точку, провести кинематический анализ движения дистального конца уретероскопа и решить обратную задачу кинематики.

Методы. Для решения поставленных задач использовались методы математического моделирования динамических систем, теории управления и теории механизмов и машин. При создании программных продуктов использован математический пакет Matlab. Разработан метод планирования траектории движения дистального конца уретероскопа на основе анализа снимков магнитно-резонансной томографии и компьютерной томографии. При движении дистального конца уретероскопа по полученной траектории применяется полиномиальный закон движения исполнительных звеньев.

Результаты. В ходе исследования были рассмотрены основные задачи, решаемые хирургом во время проведения операции методом ретроградной интраренальной хирургии, а также сформулирована стратегия автономного управления стендом уретероскопа. Разработан метод планирования траектории движения дистального конца уретероскопа на основе анализа и обработки снимков магнитно-резонансной томографии и компьютерной томографии. Разработан алгоритм автономного движения дистального конца уретероскопа из исходного положения в заданную точку. Проведён кинематический анализ движения дистального конца уретероскопа, для обеспечения движения по планируемой траектории решена обратная задача кинематики, позволяющая установить связь между положением и ориентацией дистального конца уретероскопа и управляющими воздействиями.

Заключение. Предложенные алгоритмы автономного управления движением дистального конца уретероскопа, созданные на основе математического моделирования движения будут использованы при разработке робота для проведения операций методом ретроградной интраренальной хирургии в автономном режиме, что позволит проводить операции методом ретроградной интраренальной хирургии намного легче и точнее, чем сейчас. Также в данной работе была сформулирована стратегия автономного управления медицинским стендом уретероскопа.

Ключевые слова: математическое моделирование; робот; автоматическое движение; ретроградная интраренальная хирургия; почка; уретероскоп.

Финансирование: Работа выполнена при поддержке Госзадания Минобрнауки России по теме «Разработка методов синтеза адаптивных и интеллектуальных робототехнических устройств и комплексов в целях расширения функциональных технологических и производственных возможностей человека» (соглашение № 075-03-2025-526).

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

Для цитирования: Автономное управление движением уретероскопа при проведении операции методом ретроградной интратрениальной хирургии / С. Ф. Яцун, Е. Д. Тисцов, Д. И. Ефремов, Г. А. Фурсов // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 91–101. <https://doi.org/10.21869/2223-1536-2026-16-2-91-101>.

Поступила в редакцию 15.04.2026

Подписана в печать 12.05.2026

Опубликована 30.06.2026

Autonomous control of ureterscope movement during retrograde intrarenal surgery

Sergey F. Jatsun¹ ✉, Yegor D. Tistsov¹, Dmitry I. Efremov¹, Gavriil A. Fursov¹

¹ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: teormeh@inbox.ru

Резюме

The purpose of the research are to study the movement of the distal end of the ureterscope during retrograde intrarenal surgery, to develop an algorithm for autonomous movement of the distal end of the ureterscope from the initial position to a given point, to conduct a kinematic analysis of the movement of the distal end of the ureterscope and to solve the inverse kinematics problem.

Methods. Methods of mathematical modeling of dynamic systems, control theory, and theory of mechanisms and machines were used to solve these problems. When creating software products, the mathematical package Matlab is used. A method has been developed for planning the trajectory of the distal end of the ureterscope based on the analysis of magnetic resonance imaging and computed tomography images. When the distal end of the ureterscope moves along the resulting trajectory, the polynomial law of motion of the actuating links is applied.

Results. In the course of the study, the main tasks solved by the surgeon during surgery using retrograde intrarenal surgery were considered, and a strategy for autonomous control of the ureterscope stand was formulated. A method has been developed for planning the trajectory of the distal end of the ureterscope based on the analysis and processing of magnetic resonance imaging and computed tomography images. An algorithm has been developed for the autonomous movement of the distal end of the ureterscope from the initial position to a given point. A kinematic analysis of the movement of the distal end of the ureterscope has been performed. To ensure movement along the planned trajectory, the inverse kinematic problem has been solved, which makes it possible to establish a relationship between the position and orientation of the distal end of the ureterscope and control actions.

Conclusion. The proposed algorithms for autonomous motion control of the distal end of the urethra, created on the basis of mathematical motion modeling, will be used in the development of a robot for performing operations using retrograde intrarenal surgery in an autonomous mode, which will allow performing operations using retrograde intrarenal surgery much easier and more accurately than now. Also in this paper, a strategy for autonomous management of the ureterscope medical stand was formulated.

Keywords: mathematical modeling; robot; automatic movement; retrograde intrarenal surgery; kidney; ureterscope.

Funding: The work was carried out with the support of the State Assignment of the Ministry of Education and Science of the Russian Federation on the topic "Development of methods for synthesizing adaptive and intelligent robotic devices and complexes in order to expand the functional technological and production capabilities of humans" (agreement No. 075-03-2025-526).

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

For citation: Jatsun S.F., Tistsov E.D., Efremov D.I., Fursov G.A. Autonomous control of ureterscope movement during retrograde intrarenal surgery. *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(2):91-101. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-91-101>.

Received 15.04.2026

Accepted 12.05.2026

Published 30.06.2026

Введение

Современные гибкие уретероскопы (рис. 1) состоят из следующих основных элементов: 1 – управляемый гибкий дистальный отдел ВС; 2 – пассивный гибкий участок АВ; 3 – корпус уретероскопа А; 4 – источник света, который установлен на торце инструмента, там же установлена видеокамера, обеспечивающая

через фибро-оптические волокна передачу видеоизображения на монитор. Диаметр рабочего канала современных уретероскопов изменяется в диапазоне 3,6-8 Ch [1]. В последних поколениях гибких инструментов вместо оптических волокон установлен цифровой видеочип на торце инструмента, обеспечивающий лучшую визуализацию в высоком разрешении [2].




Рис. 1. Схема уретероскопа в почке при проведении операции методом ретроградной интратрениальной хирургии

Fig. 1. Diagram of a ureterscope in the kidney during retrograde intrarenal surgery

Выделим основные задачи, решаемые хирургом при проведении операции:

1. Доставка инструмента через уретру и мочеточник в почку.
2. Движение дистального конца уретероскопа (ДКУ) в сторону камня.
3. Литотрипсия камня.
4. Вывод инструмента из ЧЛС [3].

Материалы и методы

Изгиб дистального отдела уретероскопа обеспечивается приводами, соединенными с манипулятором на рукоятке инструмента, установленной на корпусе. Для обеспечения заданного движения дистального конца уретероскопа в сторону камня рассмотрим возможные стратегии управления движением ДКУ [4].

1. Наиболее распространенным на сегодняшний день является режим мануального управления. Врач рукой перемещает корпус и рукоятку уретероскопа, обеспечивая желаемое положение ДКУ относительно камня. Контроль положения осуществляется с помощью видеокамеры и рентгена¹. Достоинства метода состоят в относительной простоте аппаратной части. Недостатками являются некомфортные для врача условия проведения операции, требования к высокой квалификации врача, нахождение врача в зоне действия рентгеновского излучения [5].

¹ Устройство для проведения операций методом ретроградной интратеренальной хирургии: пат. 228 918 Рос. Федерация. № 2024110522; заявл. 17.04.24; опубл. 17.09.24, Бюл. № 26.

2. Последние годы появились роботизированные стенды, позволяющие реализовать режим телеуправления [6]. В этом случае уретероскоп устанавливается в роботизированный медицинский стенд (МС РИРХ), который обеспечивает вертикальное, продольное движения и поворот корпуса, а также поворот рукоятки [7]. Для управления движением ДКУ врач использует модуль управления, выполненный в виде системы джойстиков, кнопок, а также перчаток [8]. Достоинства метода состоят в значительном улучшении комфортных условий для врача, выходе из зоны действия рентгеновского излучения. Недостатками метода являются значительное усложнение аппаратной части и необходимость обучения медперсонала для работы с роботизированным оборудованием [9].

3. Наиболее перспективным является режим автономного управления движением уретероскопа². В этом случае задача врача заключается в программировании работы МС РИРХ в части задания начального положения ДКУ, положения камней в почке, планировании траектории движения инструмента. Далее, система управления и приводы МС РИРХ в соответствии с заданным алгоритмом обеспечивают выполнение движений ДКУ [10]. Достоинства метода состоят в создании максимально

² Хирургический робот для ретроградной интратеренальной хирургии: пат. 2 852 306 Рос. Федерация. № 2025104297; заявл. 25.02.25; опубл. 08.12.25, Бюл. № 34.

комфортных условий для врача, минимизации движений, выполняемых врачом при проведении операции, а также выходе из зоны действия рентгеновского излучения [11]. Недостатком метода является необходимость разработки алгоритмической и программной частей МС РИРХ, обеспечивающих автономное движение ДКУ с заданной точностью, что, в свою очередь, требует переобучения медперсонала для работы с

роботизированным оборудованием в условиях автономного управления [12].

Рассмотрим подробнее задачу о движении ДКУ в сторону камня. ДКУ обозначен на схеме точкой C . Будем считать, что после доставки инструмента через уретру и мочеточник в почку ДКУ находится в почке в точке M (рис. 2). Координаты этой точки определим с помощью радиус-вектора $\vec{r}_M = (x_M, y_M, z_M)^T$ [13].




Рис. 2. Схема уретероскопа при движении ДКУ

Fig. 2. The scheme of the ureteroscope during the movement of the DCU

Будем считать, что камень располагается в точке N и его положение задано радиус-вектором $\vec{r}_N = (x_N, y_N, z_N)^T$.

Желаемую траекторию движения ДКУ представим в виде линии MN . Для ее определения можно использовать, например, снимки компьютерной томографии [11]. Алгоритм системы автономного управления обеспечивает перемещение ДКУ (точка C) вдоль траектории MN с заданной точностью [14]. Для этого МС РИРХ имеет следующие возможности:

1) перемещение точки A (см. рис. 2) корпуса уретероскопа вдоль координат OY, OZ ;

2) поворот корпуса уретероскопа относительно продольной оси на угол $\alpha \in [-\pi/2, \pi/2]$;

3) поворот рукоятки уретероскопа на угол $\varphi \in [-\pi/4, \pi/4]$, что обеспечивает поворот дистального конца уретероскопа на угол $\beta \in [-275^\circ, 275^\circ]$.

Если считать, что продольное движение корпуса уретероскопа происходит вдоль оси OY , то вектор управляю-

щих воздействий, обеспечивающих желаемое движение точки C , представим в виде

$$\bar{q} = (\alpha, \varphi, y)^T. \quad (1)$$

Положение ДКУ, т. е. точки C , определим с помощью радиус-вектора $\bar{r}_C(\bar{q})$:

$$\bar{r}_C(\bar{q}) = \bar{r}_A + \bar{r}_{AB} + \bar{r}_{BC}. \quad (2)$$

Определим радиус-векторы:

$$\bar{r}_C(\bar{q}) = \begin{bmatrix} x_C \\ y_C \\ z_C \end{bmatrix}. \quad (3)$$

Радиус-вектор, определяющий положение точки A :

$$\bar{r}_A = \begin{bmatrix} x_A \\ y_A \\ z_A \end{bmatrix}. \quad (4)$$

Радиус-вектор, определяющий положение точки B относительно точки A :

$$\bar{r}_{AB} = \begin{bmatrix} x_{AB} \\ y_{AB} \\ z_{AB} \end{bmatrix}. \quad (5)$$

Радиус-вектор, определяющий положение точки C относительно точки B :

$$\bar{r}_{BC} = \begin{bmatrix} x_{BC} \\ y_{BC} \\ z_{BC} \end{bmatrix}. \quad (6)$$

Из (2) с учетом (3) – (6) получим

$$\begin{bmatrix} x_C \\ y_C \\ z_C \end{bmatrix} = \begin{bmatrix} x_A + x_{AB} + x_{BC} \\ y_A + y_{AB} + y_{BC} \\ z_A + z_{AB} + z_{BC} \end{bmatrix}. \quad (7)$$

Примем, что поворот дистального отдела уретроскопа происходит в плоскости OBC , тогда получим

$$\bar{r}_{BC} = \begin{bmatrix} x_{BC} \\ y_{BC} \\ z_{BC} \end{bmatrix} = \begin{bmatrix} R(1 - \cos \beta) \sin \alpha \\ y_A + y_{AB} + R \sin \beta \\ R(1 - \cos \beta) \cos \alpha \end{bmatrix}. \quad (8)$$

Для современных уретероскопов длина дистального отдела равна 80 мм и является постоянной величиной [15]:

$$l_{BC} = \text{const.}$$

Установим связь между радиусом петли, создаваемой дистальным отделом при повороте на угол β . Так как

$$l_{BC} = R\beta, \quad (9)$$

то формула, связывающая угол поворота ДКУ β и радиус R , имеет вид

$$R = \frac{l_{BC}}{\beta}. \quad (10)$$

Угол β зависит от угла поворота рукоятки уретероскопа φ [16]. Экспериментально установлено, что для ряда уретероскопов $\beta = 6\varphi$ [17]. Зададим желаемое движение ДКУ вдоль траектории MN в следующем виде:

$$\bar{r}_C(t) = \begin{bmatrix} x_C(t) \\ y_C(t) \\ z_C(t) \end{bmatrix}. \quad (11)$$

Результаты и их обсуждение

Для моделирования желаемой траектории выберем полиномиальный закон, который представим в следующем виде:

$$\begin{aligned}x_C(t) &= \sum_{i=0}^5 a_i t^i, \\y_C(t) &= \sum_{i=0}^5 b_i t^i, \\z_C(t) &= \sum_{i=0}^5 c_i t^i.\end{aligned}$$

Постоянные a_i, b_i, c_i определяются из граничных условий. Например, при $t = 0$; $x_C(0) = x_0$; $\dot{x}_C(0) = 0$; $\ddot{x}_C(0) = 0$; при $t = T$; $x_C(T) = x_k$; $\dot{x}_C(T) = 0$; $\ddot{x}_C(T) = 0$, где T – время движения из точки N в точку M [20].

Далее необходимо определить уравнение, позволяющее находить вектор управляющих параметров $\bar{q}(t)$. Для этого рассмотрим равенство:

$$\bar{r}_C(t) = \bar{r}_C(\bar{q}),$$

то

$$\frac{\partial \bar{r}_C}{\partial t} = \frac{\partial \bar{r}_C}{\partial \bar{q}}(\dot{\bar{q}}). \quad (12)$$

Введем обозначение:

$$J = \frac{\partial \bar{r}_C}{\partial \bar{q}}. \quad (13)$$

где J – матрица Якоби.

Отсюда получим:

$$\dot{\bar{q}} = J^{-1} \frac{\partial \bar{r}_C}{\partial t}. \quad (14)$$

где J^{-1} – обратная матрица Якоби.

Преобразуем (14) в дискретную форму:

$$\bar{q}_k = \bar{q}_{k-1} + J^{-1} \Delta \bar{r}_C, \quad (15)$$

где $k = 1, 2, 3, \dots, n$; $\Delta \bar{r}_C = \bar{r}_{Ck-1} - \bar{r}_{Ck-2}$ – приращение радиус вектора $\bar{r}_C$ на интервале $\Delta t = t_{k-1} - t_{k-2}$; n – число точек разбиения отрезка времени T , на котором выполняется перемещение ДКУ из точки N в точку M [19].

Полученное рекуррентное выражение (15) позволяет построить алгоритм управления, обеспечивающий движение ДКУ по заданной траектории [20].

Выводы

Предложенные алгоритмы автономного управления движением ДКУ, созданные на основе математического моделирования движения, будут использованы при разработке робота для проведения операций методом РИРХ в автономном режиме, что позволит проводить операции таким методом намного легче и точнее, чем сейчас. Также в данной работе была сформулирована стратегия автономного управления медицинским стендом уретероскопа.

Список литературы

1. Григорьев Н. А. Ретроградная интратренальная хирургия: современный взгляд на проблему // Урология. 2018. № 5. С. 175–181. <https://doi.org/10.18565/urology.2018.5.175-181>.
2. Наш опыт применения ретроградной интратренальной хирургии при нефролитиазе / В. В. Сергеев, В. Л. Медведев, С. А. Габриэль, В. В. Чурбаков // Инновационная медицина Кубани. 2023. № 1. С. 46–52. <https://doi.org/10.35401/2541-9897-2023-26-1-46-52>.

3. Ультразвук-перкутанная нефролитотрипсия и ретроградная интратеренальная хирургия при лечении камней почек менее 2 см: сравнительные результаты эффективности и безопасности / И. В. Серёгин, А. А. Серёгин, Е. В. Филимонов, Н. А. Шустик, А. Д. Морозов, Л. А. Синякова, О. Б. Лоран // Креативная хирургия и онкология. 2022. Т. 12, № 2. С. 98–105. <https://doi.org/10.24060/2076-3093-2022-12-2-98-105>.

4. MP29-16 First prospective clinical assessment of the ily robotic flexible ureteroscopy platform / E. Abou Chawareb [et al.] // Journal of Urology. 2024. Vol. 211, N 5S. P. e487. <https://doi.org/10.1097/01.JU.0001008680.67760.37.16>.

5. Lee J. Y., Jeon S. H. Robotic flexible ureteroscopy: a new challenge in endourology // Investigative and Clinical Urology. 2022. Vol. 63, N 5. P. 483. <https://doi.org/10.4111/icu.20220256>.

6. Lithotripsy of renal stones with Avicenna Roboflex robotic-assisted retrograde intrarenal surgery (RA-RIRS) / A. S. Kabakci [et al.] // Handbook of research on biomimetics and biomedical robotics. IGI Global, 2018. P. 142–160. <https://doi.org/10.4018/978-1-5225-2993-4.ch006>.

7. Kincaid B. S., Hsi R. MP29-14 Single-use and reusable ureteroscope related malfunctions and adverse events: an analysis of the manufacturer and user facility device experience database // Journal of Urology. 2024. Vol. 211, N 5S. P. e486. <https://doi.org/10.1097/01.JU.0001008680.67760.37.14>.

8. Мальчиков А. В., Яцун С. Ф., Яцун А. С. Математическое моделирование копирующего управления робототехническим устройством, оснащённым линейным электроприводом с упругим звеном // Проблемы машиностроения и надёжности машин. 2019. № 5. С. 34–42. <https://doi.org/10.1134/S0235711919050055>.

9. Мини-ПНЛ, микро-ПНЛ или РИРХ: сравнение эффективности и безопасности при камнях почек до 2 см / Н. И. Сорокин [и др.] // Урология. 2023. № 4. С. 98–104. <https://doi.org/10.18565/urology.2023.4.98-104>.

10. Continuous renal calculi tracking for autonomous robotic ureteroscopic lithotripsy / Q. Zhang [et al.] // 2025 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2025. P. 5904–5911.

11. Гурбанова М. Ш., Заводчикова Е. И. Робототехника в медицине: современные технологии и перспективы // Образование и наука в XXI веке. 2025. Т. 1, № 61-4. С. 86–94.

12. Бибилова Е. А. Внедрение робототехники в медицину // Менеджмент в здравоохранении: вызовы и риски XXI век: сборник материалов VIII Международной научно-практической конференции. Волгоград: Волгоградский государственный медицинский университет, 2023. С. 61–62.

13. Shu X., Chen Q., Xie L. A novel robotic system for flexible ureteroscopy // The International Journal of Medical Robotics and Computer Assisted Surgery. 2021. Vol. 17, N 1. P. 1–11. <https://doi.org/10.1002/rcs.2191>.

14. Probability-Based Force Control for Flexible Ureterscopy Robots / Y. Deng [et al.] // IEEE Transactions on Automation Science and Engineering. 2024. Vol. 22. P. 8844–8855.
15. Сравнительная эффективность дистанционной ударно-волновой литотрипсии и ретроградной внутрипочечной хирургии при кальций-оксалатном нефролитиазе / В. Л. Медведев, А. А. Буданов, Г. Д. Дмитренко, Г. А. Палагута, А. М. Розенкранц // Инновационная медицина Кубани. 2021. № 1 (21). С. 39–46. <https://doi.org/10.35401/2500-0268-2021-21-1-39-46>.
16. Enhancing surgical outcomes in ureteral stricture treatment: a combined approach using flexible ureteroscopy and laparoscopy / X. Zhang [et al.] // BMC urology. 2025. Vol. 25, N 1. P. 293. <https://doi.org/10.1186/s12894-025-01984-4>.
17. Robotic Flexible Ureterscopy: Systematic Review and Meta-Analysis of Surgical Efficacy, Safety and Ergonomic Outcomes / P. Gopi [et al.] // Cureus. 2025. Vol. 17, N 8. P. e90447. <https://doi.org/10.7759/cureus.90447>.
18. Robotic flexible ureteroscopy: A Step-by-Step video by using Roboflex Avicenna platform / R. B. Ergül [et al.] // Urology. 2024. Vol. 189. P. e8-e9. <https://doi.org/10.1016/j.urology.2024.03.012>.
19. Analysis of performance factors in 240 consecutive cases of robot-assisted flexible ureteroscopic stone treatment / J. Klein [et al.] // Journal of Robotic Surgery. 2021. Vol. 15, N 2. P. 265-274. <https://doi.org/10.1007/s11701-020-01103-5>.
20. Technical aspects and clinical outcomes of robotic ureteroscopy: is it ready for primetime? / M. M. Sinha [et al.] // Current Urology Reports. 2023. Vol. 24, N 8. P. 391–400. <https://doi.org/10.1007/s11934-023-01167-4>.

References

1. Grigoriev N.A. Retrograde intrarenal surgery: a modern look at the problem. *Urologiya = Urology*. 2018;(5):175-181. (In Russ.) <https://doi.org/10.18565/urology.2018.5.175-181>.
2. Sergeev V.V., Medvedev V.L., Gabriel S.A., Churbakov V.V. Our experience in the use of retrograde intrarenal surgery for nephrolithiasis. *Innovatsionnaya meditsina Kubani = Innovative Medicine of the Kuban*. 2023;(1):46-52. (In Russ.) <https://doi.org/10.35401/2541-9897-2023-26-1-46-52>.
3. Seregin I.V., Seregin A.A., Filimonov E.V., Shustitsky N.A., Morozov A.D., Sinyakova L.A., Laurent O.B. Ultramini-percutaneous nephrolithotripsy and retrograde intrarenal surgery in the treatment of kidney stones less than 2 cm: comparative results of efficacy and safety. *Kreativnaya khirurgiya i onkologiya = Creative Surgery and Oncology*. 2022;12(2):98-105. (In Russ.) <https://doi.org/10.24060/2076-3093-2022-12-2-98-105>.
4. Abou Chawareb E., et al. MP29-16 First prospective clinical assessment of the ily robotic flexible ureteroscopy platform. *Journal of Urology*. 2024;211(5S):e487. <https://doi.org/10.1097/01.JU.0001008680.67760.37.16>.

5. Lee J.Y., Jeon S.H. Robotic flexible ureteroscopy: a new challenge in endourology. *Investigative and Clinical Urology*. 2022;63(5):483. <https://doi.org/10.4111/icu.20220256>.
6. Kabakci A.S., et al. Lithotripsy of renal stones with Avicenna Roboflex robotic-assisted retrograde intrarenal surgery (RA-RIRS). In: *Handbook of research on bio-mimetics and bio-medical robotics*. IGI Global; 2018. P. 142–160. <https://doi.org/10.4018/978-1-5225-2993-4.ch006>.
7. Kincaid B.S., Hsi R. MP29-14 Single-use and reusable ureteroscope related malfunctions and adverse events: an analysis of the manufacturer and user facility device experience database. *Journal of Urology*. 2024;211(5S):e486. <https://doi.org/10.1097/01.JU.0001008680.67760.37.14>.
8. Mal'chikov A.V., Yatsun S.F., Yatsun A.S. Mathematical modeling of copying control of a robotic device equipped with a linear electric drive with an elastic link. *Problemy mashinostroeniya i nadezhnosti mashin = Problems of Mechanical Engineering and Machine Reliability*. 2019;(5):34-42. (In Russ.) <https://doi.org/10.1134/S0235711919050055>.
9. Sorokin N.I., et al. Mini-PNL, micro-PNL or RIRS: comparison of efficiency and safety for stones up to 2 cm in size. *Urology*. 2023;(4):98-104. (In Russ.) <https://doi.org/10.18565/urology.2023.4.98-104>.
10. Zhang Q., et al. Continuous renal calculi tracking for autonomous robotic ureteroscopic lithotripsy. In: *2025 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2025. P. 5904–5911.
11. Gurbanova M. Sh., Zavodchikova E. I. Robotics in medicine: modern technologies and prospects. *Obrazovanie i nauka v XXI veke = Education and Science in the XXI Century*. 2025;1(61-4):86-94. (In Russ.)
12. Bibikova E.A. Introduction of robotics in medicine. In: *Menedzhment v zdravookhraneni: vyzovy i riski XXI vek: sbornik materialov VIII Mezhdunarodnoi nauchno-prakticheskoi konferentsii = Management in healthcare: challenges and risks XXI century: Collection of materials of the VIII International Scientific and Practical Conference*. Volgograd: Volgogradskii gosudarstvennyi meditsinskii universitet; 2023. P. 61–62. (In Russ.)
13. Shu X., Chen Q., Xie L. A novel robotic system for flexible ureteroscopy. *International Journal of Medical Robotics and Computer-Assisted Surgery*. 2021;17(1):1-11. (In Russ.) <https://doi.org/10.1002/rcs.2191>.
14. Deng Y., et al. Probability-Based Force Control for Flexible Ureteroscopy Robots. *IEEE Transactions on Automation Science and Engineering*. 2024;22:8844-8855.
15. Medvedev V.L., Budanov A.A., Dmitrenko G.D., Palaguta G.A., Rosenkranz A.M. Comparative effectiveness of remote shock-wave lithotripsy and retrograde intrarenal surgery for calcium oxalate nephrolithiasis. *Innovatsionnaya meditsina Kubani = Innovative Medicine of Kuban*. 2021;(1):39-46. (In Russ.). <https://doi.org/10.35401/2500-0268-2021-21-1-39-46>.
16. Zhang X., et al. Enhancing surgical outcomes in ureteral stricture treatment: a combined approach using flexible ureteroscopy and laparoscopy. *BMC urology*. 2025;25(1):293. <https://doi.org/10.1186/s12894-025-01984-4>.

17. Gopi P., et al. Robotic Flexible Ureteroscopy: Systematic Review and Meta-Analysis of Surgical Efficacy, Safety and Ergonomic Outcomes. *Cureus*. 2025;17(8):e90447. <https://doi.org/10.7759/cureus.90447>.

18. Ergül R.B., et al. Robotic flexible ureteroscopy: A Step-by-Step video by using Roboflex Avicenna platform. *Urology*. 2024;189:e8-e9. <https://doi.org/10.1016/j.urology.2024.03.012>.

19. Klein J., et al. Analysis of performance factors in 240 consecutive cases of robot-assisted flexible ureteroscopic stone treatment. *Journal of Robotic Surgery*. 2021;15(2):265-274. <https://doi.org/10.1007/s11701-020-01103-5>.

20. Sinha M.M., et al. Technical Aspects and Clinical Outcomes of Robotic Ureteroscopy: Is It Ready for Widespread Use? *Current Urology Reports*. 2023;24(8):391-400. <https://doi.org/10.1007/s11934-023-01167-4>.

Информация об авторах / Information about the Authors

Яцун Сергей Фёдорович, доктор технических наук, профессор кафедры механики, мехатроники и робототехники, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: teormeh@inbox.ru, Researcher ID: G-3891-2017, ORCID: 0000-0002-7420-0772

Sergey F. Jatsun, Dr. Sci. (Engineering), Professor at the Department of Mechanics, Mechatronics and Robotics, Southwest State University, Kursk, Russian Federation, e-mail: teormeh@inbox.ru, Researcher ID: G-3891-2017, ORCID: 0000-0002-7420-0772

Тисцов Егор Дмитриевич, аспирант кафедры механики, мехатроники и робототехники, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: tistsov@gmail.com

Yegor D. Tistsov, Postgraduate at the Department of Mechanics, Mechatronics and Robotics, Southwest State University, Kursk, Russian Federation, e-mail: tistsov@gmail.com

Ефремов Дмитрий Игоревич, аспирант кафедры механики, мехатроники и робототехники, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: edip.70@mail.ru

Dmitry I. Efremov, Postgraduate at the Department of Mechanics, Mechatronics and Robotics, Southwest State University, Kursk, Russian Federation, e-mail: edip.70@mail.ru

Фурсов Гавриил Анатольевич, студент кафедры механики, мехатроники и робототехники, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: from.skveki1@mail.ru

Gavriil A. Fursov, Student at the Department of Mechanics, Mechatronics and Robotics, Southwest State University, Kursk, Russian Federation, e-mail: from.skveki1@mail.ru

Гибридный метод распознавания государственных регистрационных знаков транспортных средств на основе конвейерной архитектуры

А. В. Киселев¹, Е. А. Кулешова¹, М. О. Таныгин¹,
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 – повышение точности и скорости распознавания государственных регистрационных знаков транспортных средств в режиме реального времени за счет применения гибридного метода, адаптированного к российским стандартам и устойчивого к условиям окружающей среды.

Методы. В статье предложен и апробирован гибридный метод распознавания государственных регистрационных знаков транспортных средств на основе конвейерной архитектуры YOLOv12 – EasyOCR. Был синтезирован уникальный обучающий набор данных, обеспечивающий максимальную вариативность. Проведен сравнительный анализ детекторов (YOLOv10, YOLOv12, RT-DETR), подтверждающий целесообразность использования модели YOLOv12, продемонстрировавшей наилучшие показатели наиболее важных метрик ($Precision = 0,99$, $Recall = 0,98$ и $mAP_{0,5:0,95} = 0,91$). Разработан многовариантный конвейер предобработки изображений для OCR, выполняющий последовательное преобразование вырезанного изображения, включающий адаптивное масштабирование, улучшение контраста, шумоподавление и морфологические операции. Для минимизации типичных ошибок OCR был использован ограниченный набор допустимых символов и реализован алгоритм проверки соответствия российскому формату государственных регистрационных знаков.

Результаты. Оценка эффективности OCR проводилась путем сравнения распознанного текста с эталонным с использованием количественных метрик, таких как CRR (Character Recognition Rate) и PRR (Plate Recognition Rate), являющейся отраслевым аналогом метрики WRR (Word Recognition Rate). Проведен ряд экспериментов на тестовом наборе данных. Экспериментальная валидация предложенного гибридного метода распознавания государственных регистрационных знаков транспортных средств подтвердила его высокую эффективность (получены значения количественных метрик: $mAP_{0,5:0,95} = 0,91$, $CRR = 99,0\%$, $PRR = 98,5\%$), что свидетельствует о способности метода к обеспечению устойчивого распознавания в условиях реальной эксплуатации.

Заключение. Полученные результаты соответствуют верхней границе диапазона показателей современных систем автоматического распознавания, включая коммерческие решения. Это свидетельствует о высокой конкурентоспособности предложенного метода.

Ключевые слова: государственные регистрационные знаки; детектор; многовариантная предобработка изображений.

Конфликт интересов: Таныгин М. О. является членом редакционной коллегии журнала «Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение» с 2022 г., но не имеет никакого отношения к решению опубликовать эту статью. Статья прошла принятую в журнале процедуру рецензирования. Об иных конфликтах интересов авторы не заявляют.

Для цитирования: Гибридный метод распознавания государственных регистрационных знаков транспортных средств на основе конвейерной архитектуры / А. В. Киселев, Е. А. Кулешова, М. О. Таныгин, Т. Н. Конаныхина, З. К. Чьямова // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 102–121. <https://doi.org/10.21869/2223-1536-2026-16-2-102-121>.

Поступила в редакцию 29.04.2026

Подписана в печать 28.05.2026

Опубликована 30.06.2026

A hybrid method for recognizing vehicle registration plates based on a pipeline architecture

Alexey V. Kiselev¹, Elena A. Kuleshova¹, Maxim O. Tanygin¹,
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 improving the accuracy and speed of real-time recognition of vehicle registration plates through the use of a hybrid method adapted to Russian standards and resistant to environmental conditions.

Methods. This paper proposes and tests a hybrid method for recognizing vehicle registration plates based on the YOLOv12 – EasyOCR pipeline architecture. A unique training dataset was synthesized to ensure maximum variability. A comparative analysis of detectors (YOLOv10, YOLOv12, RT-DETR) was conducted, confirming the feasibility of using the YOLOv12 model, which demonstrated the best performance on the most important metrics (Precision = 0,99, Recall = 0,98, and $mAP_{0,5:0,95} = 0,91$). A multivariate image preprocessing pipeline for OCR was developed, performing sequential transformations of the cropped image, including adaptive scaling, contrast enhancement, noise reduction, and morphological operations. To minimize typical OCR errors, a limited set of acceptable characters was used, and an algorithm for checking compliance with the Russian license plate format was implemented.

Results. The OCR performance was assessed by comparing the recognized text with the reference text using quantitative metrics such as Character Recognition Rate (CRR) and Plate Recognition Rate (PRR), which is the industry equivalent of Word Recognition Rate (WRR). A series of experiments were conducted on a test dataset. Experimental validation of the proposed hybrid method for recognizing vehicle license plates confirmed its high efficiency (quantitative metric values of $mAP_{0,5:0,95} = 0,91$, CRR = 99,0 %, PRR = 98,5 %), demonstrating the method's ability to ensure robust recognition under real-world conditions.

Conclusion. The obtained results correspond to the upper limit of the performance range of modern automatic recognition systems, including commercial solutions. This demonstrates the high competitiveness of the proposed method.

Keywords: state registration plates; detector; multi-variant image preprocessing.

Conflict of interest: Tanygin M.O. is a member of the editorial board of the journal "Series: Management, computing, computer science. Medical instrumentation" since 2022, but has nothing to do with the decision to publish this article. The article passed the peer review procedure adopted in the journal. The authors are not for other conflicts of interest.

For citation: Kiselev A.V., Kuleshova E.A., Tanygin M.O., Konanykhina T.N., Chyamova Z.K. A hybrid method for recognizing vehicle registration plates based on a pipeline architecture. *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(2):102–121. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-102-121>.

Received 29.04.2026

Accepted 28.05.2026

Published 30.06.2026

Введение

Интенсивное развитие городской среды и связанное с ним увеличение плотности транспортных потоков сформировали ряд проблем в сфере регулирования дорожного движения и управления доступом на территорию различных объектов [1]. Наиболее остро эти проблемы проявляются в зонах с высокими требованиями к безопасности и пропускной способности (промышленных зон, логистических хабов, объектов с охраняемыми периметрами и парковочными комплексами) [2]. Применение методов контроля, основанных на прямом участии оператора, связано не только со значительными временными затратами и снижением общей эффективности, но и с потенциальными рисками, обусловленными человеческим фактором [3].

В данном контексте ключевым технологическим решением выступают системы автоматического распознавания (САР) государственных регистрационных знаков транспортных средств (ГРЗ ТС) [4]. Интеграция таких систем в инфраструктуру «умных» городов и транспортных сетей способствует повышению не только операционной эффективности, но и уровня безопасности, в т. ч. за счет поддержки правоохранительной деятельности по поиску ТС [5].

Однако достижение стабильно высоких показателей точности распознавания в условиях неконтролируемой

внешней среды связано с рядом проблем [6]. К их числу относятся динамические изменения условий освещения, погодные факторы, наличие механических загрязнений и частичных перекрытий (окклюзий) объектов, приводящие к размытости, снижению контраста и потере части информации [7]. Классические подходы, основанные на последовательности операций предобработки визуальных данных с последующим применением оптического распознавания символов (OCR), часто демонстрируют снижение точности в нестандартных условиях [8].

Современные исследования ориентированы на разработку гибридных и ансамблевых архитектур, в частности, реализованных на основе глубоких нейронных сетей (НС) [9]. Например, в работе [10] авторами рассмотрена проблема снижения точности традиционных систем распознавания ГРЗ ТС в условиях, приближенных к реальным, где качество изображений ухудшается из-за погодных условий, наклона номера или изменения расстояния съёмки. Для решения этой проблемы был предложен метод, объединяющий усовершенствованную архитектуру нейросетевой модели (НМ) YOLOv5 и модель LPRNet. Для повышения устойчивости постобработки применяется модифицированный алгоритм Soft-NMS (мягкого подавления немаксимумов), позволяющий корректно обрабатывать пересека-

ющиеся ограничительные рамки (ОР) и предотвращать ошибки подавления. Для устранения влияния наклона и искажений ГРЗ ТС на качество распознавания авторы включают пространственную трансформирующую НС, выполняющую коррекцию геометрии изображения перед его подачей в LPRNet. Проведённые эксперименты на наборах данных (НД) из открытых источников продемонстрировали существенный рост показателей точности по сравнению с классическими решениями.

В исследовании [11] авторами рассмотрен подход к построению САР ГРЗ ТС, в которой предварительная обработка изображений выполняется средствами библиотеки OpenCV, включая преобразование в оттенки серого, использование двусторонней фильтрации и выделение контуров для локализации области ГРЗ ТС. Извлечение текстовой информации осуществляется при помощи НМ TesseractOCR. Результаты экспериментов показывают, что разработанная система способна работать в режиме реального времени и обеспечивает высокую точность распознавания при различных уровнях освещённости.

Авторы исследования [12] описали подход к распознаванию тайских ГРЗ ТС в видеопотоке. При реализации предложенного подхода авторы использовали НМ SSD MobileNetV2 для детекции ГРЗ ТС на каждом кадре видео и НМ EasyOCR для последующего извлечения текстовой информации. В связи с тем, что движение транспортных средств на видео приводит к размытию кадров и появлению ошибочных или дублирующихся результатов распознавания, для повышения качества распознавания авторами была реализована

процедура постобработки, которая устраняет ошибочные и повторяющиеся результаты.

В работе [13] для решения задачи автоматического распознавания ГРЗ ТС в режиме реального времени на парковочных пространствах авторами была использована НМ YOLOv4. Для извлечения текста был применен алгоритм OCR. Результаты экспериментов показали, что система демонстрирует точность детекции равную 89 %.

Исходя из результатов предшествующих исследований, можно сделать вывод, что распознавание ГРЗ ТС в режиме реального времени на кадрах видеопотока является актуальной задачей, а сравнительный анализ показывает, что гибридные модели, сочетающие одноэтапные НМ в качестве детекторов и глубокие нейросетевые OCR-системы, достигают наилучшего баланса между скоростью обработки видеоряда, точностью детекции и распознавания, а также адаптивностью и устойчивостью к изменениям внешней среды.

Материалы и методы

Большинство НД из открытых источников сформировано на основе изображений ГРЗ ТС иностранных государств, стандарты которых могут существенно отличаться от российских образцов по форме, шрифтовому исполнению, размерности и цветовой гамме. Кроме того, значительная часть из них состоит из изображений, полученных в идеальных условиях, что может отразиться на обобщающей способности НМ. Исходя из того, что существующие НД не удовлетворяют требованиям исследования, для обучения НМ был синтезирован уникальный обу-

чающий НД, сформированный на основе видеоматериалов, полученных с камер наблюдения, установленных на автомобильных дорогах и объектах транспортной инфраструктуры. Для обеспечения максимальной вариативности данных для формирования НД были использованы записи, сделанные при различных условиях освещенности и погоды, включая дождь, снег и туман, которые вносят естественные искажения и шумы. При покадровой разбивке собранных видеофрагментов осуществлялась фильтрация полученных изображений (из общего потока исключались кадры с чрезмерным размытием или полным перекрытием ГРЗ ТС, не несущие полезной информации для обучения модели).

С целью обеспечения высокой обобщающей способности НМ и предотвращения эффекта переобучения применялись методы аугментации данных, заключающиеся в последовательном применении комплекса геометрических и цветовых трансформаций, моделирующих типичные искажения, характерные для камер наружного наблюдения. При аугментации данных были реализованы случайные повороты изображений в диапазоне от -15 до $+15$ градусов, имитирующие неточности установки камер или наклон ТС, операции масштабирования и сдвига, позволяющие моделировать изменение дистанции до объекта и его смещение относительно центра кадра, включены процедуры коррекции яркости и контрастности, которые обеспечивают адаптацию модели к резким перепадам освещения, возникающим в солнечное время суток или при свете фар в ночное время. Для

имитации расфокусировки объектива или воздействия атмосферных осадков применялось добавление гауссовского шума и размытие по методу Гаусса.

Итоговой объем НД после применения процедуры аугментации составил 3000 изображений. Все изображения были проаннотированы. НД был разделен на три независимые выборки – обучающую, валидационную и тестовую в соотношении 70, 20 и 10 % соответственно от общего объема данных.

При выборе оптимального варианта детектора для использования в гибридном методе распознавания ГРЗ ТС был проведен сравнительный анализ различных модификаций одноэтапных архитектур YOLOv10, YOLOv12 и RT-DETR. Процесс обучения каждой из архитектур проводился в соответствии с едиными параметрами обучения на синтезированном ранее НД (количество эпох обучения: 100; размер батча: 32; размер входного изображения: 640×640 пикселей, оптимизатор: AdamW, начальная скорость обучения: 10^{-3} , коэффициент импульса: 0,937). Для автоматического предотвращения избыточного обучения использовался механизм ранней остановки с параметром «терпения», равным 10 эпохам. Использовалось косинусное затухание скорости обучения до финального значения 10^{-5} , применена L2-регуляризация для предотвращения чрезмерного роста абсолютных значений весов.

Была проведена оценка качества обучения НМ. Графики функции потерь Box Loss, рассчитанные на валидационной выборке, представлены ниже (рис. 1).




Рис. 1. Графики функции потерь Box Loss для НМ RT-DETR, YOLOv10 и YOLOv12

Fig. 1. Box Loss function graphs for RT-DETR, YOLOv10 and YOLOv12 models

Функция Box Loss представляет собой компонент общей функции потерь НМ, отвечающий за оптимизацию пространственных параметров, предсказываемых ОР. Box_loss вычисляет пространственное рассогласование, учитывая не только позиционные смещения, но и геометрические аспекты (соотношение сторон, перекрытие) [14]. В архитектурах YOLO и RT-DETR для расчета этого вида потерь используется функция CIOU (Complete Intersection over Union) Loss, которую можно представить с помощью

$$L_{CIOU} = 1 - IoU + \frac{\rho^2(A, B)}{c^2} + \alpha v, \quad (1)$$

где A и B – предсказанная ОР и настоящая ОР соответственно; IoU – это коэффициент пересечения $(A \cap B)$ и объ-

единения $(A \cup B)$ площадей, определяемый по

$$IoU = \frac{S(A \cap B)}{S(A \cup B)}, \quad (2)$$

при этом $IoU = 0$, если A и B не пересекаются; $IoU = 1$ – в случае идеального наложения [15]; $\rho^2(A, B)$ – евклидово расстояние между центрами рамок A и B ; c – диагональ наименьшей охватывающей рамки, которая включает в себя и предсказанную, и истинную рамки; α – положительный весовой коэффициент, определяемый по

$$\alpha = \frac{v}{(1 - IoU) + v}, \quad (3)$$

где v – параметр, измеряющий схожесть соотношения сторон рамок, определяемый по

$$v = \frac{4}{\pi^2} \left(\arctan\left(\frac{w^B}{h^B}\right) - \arctan\left(\frac{w^A}{h^A}\right) \right)^2, \quad (4)$$

где w^B и h^B – ширина и высота истинной рамки; w^A и h^A – ширина и высота предсказанной рамки.

Функция потерь Classification Loss отражает способность модели корректно определять класс обнаруженного

объекта. В случае решения задачи детекции Classification Loss измеряет степень уверенности модели в том, что обнаруженный объект действительно принадлежит целевому классу, а не является фоновым элементом [16]. В рассматриваемых архитектурах детекторов применяется функция потерь BCEWithLogitsLoss (Binary Cross-Entropy with Logits Loss), описываемая по

$$L_{BCE} = -[y \cdot \log(\sigma(x)) + (1 - y) \times \log(1 - \sigma(x))], \quad (5)$$

где y – бинарный индикатор принадлежности к классу при $y \in \{0,1\}$; x – выход модели (логит); $\sigma(x)$ – функция сигмоиды, преобразующая логит в вероятность, определяемая по

$$\sigma(x) = \frac{1}{1 + e^{-x}}. \quad (6)$$

Графики функции потерь Classification Loss для HM RT-DETR, YOLOv10 и YOLOv12, рассчитанные на валидационной выборке, представлены ниже (рис. 2).




Рис. 2. Графики функции потерь Classification Loss для HM RT-DETR, YOLOv10 и YOLOv12

Fig. 2. Graphs of the Classification Loss function for the RT-DETR, YOLOv10 and YOLOv12 models

В контексте задач одноклассовой детекции метрика Precision вычисляется для порогового значения confidence threshold, который определяет минимальную вероятность, при которой детекция считается валидной. Метрика Precision определяется по

$$\text{Precision} = \frac{TP}{TP + FP}, \quad (7)$$

где TP – количество корректно обнаруженных объектов целевого класса; FP –

число ложных срабатываний, т. е. случаев, когда модель ошибочно идентифицировала фоновый элемент как объект интереса [17].

Значение метрики принадлежит интервалу от 0 до 1, где 1 соответствует идеальному сценарию отсутствия ложных детекций. Рассмотрим графики метрики Precision для HM RT-DETR, YOLOv10 и YOLOv12, рассчитанные на валидационной выборке ниже (рис. 3).




Рис. 3. Графики оценки качества классификации Precision для HM RT-DETR, YOLOv10 и YOLOv12

Fig. 3. Graphs of the Precision classification quality assessment for the RT-DETR, YOLOv10 and YOLOv12 models

Метрика оценки качества классификации Recall определяется по

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (8)$$

где FN – число пропущенных объектов, т. е. случаев, когда номерной знак присутствовал на изображении, но модель не смогла его идентифицировать [17].

Значение метрики принадлежит интервалу от 0 до 1, где 1 соответствует идеальному сценарию обнаружения всех объектов без исключения. Графики метрики Recall для HM RT-DETR, YOLOv10 и YOLOv12, рассчитанные на валидационной выборке, представлены ниже (рис. 4).




Рис. 4. Графики оценки качества классификации Recall для HM RT-DETR, YOLOv10 и YOLOv12

Fig. 4. Graphs of the Recall classification quality assessment for the RT-DETR, YOLOv10 and YOLOv12 models

Метрика $mAP_{0,5:0,95}$ (mean Average Precision (AP)) представляет собой среднее арифметическое значений пло-

щадей под кривой Precision-Recall для каждого класса при порогах IoU от 0,5 до 0,95 и рассчитывается по

$$mAP_{0,5:0,95} = \frac{(mAP_{0,5} + mAP_{0,55} + mAP_{0,6} + \dots + mAP_{0,95})}{10}, \quad (9)$$

где $mAP_{0,5}$, $mAP_{0,55}$, $mAP_{0,6}$ и т. д. – это значения mAP, рассчитанные для каждого отдельного порога IoU в диапазоне от 0,5 до 0,95 с шагом 0,05; 10 – количество порогов IoU, по которым производится усреднение.

Графики метрики $mAP_{0,5:0,95}$ для НМ RT-DETR, YOLOv10 и YOLOv12, рассчитанные на валидационной выборке, представлены ниже (рис. 5).




Рис. 5. Графики метрики $mAP_{0,5:0,95}$ для НМ RT-DETR, YOLOv10 и YOLOv12

Fig. 5. Graphs of the $mAP_{0,5:0,95}$ metric for the RT-DETR, YOLOv10, and YOLOv12 models

Проведенный сравнительный анализ метрик качества указывает на целесообразность использования НМ YOLOv12 в качестве детектора ГРЗ ТС в предлагаемом гибридном методе. НМ продемонстрировала лучшие результаты по наиболее важным метрикам ($Precision = 0,99$, $Recall = 0,98$ и $mAP_{0,5:0,95} = 0,91$), что свидетельствует о высокой полноте обнаружения ГРЗ ТС при практически полном отсутствии ложных срабатываний. Для реализации

полного цикла обработки видеопотока, включающего не только обнаружение ГРЗ ТС, но и распознавание символов на них, модель детекции была интегрирована с библиотекой оптического распознавания символов EasyOCR, в основе которой лежат глубокие НС, предобученные в т. ч. на кириллических символах.

Рассмотрим блок-схему алгоритма работы гибридного метода распознавания ГРЗ ТС (рис. 6).




Рис. 6. Блок-схема алгоритма работы гибридного метода распознавания ГРЗ

Fig. 6. Block diagram of the algorithm for the recognition of state registration plates

Предлагаемый гибридный метод можно описать следующим образом:

Этап 1. Загрузка кадра из видеопотока.

Этап 2. Инференс НМ YOLO (первичное обнаружение объектов в кадре, в ходе которого предсказанные ОР с показателем уверенности выше порогового значения рассматриваются как кандидаты для последующей проверки наличия целевого объекта).

Этап 3. Проверка присутствия ГРЗ ТС в кадре. Если ГРЗ ТС отсутствует в кадре, то выводится результат «ГРЗ ТС отсутствует в кадре» и происходит переход к следующему кадру видеопотока, в случае присутствия ГРЗ ТС в кадре – переход к этапу 4.

Этап 4. Выбор ОР с наивысшим значением показателя уверенности.

Этап 5. Обрезка области вокруг ГРЗ ТС с заданным отступом PAD_RATIO (PAD_RATIO = 0,15).

Этап 6. Многовариантная предобработка вырезанной области для OCR. На данном этапе выполняется последовательное конвейерное преобразование вырезанного изображения, результатом которого являются 9 отдельных изображений, полученных на разных этапах конвейера.

Этап 6.1. Преобразование в оттенки серого – процедура, исключаяющая влияние цветовой информации на последующие этапы.

Этап 6.2. Адаптивное масштабирование. Если высота изображения h менее 100 пикселей, то к нему применяется увеличение с коэффициентом $scale$ с использованием бикубической интерполяции по

$$scale = \begin{cases} 1, & \text{если } h \geq 100, \\ \max\left(2, \frac{120}{h}\right), & \text{если } h < 100. \end{cases} \quad (10)$$

При этом порог масштабирования (100 пикселей по высоте) соответствует минимальному разрешению, при котором стандартные шрифты номерных знаков сохраняют распознаваемую структуру.

Этап 6.3. Улучшение контраста методом CLAHE (Contrast Limited Adaptive Histogram Equalization). Для компенсации неравномерного освещения и низкого контраста применяется метод адаптивного выравнивания гистограммы с ограничением контраста. Параметры алгоритма эмпирически оптимизированы: порог ограничения гистограммы clipLimit = 2,5 и размер локальной области tileSize = (8,8).

Этап 6.4. Повышение резкости. Применяется для коррекции эффектов расфокусировки и движения с использованием метода нерезкой маски (Unsharp Masking) в комбинации с гауссовым размытием.

Этап 6.5. Подавление шума. Применяется для подавления аддитивного шума, характерного для съемки в условиях низкой освещенности, с использованием алгоритма нелокального среднего (Non-Local Means Denoising), позволяющего корректно сохранять структурные детали (края символов).

Этап 6.6. Адаптивная бинаризация. На данном этапе сегментация текста выполняется с помощью адаптивного порогового преобразования по методу Гаусса с размером окна 15 пикселей и константой сдвига равной 5.

Этап 6.7. Морфологическое закрытие. Для устранения мелких разрывов в символах, которые могут возникать вследствие бинаризации или дефектов поверхности ГРЗ ТС, применяется морфологическое закрытие. Морфологиче-

ское закрытие – это комбинация дилатации и эрозии, применяемая последовательно. Оно используется для того, чтобы закрыть маленькие отверстия и соединить близлежащие объекты. Дилатация – это операция, которая увеличивает область белых пикселей на изображении. При применении этой операции к изображению каждый пиксель обходится структурирующим элементом (ядром). Структурирующий элемент – это небольшая матрица (ядро), которая используется в морфологической обработке изображений для определения способа изменения этих изображений. При попадании пикселя в центр области, определяемой ядром, он заменяется значением максимума в этой области. Эрозия – это обратная операция дилатации, она уменьшает объекты на изображении. При применении эрозии каждый пиксель заменяется минимумом в области, определяемой ядром. Пиксель остается белым только в том случае, если все пиксели в области под ядром также белые¹.

Сначала изображение подвергается дилатации (11), а затем – эрозии (12) с использованием одного и того же значения ядра (размер ядра (kernel) = 2×2 пикселя). Морфологическое закрытие можно описать с помощью (13):

$$D(I) = \max_{\delta \in \text{kernel}} I(x + \delta_x, y + \delta_y), \quad (11)$$

$$E(I) = \min_{\delta \in \text{kernel}} I(x + \delta_x, y + \delta_y), \quad (12)$$

$$C(I) = E(D(I)) = E\left(\max_{\delta \in \text{kernel}} I(x + \delta_x, y + \delta_y)\right), \quad (13)$$

где I – это исходное изображение; (x, y) – координаты центра пикселя; δ – смещение по элементам ядра; kernel – ядро [18].

Этап 6.8. Бинаризация с помощью метода Оцу с предварительным применением фильтра Гаусса (размер ядра (kernel) = 5×5).

Этап 6.9. Инверсия – создание инвертированных версий бинаризованных изображений из этапов 6.6 и 6.8.

Этап 6.10. Гамма-коррекция – коррекция яркости с целью выполнить умеренное осветление изображения без потери информации в светлых участках ($\gamma = 1,3$).

Этап 6.11. Формирование вариантов для обработки. На данном этапе происходит генерация девяти вариантов альтернативных представлений исходного изображения для последующей обработки: original/upscaled – базовое изображение в градациях серого; clahe – вариант с улучшенным локальным контрастом; sharpened – изображение с повышенной резкостью; denoised – версия с подавленным шумом; binary – адаптивно бинаризованное изображение с морфологической обработкой; otsu – бинаризованное изображение по методу Оцу; inverted – инвертированный бинаризованный вариант; otsu_inv – инвертированное бинаризованное изображение по методу Оцу; gamma – изображение с коррекцией яркости.

Этап 7. Применение OCR с ограниченным набором символов для каждого из девяти вариантов предобработки. На данном этапе выполняется распознавание символов на каждом из девяти по-

¹ Киселев А. В., Филист С. А., Шаталова О. В. Методы обработки, анализа и классификации медико-биологических сигналов и данных: учебное пособие. Старый Оскол: Тонкие наукоемкие технологии, 2023. 328 с.

лученных вариантов предобработки с помощью EasyOCR с установленным ограничением набора допустимых для распознавания символов. Для уменьшения вероятности ошибок OCR набор допустимых символов ограничен только теми символами, которые допустимы в российских ГРЗ ТС, а именно цифрами от 0 до 9 и кириллическими буквами А, В, Е, К, М, Н, О, Р, С, Т, У, Х, а также их аналогами в латинском алфавите.

Этап 8. Форматирование распознанного текста, включающее в себя перевод в верхний регистр и замену похожих символов в соответствии с таблицей замен.

Этап 9. Проверка соответствия формату. На данном этапе производится проверка соответствия формата распознанного текста формату российского ГРЗ ТС (буква, три цифры, две буквы, две или три цифры). Также на данном этапе происходит исправление типичных ошибок распознавания, например, если на месте буквы распознана цифра или наоборот (например, «В» и «8»), замена символов в определенных пози-

циях, если это необходимо для соответствия формату. Среди всех вариантов выбирается лучший по значению уверенности результат, который соответствует формату номера, либо, если таких нет, то лучший по значению уверенности результат. Если результат полностью соответствует формату, то он сохраняется как валидный, в случае несоответствия формату – сохраняется резервный вариант с наивысшим значением показателя уверенности.

Этап 10. Визуализация лучшего результата OCR. На данном этапе происходит визуализация предсказанных ОР на исходном изображении, создание коллажа из исходного изображения с предсказанными ОР и лучшего результата OCR, сохранение коллажа и запись данных в CSV-файл.

Результаты и их обсуждение

Рассмотрим пример многовариантной предобработки вырезанной области для генерации девяти вариантов альтернативных представлений исходного изображения (рис. 7).



Рис. 7. Пример многовариантной предобработки вырезанной области для генерации девяти вариантов альтернативных представлений исходного изображения

Fig. 7. An example of multivariate preprocessing of a cut-out area to generate nine alternative representations of the original image

На рисунке 8 представлены результаты тестирования гибридного метода распознавания ГРЗ ТС на тестовом наборе данных. При тестировании ис-

пользовались кадры, сделанные при различных уровнях освещения и различной степени зашумленности.



Рис. 8. Результаты тестирования реализованного гибридного метода распознавания ГРЗ ТС

Fig. 8. Results of testing the implemented hybrid method of license plate recognition

Оценка эффективности OCR-метода оценивалась путем сравнения распознанного текста с эталонным с использованием количественных метрик, таких как CRR (Character Recognition Rate), определяемой по (14) и PRR (Plate Recognition Rate), являющейся отраслевым аналогом метрики WRR (Word Recognition Rate), определяемой по (15).

$$CRR = \frac{\sum N_{\text{total}} - (\sum S + \sum D + \sum I)}{\sum N_{\text{total}}}, \quad (14)$$

где N_{total} – общее количество символов во всех эталонных номерах тестового набора данных; $\sum S + \sum D + \sum I$ – суммарное количество замен (S), пропусков (D) и лишних символов (I) по всему тестовому набору данных.

$$PRR = \frac{P_{\text{correct}}}{P_{\text{total}}}, \quad (15)$$

где P_{correct} – общее количество номерных пластин, где каждый символ совпал с эталоном (CRR для этого номера равен 1); P_{total} – общее количество номерных пластин в тестовой выборке.

Значения данных метрик у современных САР ГРЗ ТС, в т. ч. коммерческих, лежат в диапазонах от 96,0 до 100,0 % для CRR и от 92,2 до 99,9 % для PRR [19]. Полученные на тестовом наборе данных значения метрик CRR и PRR для предложенного гибридного метода распознавания ГРЗ ТС равны 99,0 и 98,5 % соответственно. Попадание значений данных метрик в верхние границы представленных выше диапазонов указывает на конкурентоспособность предложенного гибридного метода распознавания ГРЗ ТС.

Выводы

В рамках проведенного исследования предложен и апробирован гибридный метод распознавания ГРЗ ТС на основе конвейерной архитектуры YOLOv12 – EasyOCR. Был синтезирован уникальный обучающий НД, сформированный на основе видеоматериалов, полученных с камер наблюдения, установленных на автомобильных дорогах и объектах транспортной инфраструктуры. Для обеспечения макси-

мальной вариативности данных для формирования НД были использованы записи, сделанные при различных условиях освещенности и погоды, включая дождь, снег и туман, которые вносят естественные искажения и шумы. При покадровой разбивке собранных видеофрагментов осуществлялась фильтрация полученных изображений (из общего потока исключались кадры с чрезмерным размытием или полным перекрытием ГРЗ ТС, не несущие полезной информации для обучения НМ).

Проведен сравнительный анализ детекторов (YOLOv10, YOLOv12, RT-DETR), подтверждающий целесообразность использования модели YOLOv12, продемонстрировавшей наилучшие показатели наиболее важных метрик (Precision = 0,99, Recall = 0,98 и $mAP_{0,5:0,95} = 0,91$).

Разработан многовариантный конвейер предобработки изображений для OCR, выполняющий последовательное преобразование вырезанного изображе-

ния, включающее адаптивное масштабирование, улучшение контраста, шумоподавление и морфологические операции, позволяющий повысить устойчивость распознавания к неконтролируемым условиям внешней среды. Результатом многовариантной предобработки вырезанной области для OCR являются 9 отдельных изображений, полученных на разных этапах конвейера.

Для минимизации типичных ошибок OCR был использован ограниченный набор допустимых символов и реализован алгоритм проверки соответствия российскому формату ГРЗ ТС.

Экспериментальная валидация предложенного гибридного метода распознавания ГРЗ ТС подтвердила его высокую эффективность (получены значения количественных метрик $mAP_{0,5:0,95} = 0,91$, CRR = 99,0 %, PRR = 98,5 %), что свидетельствует о способности метода к обеспечению устойчивого распознавания в условиях реальной эксплуатации.

Список литературы

1. Ma Y., Mészáros F. Review of Urban Access Regulations from the Sustainability Viewpoint // *Urban Science*. 2024. Vol. 8, N 2. P. 29 1–18. <https://doi.org/10.3390/urbansci8020029>.
2. Smart Parking Systems: Reviewing the Literature, Architecture and Ways Forward / C. Biyik, Z. Allam, G. Pieri, D. Moroni, M. Fraifer, E. O'Connell, S. Olariu, M. Khalid // *Smart Cities*. 2021. Vol. 4. P. 623–642. <https://doi.org/10.3390/smartcities4020032>.
3. Human Factor Analysis of the Railway Traffic Operators / A. Janota, R. Pirník, J. Ždánsky, P. Nagy // *Machines*. 2022. Vol. 10, N 9. P. 820. <https://doi.org/10.3390/machines10090820>.
4. Rai R., Shitole S., Sutar P., Kaldhone S., Jadhav J. D. Automatic License Plate Recognition Using YOLOv4 and Tesseract OCR // *International Journal of Innovative Research in Computer and Communication Engineering*. 2022. Vol. 10, N 3. P. 1656. <https://doi.org/10.15680/IJIRCCE.2022.1003089>.

5. Automated License Plate Recognition: A Survey on Methods and Techniques / J. Shashirangana, H. Padmasiri, D. Meedeniya, C. Perera // IEEE Access. 2021. Vol. 9. P. 11203–11225. <https://doi.org/10.1109/ACCESS.2020.3047929>.

6. Брежнев А. В., Томакова Р. А., Брежнева А. Н. Информационная система мониторинга на основе интеллектуальной классификации изображений видеопотоков // Информационное общество. 2023. № 5. С. 134–142. https://doi.org/10.52605/16059921_2023_05_134.

7. Saha U., Saha B., Imran M. A Weather-Adaptive Convolutional Neural Network Framework for Better License Plate Detection // Sensors. 2024. Vol. 24, N 23. P. 7841. <https://doi.org/10.3390/s24237841>.

8. Automated License Plate Recognition for Resource-Constrained Environments / H. Padmasiri, J. Shashirangana, D. Meedeniya, O. Rana, C. Perera // Sensors. 2022. Vol. 22, N 4. P. 1434. <https://doi.org/10.3390/s22041434>.

9. Бобырь М. В., Емельянов С. Г., Милостная Н. А. Разработка программной модели для распознавания символов на номерных знаках автомобиля // Искусственный интеллект и принятие решений. 2025. № 2. С. 142–156. <https://doi.org/10.14357/20718594250212>. EDN KNUYFN.

10. License plate recognition system for complex scenarios based on improved YOLOv5s and LPRNet / X. Wang, M. Wang, H. Guo, J. Li, X. Wang, Y. Zhang // Scientific Reports. 2025. Vol. 15. P. 10052. <https://doi.org/10.1038/s41598-025-18311-4>.

11. Automatic Vehicle License Number Plate Recognition System Using Tesseract OCR & OpenCV / K. N. Chandan, K. Sahana, M. Tharun Gowda, S. M. Darshan, M. Arunkumar // International Advanced Research Journal in Science, Engineering and Technology. 2025. Vol. 12, N 5. <https://doi.org/10.17148/IARJSET.2025.12590>.

12. Sainui J., Thepporn C., Chusuwan P. Thai License Plate Recognition using SSD MobileNet and EasyOCR // Proceedings of the 2024 6th International Conference on Image Processing and Machine Vision (IPMV '24). New York: ACM, 2024. P. 36–41. <https://doi.org/10.1145/3645259.3645266>.

13. License plate detection using YOLO v4 / R. Rathi, A. Sharma, N. Baghel, P. Channe, S. Barve, S. Jain // International Journal of Health Sciences. 2022. Vol. 6, N S2. P. 9456–9462. <https://doi.org/10.53730/ijhs.v6nS2.7475>.

14. 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>.

15. Stodt J., Reich C., Clarke N. Unified intersection over union for explainable artificial intelligence // Intelligent Systems and Applications. 2024. Vol. 2. P. 758–770. https://doi.org/10.1007/978-3-031-47724-9_50.

16. Generalized Focal Loss: Towards Efficient Representation Learning for Dense Object Detection / X. Li, C. Lv, W. Wang, G. Li, L. Yang, J. Yang // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2023. Vol. 45, N 3. P. 3139–3153. <https://doi.org/10.1109/TPAMI.2022.3180392>.
17. Оценка эффективности модели глубокого обучения на основе EfficientNetB3 для дифференциальной диагностики стадий болезни Альцгеймера / А. В. Киселев, Е. А. Кулешова, М. О. Таныгин, П. М. Свиных, И. А. Халин // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2025. Т. 15, № 4. С. 192–210. <https://doi.org/10.21869/2223-1536-2025-15-4-192-210>.
18. Метод контроля доступа и мониторинга соблюдения техники безопасности на энергетических хозяйствах предприятий на основе конвейерной нейросетевой модели / А. В. Киселев, Н. С. Брусенцев, Е. А. Кулешова, Д. А. Ермаков // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2024. Т. 14, № 4. С. 28–46. <https://doi.org/10.21869/2223-1536-2024-14-4-28-46>.
19. Advancing Multinational License Plate Recognition Through Synthetic and Real Data Fusion: A Comprehensive Evaluation / R. Laroca, V. Estevam, G. J. P. Moreira, R. Minetto, D. Menotti // *IET Intelligent Transport Systems*. 2025. Vol. 19, N 1. P. e70086. <https://doi.org/10.1049/itr2.70086>.

References

1. Ma Y., Mészáros F. Review of Urban Access Regulations from the Sustainability Viewpoint. *Urban Science*. 2024;8(2):1-18. <https://doi.org/10.3390/urbansci8020029>.
2. Biyik C., Allam Z., Pieri G., Moroni D., Fraifer M., O'Connell E., Olariu S., Khalid M. Smart Parking Systems: Reviewing the Literature, Architecture and Ways Forward. *Smart Cities*. 2021;4:623-642. <https://doi.org/10.3390/smartcities4020032>.
3. Janota A., Pirník R., Ždánsky J., Nagy P. Human Factor Analysis of the Railway Traffic Operators. *Machines*. 2022;10(9):820. <https://doi.org/10.3390/machines10090820>.
4. Rai R., Shitole S., Sutar P., Kaldhone S., Jadhav J.D. Automatic License Plate Recognition Using YOLOv4 and Tesseract OCR. *International Journal of Innovative Research in Computer and Communication Engineering*. 2022;10(3):1656. <https://doi.org/10.15680/IJIRCC.2022.1003089>.
5. Shashirangana J., Padmasiri H., Meedeniya D., Perera C. Automated License Plate Recognition: A Survey on Methods and Techniques. *IEEE Access*. 2021;9:11203-11225. <https://doi.org/10.1109/ACCESS.2020.3047929>.
6. Brezhnev A.V., Tomakova R.A., Brezhneva A.N. Information monitoring system based on intelligent classification of video stream images. *Informatsionnoye obshchestvo = Information Society*. 2023;5:134-142. (In Russ.) https://doi.org/10.52605/16059921_2023_05_134.

7. Saha U., Saha B., Imran M.A Weather-Adaptive Convolutional Neural Network Framework for Better License Plate Detection. *Sensors*. 2024;24(23):7841. <https://doi.org/10.3390/s24237841>.

8. Padmasiri H., Shashirangana J., Meedeniya D., Rana O., Perera C. Automated License Plate Recognition for Resource-Constrained Environments. *Sensors*. 2022;22(4):1434. <https://doi.org/10.3390/s22041434>.

9. Bobyr M.V., Emelyanov S.G., Milostnaya N.A. Development of a software model for character recognition on vehicle license plates. *Iskusstvennyy intellekt i prinyatiye resheniy = Artificial Intelligence and Decision Making*. 2025;(2):142-156. (In Russ.) <https://doi.org/10.14357/20718594250212>.

10. Wang X., Wang M., Guo H., Li J., Wang X., Zhang Y. License plate recognition system for complex scenarios based on improved YOLOv5s and LPRNet. *Scientific Reports*. 2025;15:10052. <https://doi.org/10.1038/s41598-025-18311-4>.

11. Chandan K.N., Sahana K., Tharun Gowda M., Darshan S.M., Arunkumar M. Automatic Vehicle License Number Plate Recognition System Using Tesseract OCR & OpenCV. *International Advanced Research Journal in Science, Engineering and Technology*. 2025;12(5). <https://doi.org/10.17148/IARJSET.2025.12590>.

12. Sainui J., Thepporn C., Chusuwan P. Thai License Plate Recognition using SSD MobileNet and EasyOCR. In: *Proceedings of the 2024 6th International Conference on Image Processing and Machine Vision (IPMV '24)*. New York: ACM; 2024. P. 36-41. <https://doi.org/10.1145/3645259.3645266>.

13. Rath R., Sharma A., Baghel N., Channe P., Barve S., Jain S. License plate detection using YOLO v4. *International Journal of Health Sciences*. 2022;6(S2):9456-9462. <https://doi.org/10.53730/ijhs.v6nS2.7475>.

14. Kiselev A.V., Brusentsev N.S., Kuleshova E.A. Analysis of the efficiency of using two-stage neural network models for early detection of forest fires. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravleniye, vychislitel'naya tekhnika, informatika. Meditsinskoye priborostroyeniye = Proceedings of the Southwest State University. Series: Management, Computer Engineering, Computer Science. Medical Instrumentation*. 2024;14(1):8-23. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-1-8-23>.

15. Stodt J., Reich C., Clarke N. Unified intersection over union for explainable artificial intelligence. *Intelligent Systems and Applications*. 2024;2:758-770. https://doi.org/10.1007/978-3-031-47724-9_50.

16. Li X., Lv C., Wang W., Li G., Yang L., Yang J. Generalized Focal Loss: Towards Efficient Representation Learning for Dense Object Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2023;45(3):3139-3153. <https://doi.org/10.1109/TPAMI.2022.3180392>.

17. Kiselev A.V., Kuleshova E.A., Tanygin M.O., Svinukhov P.M., Khalin I.A. Evaluation of the effectiveness of a deep learning model based on EfficientNetB3 for differential diagnosis of Alzheimer's disease stages. *Izvestiya Yugo-Zapadnogo gosudarstvennogo uni-*

versiteta. *Seriya: Upravleniye, vychislitel'naya tekhnika, informatika. Meditsinskoye priborostroyeniye = Proceedings of the Southwest State University. Series: Management, Computer Engineering, Computer Science. Medical Instrumentation.* 2025;15(4):192-210. (In Russ.) <https://doi.org/10.21869/2223-1536-2025-15-4-192-210>.

18. Kiselev A.V., Brusentsev N.S., Kuleshova E.A., Ermakov D.A. Method of access control and safety monitoring at energy facilities of enterprises based on a conveyor neural network model. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravleniye, vychislitel'naya tekhnika, informatika. Meditsinskoye priborostroyeniye = Proceedings of the South-West State University. Series: Management, Computer Engineering, Computer Science. Medical Instrumentation.* 2024;14(4):28-46. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-4-28-46>.

19. Laroca R., Estevam V., Moreira G.J.P., Minetto R., Menotti D. Advancing Multinational License Plate Recognition Through Synthetic and Real Data Fusion: A Comprehensive Evaluation. *IET Intelligent Transport Systems.* 2025;19(1):e70086. (In Russ.) <https://doi.org/10.1049/itr2.70086>.

Информация об авторах / Information about the Authors

Киселев Алексей Викторович, кандидат технических наук, 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, Cand. Sci. (Engineering), Associate Professor at the Department Computers, 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, Cand. Sci. (Engineering), Associate Professor at the Department Information Security, Southwest State University, Kursk, Russian Federation, e-mail: lena.kuleshova.94@mail.ru, ORCID: 0000-0002-8270-564X

Таныгин Максим Олегович, доктор технических наук, доцент, профессор кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: tanygin@yandex.ru, ORCID: 0000-0002-4099-1414

Maxim O. Tanygin, Dr. Sci. (Engineering), Associate Professor, Professor at the Department Information Security, Southwest State University, Kursk, Russian Federation, e-mail: tanygin@yandex.ru, ORCID: 0000-0002-4099-1414

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, Cand. Sci. (Engineering), Associate Professor, Associate Professor at the Department 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/10.21869/2223-1536-2026-16-2-122-149>



УДК 004.891.3, 004.932

Двухконтурная валидация нейросетевой сегментации пневмоторакса в условиях дисбаланса классов

А. В. Косинов¹ ✉, Р. А. Крупчатников¹, В. В. Серебровский¹,
М. А. Ефремов¹, Д. С. Кондрашов¹

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

✉ e-mail: skosinka@yandex.ru

Резюме

Целью исследования является разработка методики клинически ориентированного обучения, валидации и выбора нейросетевой модели сегментации пневмоторакса на рентгенограммах органов грудной клетки при выраженном дисбалансе классов и необходимости контролируемого ограничения ложных срабатываний в составе систем поддержки принятия решений.

Методы. В работе предложена двухконтурная схема оценивания качества сегментации, включающая технический контур, служащий для контроля сходимости обучения по значениям функции потерь и сырым показателям, а также клинический контур для оценки бинаризованных масок после фиксированной постобработки результатов. Для каждой эпохи обучения выполняется перебор порога бинаризации; рабочая точка считается допустимой при выполнении клинических ограничений, после чего итоговая эпоха выбирается как максимизирующая индекс Дайса на положительных случаях среди допустимых решений. Сегментатор реализован на основе архитектуры U-Net++ и обучается по двухэтапной схеме с повышением пространственного разрешения с использованием гибридной функции потерь.

Результаты. На клинически репрезентативном материале – наборе разработки SIIM-ACR – финальная конфигурация, выбранная по протоколу на 15-й эпохе, обеспечила индекс Дайса на положительных случаях = 0,753 (95% ДИ 0,734–0,771) при частоте ложноположительных срабатываний = 0,177 (95% ДИ 0,158–0,197) и чувствительности на уровне изображения = 0,948 и ощутимо превзошла базовую конфигурацию.

Заключение. Предложенная методика двухконтурной валидации и критериального выбора эпохи в допустимой области обеспечивает воспроизводимый контроль компромисса между качеством сегментации на патологических снимках и частотой ложных тревог на снимках без патологии, снижая риск выбора субоптимальной модели при ориентировании только на минимум функции потерь. Полученные результаты подтверждают целесообразность использования разработанного протокола при проектировании сегментационных модулей для систем поддержки принятия решений в задачах лучевой диагностики.

Ключевые слова: сегментация медицинских изображений; пневмоторакс; рентгенография органов грудной клетки; клинический контур; валидация; системы поддержки принятия решений.

Финансирование: Работа выполнена в рамках реализации программы развития ФГБОУ ВО «Юго-Западный государственный университет» проекта «Приоритет-2030».

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

Для цитирования: Косинов А. В., Крупчатников Р. А., Серебровский В. В., Ефремов М. А., Кондрашов Д. С. Двухконтурная валидация нейросетевой сегментации пневмоторакса в условиях дисбаланса классов // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 122–149. <https://doi.org/10.21869/2223-1536-2026-16-4-122-149>.

Поступила в редакцию 11.04.2026

Подписана в печать 10.05.2026

Опубликована 30.06.2026

© Косинов А. В., Крупчатников Р. А., Серебровский В. В., Ефремов М. А., Кондрашов Д. С., 2026

Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026;16(2):122–149

Two-loop validation of neural network-based pneumothorax segmentation under class imbalance

Aleksandr V. Kosinov¹ ✉, Roman A. Krupchatnikov¹, Vadim V. Serebrovsky¹,
Mihail A. Efremov¹, Dmitry S. Kondrashov¹

¹ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: skosinka@yandex.ru

Abstract

The purpose of the research is to develop a clinically oriented methodology for training, validating, and selecting a neural network model for pneumothorax segmentation on chest radiographs under severe class imbalance and the need for controlled limitation of false positive alerts in clinical decision support systems.

Methods. We propose a two-loop segmentation quality assessment framework comprising a technical loop for monitoring training convergence using the loss function values and raw metrics, and a clinical loop for evaluating binarized masks after a fixed post-processing pipeline. For each training epoch, a binarization threshold is swept; an operating point is deemed acceptable if predefined clinical constraints are satisfied. The final epoch is then selected as the one that maximizes Dice index on positive cases among all acceptable solutions. The segmenter is implemented using a U-Net++ architecture and trained via a two-stage scheme with increasing spatial resolution, using a hybrid loss function.

Results. On clinically representative data SIIM-ACR development set, configuration selected by the protocol achieved Dice index on positive cases = 0,753 (95% CI 0,734–0,771) with false positive rate = 0,177 (95% CI 0,158–0,197) and image-level sensitivity = 0,948, and substantially outperformed the baseline configuration.

Conclusion. The proposed two-loop validation methodology and constraint-based epoch selection within the admissible region provide reproducible control of the trade-off between segmentation quality on pathological images and the false alarm rate on non-pathological images, reducing the risk of selecting a suboptimal model when relying solely on minimum loss. The results support the use of the developed protocol in designing segmentation modules for decision support systems in radiological imaging tasks.

Keywords: medical image segmentation; pneumothorax; chest x-ray; clinical circuit; validation; decision support systems.

Funding: The work was carried out within the framework of the Priority-2030 project development program of the Federal State Budgetary Educational Institution of Higher Education "Southwest State University."

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

For citation: Kosinov A.V., Krupchatnikov R.A., Serebrovsky V.V., Efremov M.A., Kondrashov D.S. Two-loop validation of neural network-based pneumothorax segmentation under class imbalance. *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(2):122–149. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-122-149>.

Received 11.04.2026

Accepted 10.05.2026

Published 30.06.2026

Введение

Рентгенография органов грудной клетки остаётся одним из наиболее часто выполняемых исследований и обычно является первым методом визуализации при симптомах со стороны лёгких благодаря доступности, скоро-

сти и низкой лучевой нагрузке [1]. Пневмоторакс – потенциально жизнеугрожающее состояние, требующее в некоторых случаях неотложного вмешательства, однако выявление пневмоторакса на рентгеновских снимках может быть затруднено даже для опытных

врачей, особенно в сложных случаях и при наложении анатомических структур и наличии медицинских устройств, способных маскировать признаки [2].

Системы поддержки принятия решений (СППР) на базе глубинного обучения демонстрируют высокий потенциал в задачах сегментации [3]. Однако при переходе от исследовательских задач к клинической практике возникает ряд методологических проблем:

1. Нечувствительность стандартных метрик. Коэффициент Дайса для бинарной сегментации является математическим эквивалентом F1-меры, что определяет его специфическое поведение при оценке несбалансированных данных [4]. При этом данная метрика в явном виде не учитывает истинно-отрицательные результаты, создавая слепые зоны при валидации моделей скрининга [5]. Следовательно, правильное оценивание эффективности систем требует явной фиксации определения метрики при использовании конкретных схем агрегаций, которые вводят вклад отрицательных случаев или фоновых классов косвенно. На практике в задачах с выраженным преобладанием отрицательных изображений стандартные подходы часто приводят к скрытым искажениям оценок сегментации [6]. Как показывают современные консенсусные рекомендации, при редкой патологии агрегация метрик по всей выборке становится серьезным источником методологических артефактов [4]. В частности, детальный анализ валидационных пайплайнов выявляет как минимум два распространенных сценария неадекватной оценки качества моделей [5]. Во-первых, во многих реализациях

рассчитывается средний индекс Дайса по снимкам, где для отрицательных случаев с пустой истинной маской и пустым предсказанием метрике присваивается значение индекса Дайса = 1 [5]. При большом числе отрицательных снимков при обучении среднее значение такой метрики может быть завышено и перестает отражать качество сегментации на патологических примерах. Простейший контрпример: рассмотрим три снимка, из которых два – с отсутствующей патологией и один – с патологией. Если на обоих «здоровых» модель предсказывает пустую маску, а на снимке с патологией ошибается, то при соглашении индекс Дайса на здоровых = 1 среднее значение составит 0,67, хотя клинически значимое качество работы модели на патологии неудовлетворительно, при том, что это самый важный параметр. Во-вторых, при использовании усреднения по классам в постановках, где явно присутствует фон как отдельный класс, в итоговую величину может входить индекс Дайса фоновых классов, который может оказаться близким к 1 на большинстве изображений. Такое усреднение также формирует иллюзию высокого качества, хотя ключевой интерес представляет сегментация патологического региона. Для устранения этих эффектов и методических неоднозначностей в настоящем исследовании предлагается подход с разделением метрик по подмножествам негативных и позитивных случаев, а также вводится понятие клинического контура оценки, позволяющего интерпретируемо контролировать компромисс между чувствительностью и специфичностью.

2. Конфликт чувствительности и специфичности. Агрессивная оптимизация сегментатора для поиска мелких очагов должна сопровождаться контролем ложноположительных срабатываний, поскольку в скрининговом режиме цена ложноположительных срабатываний выражается не только в метриках, но и в росте числа дообследований, перегрузке клинического контура и снижении доверия к СППР [7].

3. Критерий остановки обучения. Стандартная практика выбора рабочей точки по минимуму функции потерь на валидационном наборе часто оказывается несостоятельной в медицинских задачах [5]. Это обусловлено тем, что для преодоления дисбаланса классов применяются специализированные целевые функции, чья динамика расходится с поведением прямых метрик качества [8]. Например, сложные агрессивные функции потерь, такие как Focal или Tversky loss, формируют собственные траектории сходимости, слабо коррелирующие с коэффициентом Дайса на поздних этапах обучения [9]. Это делает классический критерий «минимум валидационных потерь» недостаточным для выбора итоговой модели, требуя введения внешних клинических ограничений для определения оптимальной рабочей точки [10].

Следует отметить, что задачи анализа рентгенограмм грудной клетки имеют серьезную отечественную исследовательскую базу: в частности, успешно применялись алгоритмы обнаружения патологий на основе анализа локальных окон [11]. Дополнительно были разработаны методы параметрического моделирования мор-

фологических образований непосредственно на диагностических снимках [12]. Эти классические подходы послужили фундаментом для создания комплексных математических моделей, интегрируемых в интеллектуальные системы анализа флюорограмм [13]. Классические методы сегментации биомедицинских изображений на основе градиентных операторов также продолжают использоваться как базовый инструментальный аппарат и историческая основа для последующих нейросетевых решений [14]. Отдельный интерес представляют патентные решения по автоматической сегментации флюорограмм грудной клетки, подтверждающие прикладную востребованность направления¹. В смежных задачах лучевой диагностики описаны автоматизированные системы классификации рентгенограмм (например, молочной железы), что дополнительно подтверждает актуальность встраивания алгоритмов в диагностические рабочие процессы [15].

Помимо узких задач лучевой диагностики, нейросетевые алгоритмы активно внедряются в архитектуру комплексных медицинских классификаторов риска [16]. Значительный потенциал в этой области демонстрируют гибридные модели, адаптированные для анализа кардиологических патологий [17]. Подобные системы позволяют прогнозировать состояние сердечно-

¹ Способ автоматической сегментации флюорограмм грудной клетки больных пневмонией: пат. 2629629 Рос. Федерация. № 2016132680; заявл. 09.08.16; опубл. 30.08.17, Бюл. № 25.

сосудистой системы на основе автоматизированной обработки многомерных биосигналов [18]. Параллельно развиваются методы построения предиктивных моделей медицинского риска с использованием сверточных нейронных сетей и синергетических каналов [19]. Отдельным важным направлением выступает применение мультимодальных нейросетевых классификаторов для оценки функционального состояния дыхательной системы [20]. Для задач инженерного прототипирования и воспроизводимого проектирования нейросетевых моделей используются специализированные программные средства интерактивного построения моделей нейронных сетей¹.

Практически значимым направлением являются многозадачные постановки (одновременная детекция, сегментация и классификация), активно используемые в прикладных медицинских сценариях [21].

Несмотря на то, что задачи классической сегментации флюорограмм широко представлены как в отечественной, так и в зарубежной литературе, вопросы интерпретируемой валидации в условиях дисбаланса остаются нераскрытыми.

Целью исследования является разработка методики клинически ориентированного обучения, валидации и выбора нейросетевой модели сегментации пневмоторакса на рентгенограммах органов грудной клетки при выраженном дисбалансе классов и необходимости

контролируемого ограничения ложных срабатываний в составе систем поддержки принятия решений.

Материалы и методы

Набор данных и предварительная обработка

Экспериментальное исследование выполнено на открытом наборе данных SIIM-ACR Pneumothorax Segmentation². Набор включает в себя рентгенограммы грудной клетки человека в формате DICOM (медицинский стандарт для радиограмм) и маски патологий в формате RLE.

Формирование выборки: для воспроизводимости результатов и предотвращения утечки данных был разработан и реализован иерархический протокол разделения данных. Разбиение выполнялось по идентификатору PatientID. В текущей выгрузке набора SIIM-ACR данный идентификатор является уникальным на каждый снимок, поэтому разбиение эквивалентно разбиению по изображениям без пересечения идентификаторов между обучением, валидацией и отложенной выборкой. Для компенсации ограничения применяются бутстреп-доверительные интервалы и одинарная финальная оценка на отложенной выборке после заморозки протокола.

Итоговая статистика разбиения представлена ниже (табл. 1)

¹ Программа для интерактивного создания модели нейронной сети (NetModel): а.с. 2023685902 Рос. Федерация. № 2023683638; заявл. 08.11.23; опубл. 30.11.23.

² SIIM-ACR Pneumothorax Segmentation // Kaggle. URL: <https://www.kaggle.com/competitions/siim-acr-pneumothorax-segmentation> (дата обращения: 18.03.2026).

Таблица 1. Статистика разбиения набора данных**Table 1.** Dataset split statistics

Параметр / Metric	Значение / Value	Описание / Description
Всего снимков	10675	Общее количество уникальных рентген снимков грудной клетки человека
Позитивные случаи	2379	Снимки с подтвержденным пневмотораксом
Отрицательные случаи	8296	Снимки без признаков патологии
Выборка для разработки	9074	Обучающая и валидационная выборка, 85% от общего объема
Отложенная выборка	1601	Независимый тестовый набор, 15% от общего объема
Доля положительных случаев в выборках	~22,3%	Целевой баланс классов в выборках

Процесс разделения состоял из двух этапов с сохранением стратификации по целевому классу, доля снимков с подтвержденным пневмотораксом стремилась к ~22,3% в каждой выборке.

Шаг 1: выделение отложенной тестовой выборки. Из общего массива данных была выделена независимая слепая выборка, составляющая 15% от общего числа снимков (всего в выборке 1601 снимок, 357 позитивных случаев, 1244 отрицательных случая). Данная выборка была полностью изолирована от процесса обучения, подбора гиперпараметров и выбора архитектуры. Она использовалась однократно после фиксации протокола выбора рабочей эпохи на наборе разработки исключительно для финальной оценки качества итоговой модели.

Шаг 2: оставшиеся 85% данных (9074 снимка) составили набор для разработки системы и подбора гиперпараметров. Для организации перекрестной проверки на этом наборе данных был применен алгоритм Stratified Group K-Fold при $k = 5$ с группировкой по PatientID. Поскольку в текущей выгруз-

ке PatientID уникален на снимок, данный метод обеспечивает равномерное распределение классов во всех K-Fold подвыборках без пересечения идентификаторов.

Разбиение фиксировалось в виде метаданных и статических файлов. Данный подход обеспечивает полную детерминированность экспериментов. Обучение, выбор рабочей точки, подбор гиперпараметров делались исключительно на наборе для разработки, без доступа к отложенной выборке.

Обработка пропусков: снимки без аннотированной патологии (здоровые пациенты) рассматриваются как имеющие «нулевую маску» через представление в нулевом тензоре. Исключение таких снимков из валидации недопустимо, так как они формируют базу для оценки специфичности.

Официальный полный тестовый набор SIIM-ACR stage 2 (3 205 снимков) в исследовании намеренно не использовался, поскольку для него отсутствуют публичные эталонные маски, что исключает возможность проверяемой количественной оценки сегментации. Для

финальной проверки была использована собственная отложенная выборка.

При обучении к изображениям применялись аугментации. Каждая трансформация включалась независимо с заданной вероятностью для каждого изображения. Такой режим реализует регуляризацию через контролируемое разнообразие входных данных без изменения целевой разметки. Важно, что геометрические искажения, такие как повороты, сдвиги и масштабирование, были отключены, поскольку в медицинской практике рентгеновские снимки обычно не имеют заметных вращений относительно центра или сдвигов, благодаря этому пространственная структура снимка сохранялась, а также отсутствие вращений и сдвигов ограничивает неестественные деформации анатомии, что особенно важно для рентгенограмм грудной клетки человека.

Ключевая геометрическая операция – горизонтальное зеркалирование. Это означает, что примерно в половине обучающих примеров происходит отражение снимка по горизонтали, что снижает риск переобучения на шаблоны датасета и повышает инвариантность модели к ориентации пациента.

Фотометрическая часть аугментаций моделирует вариабельность реальной рентген-аппаратуры: `brightness_contrast = 0,2`, `gamma = 0,1`, `noise = 0,1`. Эти операции имитируют различия экспозиции, контрастности, нелинейного тонового отклика и шумовых характеристик между сканерами и протоколами. Дополнительно применялось CLANE преобразование, но только на `train` с параметрами: `p = 0,5`, `clip_limit = 2,0`, `tile_grid = 8x8`, что усиливает локальный контраст и стабилизирует визуализацию тонких границ.

После аугментаций выполнялась нормализация в пространстве ImageNet, обеспечивающая согласованную статистику входа для энкодера с предобученными весами.

Архитектура модели и стратегия обучения

В качестве базовой архитектуры сегментатора выбрана модель U-Net++ с энкодером ResNet-34, с весами, предобученными на ImageNet. Чтобы понять выбор данной архитектуры, необходимо обратиться к принципам классической сети U-Net. U-Net состоит из двух симметричных частей: энкодер и декодер. Кодировщик работает как традиционная сверточная сеть: он последовательно сжимает изображение, выделяя из него смысловые признаки и отвечает на вопрос: «Что находится на изображении?». Однако при таком сжатии теряется информация о точном местоположении объектов. Для решения этой проблемы используется декодер, который пошагово увеличивает сжатое представление обратно до размеров исходного изображения и отвечает на вопрос: «Где находится объект?». Ключевой особенностью U-Net являются так называемые прямые связи, по которым детализированная информация из левой части передается в правую, помогая сети точно очертить границы патологии [22].

Несмотря на эффективность базовой U-Net, в ней прямые связи соединяют слои жестко и прямолинейно. Предложенная в настоящей работе модификация U-Net++ решает эту проблему за счет внедрения плотной, паутинообразной сети вложенных соединений. Вместо простого копирования

признаков U-Net++ пропускает их через промежуточные сверточные блоки. На практике это означает, что сеть автоматически сглаживает семантический разрыв между грубыми и тонкими признаками. Для задачи поиска пневмоторакса это критически важно: патология может проявляться как крошечной полоской, так и обширной областью. U-Net++ естественным образом агрегирует признаки разных масштабов, что вкупе с механизмом глубокого контроля обеспечивает высокую чувствительность и стабильность обучения на малых выборках [23].

Для достижения высокой чувствительности была предложена стратегия двухэтапного обучения:

- стадия 1 (прогрев, стадия предварительного обучения): обучение на разрешении 512 на 512 пикселей. Используется стандартная функция потерь Focal + индекс Дайса. Цель – быстрая сходимость весов энкодера и декодера и формирование грубых карт признаков;

- стадия 2 (дообучение, точная подгонка весов на высоком разрешении): дообучение лучших весов первой стадии на разрешении 1024 на 1024 пикселей. Данный этап критически важен, так как некоторые из признаков пневмоторакса могут являться текстурными патологиями высокого разрешения, детали которых могут быть потеряны при уменьшении разрешения до 512 на 512 пикселей [24].

Стабилизация: производится заморозка статистик Batch Normalization в энкодере для стабильности обучения на малом размере батча с накоплением градиента до эффективного. Вычислительные ресурсы были ограничены, поэтому на разрешении 1024 на 1024 пик-

селей использовался батч равным 4, а эффективный батч с аккумуляцией градиента был равен 64.

В дальнейших экспериментах базовая модель, обученная на разрешении 512 на 512, обозначается как конфигурация C12, а итоговая модель после второго этапа дообучения на 1024 на 1024 – как C108.

Функция потерь при обучении

Функция потерь: для шага 2 была сконструирована гибридная функция потерь с компонентой Tversky loss, бинарной кросс-энтропии (BCE) и focal loss, для борьбы с дисбалансом между фоном и объектом интереса сверточной нейронной сети, а также для минимизации пропусков патологии [8].

В работе используются параметры функции потерь Tversky: $\alpha = 0,3$, $\beta = 0,7$. Гиперпараметры метрики расчёта Tversky позволяют асимметрично штрафовать ложноположительные и ложноотрицательные ошибки. Выбор $\beta > \alpha$ обеспечивает более высокий штраф за пропуск пикселей с патологией, по сравнению с ложноположительным срабатыванием [25]. Это переводит модель в разряд моделей с повышенной чувствительностью, данный режим предпочтительный в задачах СППР [26].

Однако агрессивная оптимизация чувствительности (смещение штрафов через параметры α и β) неизбежно приводит к генерации избыточного числа ложноположительных срабатываний (шума) на снимках без патологий. Чтобы этот процесс не вышел из-под контроля и не привел к деградации специфичности, в настоящей работе вводится жесткий фильтр – клинический контур оценки с формализованным ограниче-

нием на уровень ложных тревог, который выступает в роли системного предохранителя.

Методика двухконтурной валидации (RAW/CLIN)

Для объективной оценки качества модели вводится разделение метрик на два контура:

– RAW-контур (технический): оценка вероятностных карт сети без постобработки. Используется для мониторинга сходимости и сырых метрик качества обучения сверточной нейронной сети;

– клинический контур (прикладной): оценка бинаризованных масок после применения порогового отсечения и фильтрации по минимальной площади.

Определение метрик: пусть для изображения i задана истинная бинарная маска патологии $M_i \in \{0,1\}^{H \times W}$, предсказание нейросети на этом изображении представлено вероятностной картой $P_i \in [0,1]^{H \times W}$. Бинаризация выполняется по порогу t :

$$B_i(t) = 1(P_i \geq t),$$

где $1(\cdot)$ – индикаторная функция, применяемая поэлементно. Для получения маски, соответствующей прикладному использованию в составе СППР, вводится клинический контур (CLIN) как фиксированный оператор постобработки:

$$\hat{M}_i(t) = \text{CLIN}(B_i(t)).$$

Оператор $\text{CLIN}(\cdot)$ является неизменяемым во всех экспериментах настоящего исследования.

Как было показано ранее, агрегированные метрики на дисбалансных выборках искажают реальную картину ка-

чества. Для устранения этих эффектов оценка проводится отдельно на подмножествах позитивных и негативных изображений. Позитивным считается изображение с непустой истинной маской: $|M_i| > 0$, негативным – изображение с пустой истинной маской $|M_i| = 0$, включая случаи отсутствия разметки RLE (run-length encoding), трактуемые как нулевая маска.

Ключевые метрики клинического контура: показатели семейства Dice/F1 широко применяются в современных работах по медицинской сегментации как базовые метрики качества, что требует аккуратной фиксации правил их расчета и агрегации [27].

Dice_pos – основная метрика качества сегментации в клиническом контуре – среднее значение коэффициента Дайса, рассчитываемое только на позитивных случаях, для защиты от завышения метрик через истинно отрицательные срабатывания.

Индекс Дайса на одном изображении определяется как

$$\text{Dice}(i, t) = \frac{2 \cdot |M_i \cap \hat{M}_i(t)|}{|M_i| + |\hat{M}_i(t)|}.$$

Dice_pos, усредняемый только по позитивным изображениям:

$$\text{Dice}_{\text{pos}}(t) = \frac{1}{|I_{\text{pos}}|} \cdot \sum_{i \in I_{\text{pos}}} \text{Dice}(i, t),$$

где $I_{\text{pos}} = \{i : |M_i| > 0\}$.

FP_Rate – частота ложноположительных случаев – риск ложных тревог на негативных изображениях, для которых модель предсказала наличие маски патологии. Снимки без патологии не исключаются из оценки, а используют-

ся строго для контроля риска ложных тревог на негативном подмножестве:

$$FP_{Rate}(t) = \frac{1}{|I_{neg}|} \cdot \sum_{i \in I_{neg}} 1 \left(|\hat{M}_i(t)| > 0 \right),$$

где $I_{neg} = \{i : |M_i| = 0\}$.

Pos_any – доля положительных снимков, на которых предсказанная маска в клиническом контуре не пуста. Метрика используется как индикатор покрытия / обнаружения и трактуется как чувствительность модели на уровне изображения:

$$pos_{any}(t) = \frac{1}{|I_{pos}|} \cdot \sum_{i \in I_{pos}} 1 \left(|\hat{M}_i(t)| > 0 \right).$$

Pos_any можно трактовать как чувствительность (sensitivity) модели.

Таким образом, $Dice_pos$ характеризует качество локализации / сегментации на патологических снимках, FP_Rate – частоту ложных тревог на снимках без патологии, а Pos_any – устойчивость обнаружения патологии на уровне изображения. Эти метрики совместно задают интерпретируемый контроль компромисса чувствительность – ложные тревоги при дисбалансе классов.

Поскольку в задачах сегментации на дисбалансных данных минимум функции потерь на валидации может не совпадать с клинически предпочтительным качеством (эффект расхождения функции потерь и прикладных метрик), в настоящей работе применяется формализованный протокол выбора рабочей точки и эпохи обучения, основанный исключительно на клиническом контуре.

Предрегистрация сетки порогов. Для исключения подбора порога бинаризации после начала эксперимента ис-

пользуется заранее фиксированная сетка порогов клинического контура:

$$BASE_{thr} = \{0,001; 0,002; 0,005; 0,01; 0,02; 0,03; 0,05; 0,10; 0,15; 0,20; 0,30; 0,50\}.$$

В ходе экспериментов допускается оценивание модели только в точках $t \in base_{thr}$.

Клинические ограничения: для каждой эпохи обучения e на наборе разработки рассматриваются значения метрик клинического контура при переборе порога $t \in base_{thr}$. Рабочая точка считается допустимой если одновременно выполняются ограничения:

$$FP_{Rate}(e, t) \leq fp_{target}, \text{ и } pos_{any}(e, t) \geq min_{pos_any},$$

где $FP_{target} = 0,30$ и $Min_{pos_any} = 0,20$.

В качестве клинических метрик также использовались значения $pr_min_area = 300$ пикселей. Клинический контур также пересчитывался после изменения разрешения изображений в случаях, где применялось изменение разрешения.

Выполняется запрет подгонки на отложенной выборке. Отложенная выборка используется после выбора рабочих точек и заморозки всех параметров, основываясь на данных, полученных во время работы с валидационной выборкой.

Процедура выбора эпохи

Учитывая эффект расхождения строгой математической функции потерь и реальных метрик качества модели, вместо традиционного выбора модели по минимуму потерь при обучении предложен следующий алгоритм ограниченного выбора: задаются клинические ограничения и на каждой эпохе ва-

лидации производится поиск порога бинаризации, удовлетворяющего ограничениям.

Пусть E – множество эпох обучения, а e – конкретная эпоха. Для каждой эпохи $e \in E$ на валидационной выборке определяются метрики. Вычисляется область допустимых решений, определяемая клинической политикой: финальная модель выбирается путем максимизации качества сегментации внутри допустимой области. Эпоха считается

$$\mathcal{F}(e) = \{t \in \text{base}_{\text{thr}} : \text{FP}_{\text{Rate}}(e, t) \leq \text{fp}_{\text{target}} \wedge \text{pos}_{\text{any}}(e, t) \geq \min_{\text{pos_any}}\},$$

где $\text{FP}_{\text{target}} = 0,30$, $\text{Min_pos_any} = 0,20$, FP_{Rate} определяется строго на подмножестве отрицательных снимков, а Pos_any – как доля положительных снимков с непустой предсказанной маской после клинического контура.

Клинические ограничения, используемые в клиническом контуре, задаются не как окончательная эксплуатационная спецификация для скрининговой системы, а как внутренний критерий выполнимости для этапа разработки и методической валидации сегментационного модуля. В частности, порог $\text{FP}_{\text{target}} = 0,30$ применяется как верхняя граница допустимого уровня ложных тревог на отрицательных снимках в контуре подбора для предотвращения деградации специфичности при целенаправленной оптимизации чувствительности сегментатора. Такая постановка отражает целевую роль сегментатора в данной статье: получить высокочувствительный модуль локализации, устойчиво сохраняющий обнаружение патологии при контролируемом росте ложноположительных срабатываний, но без претензии на достижение конечного уровня ложноположительных срабаты-

ся допустимой, если такое решение существует.

В соответствии с предрегистрацией протокола оценивания выбор итоговой модели выполняется исключительно по клиническому контуру и определяется правилом первичной конечной точки. Для каждой эпохи e и каждого порога бинаризации рассчитываются метрики клинического контура, после чего формируется множество допустимых решений:

ваний, требуемого в реальном клиническом рабочем процессе. Выбор относительно мягкого ограничения на этапе разработки мотивирован архитектурной декомпозицией задачи на несколько исследований. В данном исследовании фокусируется методика обучения и клинически ориентированного выбора эпохи / рабочей точки для сегментатора при сильном дисбалансе классов и эффекте расхождения метрик. При этом жесткое снижение уровня ложноположительных срабатываний до уровня, сопоставимого с эксплуатационными требованиями к скринингу, рассматривается как задача системной архитектуры и решается в последующих исследованиях. Таким образом, ограничения $\text{FP}_{\text{target}} = 0,30$, $\text{Min_pos_any} = 0,20$ следует трактовать как операционное ограничение разработки.

Рабочая точка для итоговой эпохи определяется по правилу первичной конечной точки:

$$e^* = \arg \max_{\text{pos}} \text{Dice}_{\text{pos}}(e, t^*(e)).$$

Таким образом, в рамках выбора лучшей рабочей точки показатель FP_{Rate} используется только как огра-

ничество выполнимости, а не как оптимизируемая цель. Любые дополнительные характеристики, например динамика FP_Rate по эпохам или анализ локальных минимумов FP_Rate, рассматриваются как вторичные результаты и не изменяют предопределённого правила выбора лучших рабочих точек.

Данный подход демонстрирует, что выбранная модель удовлетворяет требованиям безопасности по уровню ложноположительных срабатываний и эффективности, игнорируя локальные минимумы функции потерь, имеющие низкую клиническую ценность.

При финальной проверке на отложенной выборке порог бинаризации не подбирался повторно и не пересканировался. Использовалось значение порога, выбранное на наборе разработки по предопределённому правилу, а на отложенной выборке выполнялась только однократная оценка метрик в фиксированной рабочей точке и для выбранной эпохи. Это исключает использование отложенной выборки для подбора параметров и сохраняет корректность схемы однократной проверки.

Статистический анализ

Для количественной оценки неопределённости метрик клинического контура использовались 95% доверительные интервалы, полученные методом бутстреп-ресэмплинга. Единицей наблюдения в статистическом анализе являлось изображение (случай), а не отдельные пиксели. Для каждой сравниваемой конфигурации модели формировался массив наблюдений размера N, включающий число изображений в соответствующей подвыборке. Далее выполнялось 1000 бутстреп-итераций. На каждой итерации строился бутстреп-

сэмпл путем выборки N строк из таблицы статистики эпохи. Ресэмплирование проводилось совместно по всем строкам. С учётом того что метрики определены на различных подмножествах данных (Dice_pos и Pos_any – на позитивных случаях, FP_Rate – на негативных), бутстреп выполнялся отдельно без стратификации по классу. На каждой итерации формировалась выборка с возвращением того же размера, что и исходное соответствующее подмножество, после чего метрика пересчитывалась по формальным определениям клинического контура. Границы 95% доверительного интервала определялись по 2,5- и 97,5-перцентилям эмпирического распределения бутстреп-оценок, без явной стратификации по позитивным и негативным снимкам. Это корректно при больших объёмах данных и устойчивой представленности классов, однако при малых выборках может приводить к повышенной вариативности позитивных метрик.

Результаты и их обсуждение

Сравнительный анализ эффективности базового и предложенного подходов

Для оценки эффективности предложенной методики выполнено сравнение клинических метрик сегментации на наборе разработки для двух конфигураций: базовой модели C12 (обучение 512 на 512 пикселей) и предложенной модели C108 (1024 на 1024 пикселей – второй этап с последующей тонкой настройкой). Метрики рассчитывались в клиническом контуре и в рабочей точке, выбранной на наборе разработки согласно предопределённому протоколу. Рассмотрим сводные результаты (табл. 2).

Таблица 2. Клинические метрики на наборе разработки для сравниваемых конфигураций**Table 2.** Clinical metrics on the development set for the compared configurations

Модель / Конфигурация / Model / Configuration	Dice_pos, среднее [95% ДИ] / Dice_pos, mean (95% CI)	Pos_any, среднее [95% ДИ] / Pos_any, mean (95% CI)	FP_Rate, среднее [95% ДИ] / FP_Rate, mean (95% CI)
C12	0,488 [0,466–0,509]	0,876 [0,845–0,908]	0,464 [0,440–0,491]
C108, эпоха 8, минимум функции потерь	0,569 [0,547–0,590]	0,983 [0,969–0,995]	0,424 [0,399–0,452]
C108, эпоха 12	0,699 [0,679–0,718]	0,958 [0,937–0,978]	0,253 [0,233–0,277]
C108, эпоха 17	0,721 [0,700–0,740]	0,962 [0,944–0,981]	0,224 [0,202–0,247]
C108, эпоха 15, вы- бранная согласно про- токолу	0,753 [0,734–0,771]	0,948 [0,905–0,956]	0,177 [0,158–0,197]

Для показателей в таблице 2 приведены 95% ДИ, полученные методом бутстреп-перевыборки.

Сравнение выполнялось строго в терминах клинического контура и в соответствии с предопределённым правилом первичной конечной точки: для каждой эпохи на наборе разработки выбиралась рабочая точка, удовлетворяющая клиническим ограничениям, после чего итоговая эпоха определялась как максимизирующая Dice_pos среди допустимых решений. В рамках этого протокола для конфигурации C108 наилучшее значение Dice_pos достигается на 15-й эпохе – 0,753 [0,734–0,771] при FP_Rate 0,177 [0,158–0,197] и Pos_any 0,948, поэтому именно эта эпоха рассматривается как выбранная модель на уровне разработки.

Базовая конфигурация C12 демонстрирует Dice_pos 0,488 [0,466–0,509] при FP_Rate 0,464 [0,440–0,491] и Pos_any 0,876. Высокое значение FP_Rate означает, что значимая доля негативных снимков сопровождается ложной тревогой в клиническом контуре, что делает конфигурацию C12

нежелательной в составе СППР без дополнительного механизма подавления ложноположительных срабатываний на уровне системы. Кроме того, никакая из эпох конфигурации C12 не смогла пройти порог клинического уровня.

Промежуточные точки обучения C108 (эпохи 12 и 17) приведены как вторичный анализ динамики компромисса между качеством сегментации и ложными тревогами. Так, на 17-й эпохе наблюдается более высокое покрытие Pos_any (0,962) при Dice_pos 0,721 [0,700–0,740] и FP_Rate 0,224 [0,202–0,247], тогда как 15-я эпоха обеспечивает максимальный Dice_pos при несколько меньшем Pos_any и более низком FP_Rate. Эти различия иллюстрируют, что выбор лучшей точки зависит от заранее зафиксированного критерия, а не постфактум предпочтением одной из метрик.

По сравнению с базовой конфигурацией C12 предложенная конфигурация C108 (выбранная по протоколу на 15-й эпохе) демонстрирует следующие изменения на наборе для разработки:

1) рост качества сегментации на позитивных случаях: среднее значение коэффициента Dice_pos увеличивается с 0,488 до 0,753, абсолютная разница составляет $\Delta = 0,265$. Относительный прирост составил 54,3% относительно C12;

2) высокое покрытие обнаружения на уровне снимка: метрика Pos_anu возрастает с 0,876 до 0,948 по сравнению с C12 $\Delta = 0,072$ или +8,2%. Модель детектирует 94,8% случаев патологии (против 87,7% у C12), что указывает на сохранение высокого уровня обнаружения патологии при выбранной рабочей точке;

3) снижение ложных тревог на отрицательных снимках: доля ложнопозитивных результатов снизилась более чем в 2,62 раза – с 0,464 до 0,177, на 61,9%, абсолютное снижение составляет $\Delta = 0,287$.

Абляционное сравнение критериев выбора модели: ключевым элементом анализа является доказательство эффективности предложенного алгоритма выбора эпохи. Для этого в таблицу 2 включена конфигурация «C108, эпоха 8» –

это та же самая нейронная сеть, но зафиксированная по стандартному критерию ранней остановки в точке абсолютного минимума валидационной функции потерь. Сравнение показывает, что выбор эпохи по val_loss (эпоха 8) проигрывает выбору по клиническому алгоритму (эпоха 15) в качестве локализации и, что более критично, демонстрирует недопустимо высокий уровень ложных тревог. Эта абляция внутри одной архитектуры показывает: существенный прирост качества обусловлен не только переходом на высокое разрешение, но и применением разработанного двухконтурного протокола валидации, который уберет модель от фиксации в клинически субоптимальной точке.

Для наглядной демонстрации того, как алгоритм определяет рабочую точку внутри выбранной эпохи, на рисунке 1 представлено поведение метрик клинического контура для итоговой конфигурации C108 (эпоха 15) при переборе порогов бинаризации.




Рис. 1. Анализ метрик клинического контура для конфигурации C108 (эпоха 15): а – динамика метрик в зависимости от порога бинаризации; б – кривая компромисса «чувствительность – доля ложных срабатываний» с указанием значений порогов на точках

Fig. 1. Analysis of clinical contour metrics for the C108 configuration (epoch 15): а – metrics dynamics depending on the binarization threshold; б – "sensitivity – false positive rate" trade-off curve

Левый график иллюстрирует разнонаправленную динамику: по мере увеличения порога доля ложных срабатываний (оранжевая пунктирная линия) стремительно падает, индекс Дайса (зеленая линия) растет и стабилизируется, в то время как чувствительность (синяя линия) демонстрирует пологую деградацию.

Правый график параметрической кривой компромисса наглядно объясняет результат работы алгоритма: рабочая точка для порога $t = 0,50$ располагается на выраженном изгибе кривой. В этой точке достигается оптимальный баланс: модель выдерживает клиническое ограничение, сохраняя при этом высокую чувствительность обнаружения. Выбор более низких порогов дает минимальный прирост к чувствительности, но приводит к резкому, непропорциональному росту числа ложных тревог.

В совокупности результаты на наборе разработки показывают, что предложенная методика обучения и клинически ориентированного выбора

рабочей точки обеспечивает более благоприятный баланс Dice_pos и FP_Rate по сравнению с базовым протоколом. Интерпретация наблюдаемого улучшения как эффекта увеличения разрешения и изменения функции потерь соответствует исходной инженерной гипотезе, однако причинный вклад отдельных компонентов (разрешение, состав функции потерь, правила клинического контура) требует отдельного абляционного исследования и рассматривается как предмет последующего анализа.

Проверка на отложенной выборке и K-Fold

Для оценки стабильности предложенной архитектуры и устойчивости алгоритма выбора рабочей точки была проведена процедура перекрестной проверки (Stratified Group K-Fold при $K = 5$) на наборе для разработки. Детализированные метрики клинического контура по каждому из разбиений представлены ниже (табл. 3).

Таблица 3. Результаты 5-кратной перекрестной проверки (Stratified Group K-Fold) для предложенной модели C108

Table 3. Results of 5-fold cross-validation (Stratified Group K-Fold) for the proposed C108 model

Подвыборка / Subset	Объем разбиения / Split size	Dice_pos, среднее [95% ДИ] / Dice_pos, mean (95% CI)	FP_Rate среднее [95% ДИ] / FP_Rate, mean (95% CI)	Pos_any среднее [95% ДИ] / Pos_any, mean (95% CI)
Фолд 0	405 / 1410	0,753 [0,734–0,771]	0,177 [0,158–0,197]	0,931 [0,905–0,956]
Фолд 1	405 / 1410	0,801 [0,785–0,817]	0,157 [0,139–0,177]	0,975 [0,960–0,988]
Фолд 2	404 / 1411	0,815 [0,799–0,830]	0,150 [0,133–0,169]	0,978 [0,964–0,991]
Фолд 3	404 / 1411	0,792 [0,776–0,808]	0,174 [0,154–0,194]	0,975 [0,960–0,989]
Фолд 4	404 / 1410	0,804 [0,786–0,820]	0,165 [0,145–0,184]	0,975 [0,960–0,990]
В среднем (стандартное отклонение, SD)	404 / 1410	0,793 $\pm$ 0,023	0,165 $\pm$ 0,011	0,967 $\pm$ 0,020

Результаты экспериментов подтвердили высокую устойчивость модели к изменению обучающей и валидационной подвыборок. Усредненные значения метрик по всем пяти фолдам составили: $\text{Dice_pos} = 0,793 \pm 0,023$, $\text{FP_Rate} = 0,165 \pm 0,011$ и $\text{Pos_any} = 0,967 \pm 0,020$. Во всех без исключения сплитах выбранные алгоритмом рабочие точки уверенно выполнили заданные клинические ограничения. Примечательно, что показатели нулевого фолда, где $\text{Dice_pos} = 0,753$, подробно проанализированные в сравнительном анализе, являются наиболее консервативной оценкой. На остальных четырех подвыборках качество локализации патологии варьировалось в диапазоне 0,792-0,815 при снижении доли ложных

срабатываний вплоть до 0,150. Низкая дисперсия метрик между фолдами показывает, что предложенный двухконтурный протокол валидации обеспечивает надежный и воспроизводимый результат, не зависящий от случайного разбиения данных. В таблице 4 показаны данные по тестированию на отложенной выборке.

Финальная проверка выбранной по протоколу конфигурации C108 выполнена на независимой отложенной выборке, которая не использовалась для обучения, подбора гиперпараметров, выбора эпохи или выбора рабочей точки. На отложенной выборке применялись те же параметры клинического контура и та же рабочая точка, которые были зафиксированы на наборе разработки.

Таблица 4. Результаты тестирования на отложенной выборке

Table 4. Results on the holdout test set

Показатель / Metric	Среднее значение / Mean	95% ДИ / 95% CI
Dice_pos	0,737	[0,718–0,755]
FP_Rate	0,203	[0,183–0,224]
Pos_any	0,924	[0,895–0,951]

Дополнительно для интерпретации метрик на уровне изображений: при N позитивных = 357 и N негативных = 1244 получено истинно положительных = 330 и ложно негативных = 27, $\text{Pos_any} = 0,924$, ложноположительных = 252 и истинно отрицательных = 992 – метрика $\text{FP_Rate} = 0,203$. Таким образом, при переносе на отложенную выборку модель сохраняет высокий уровень обнаружения патологии на уровне снимка и контролируемую частоту ложных тревог, оставаясь в допустимой области, заданной ограничениями протокола.

Наблюдаемое отличие показателей, по сравнению с набором разработки, ожидаемо для независимой проверки и

не меняет вывод о воспроизводимости протокола выбора модели.

Анализ динамики обучения и феномен расхождения метрик

На рисунке 2 представлена динамика функции потерь и ключевых метрик модели для конфигурации C108 в процессе дообучения на разрешении 1024 на 1024 пикселя. График иллюстрирует выявленный в ходе эксперимента эффект расхождения значений функции потерь и целевых клинических метрик. Минимум значения функции потерь на проверочной выборке не совпадает с эпохой, обеспечивающей наилучшее клинически интерпретируемое качество по заранее заданному правилу выбора.




Рис. 2. Динамика функции потерь и клинических метрик для C108 на наборе разработки в ходе дообучения

Fig. 2. Dynamics of the loss function and clinical metrics for the C108 configuration on the development set during fine-tuning

Динамика (см. рис. 2) условно разделяется на две фазы. В первой фазе (ранние эпохи) уменьшение функции потерь сопровождается согласованным улучшением клинических метрик. Во второй фазе наблюдается расхождение: при отсутствии дальнейшего улучшения (или даже при росте) значения функции потерь клинические метрики продолжают улучшаться или стабилизируются на более благоприятном уровне, что делает выбор сохранённой модели по минимуму функции потерь потенциально субоптимальным для клинического контура. Графики построены в рабочей точке по порогу $\text{thr} = 0.5$, выбранному по предрегистрации:

1. Фаза согласованной оптимизации (эпохи 1–8): наблюдается совместная динамика — уменьшение значения функции потерь сопровождается ростом Dice_{pos} и снижением FP_{Rate} . Ло-

кальный минимум функции потерь достигается примерно на 8-й эпохе.

2. Фаза расхождения (эпохи 9–25): после достижения минимума функция потерь на проверочной выборке не улучшается, однако клинические метрики демонстрируют сохранение или улучшение. В частности, Dice_{pos} достигает максимума на 15-й эпохе, (см. рис. 2). Это указывает, что минимум функции потерь не является надёжным критерием выбора клинически предпочтительной рабочей точки при заданной постановке задачи и выбранных компонентах функции потерь.

Практическое следствие показанного расхождения состоит в том, что стандартная ранняя остановка обучения, ориентированная на минимум функции потерь на проверочной выборке, выбрала бы модель вблизи эпохи локального ми-

нимума потерь и тем самым могла бы зафиксировать модель, уступающую выбранной по клиническому правилу. В настоящей работе лучшая эпоха определяется предрегистрацией: выбирается эпоха, максимизирующая $Dice_pos$ в допустимой области, заданной ограничениями на FP_Rate и Pos_any . Следовательно, траектории функции потерь и вторичных метрик интерпретируются как описательные и не изменяют правила выбора модели. Наблюдения (см. рис. 2) поддерживают тезис о том, что при выраженном дисбалансе и гибридных функциях потерь минимизация математической ошибки не гарантирует опти-

муму по клинически интерпретируемым метрикам.

Качественный анализ результатов сегментации

Для интерпретации количественных различий метрик выполнен визуальный анализ предсказаний на репрезентативной выборке случаев из набора разработки, включающей как позитивные снимки с различной выраженностью пневмоторакса, так и негативные снимки с типичными источниками ложных срабатываний (костные структуры, трубки, артефакты). Рассмотрим примеры сравнений для C12 и C108 (рис. 3–5).




Рис. 3. Пример позитивного случая с малым объёмом пневмоторакса: эталонные данные и предсказания C12 (а) и C108 (б) в клиническом контуре

Fig. 3. Example of a positive case with a small pneumothorax volume: ground truth and clinical-loop predictions of C12 (a) and C108 (b)




Рис. 4. Пример позитивного случая с распространённым пневмотораксом: сравнение топологии масок, фрагментация предсказания и связанная область выражены лучше: а – C12; б – C108

Fig. 4. Example of a positive case with extensive pneumothorax: comparison of mask topology; prediction fragmentation is reduced and the connected component is represented more clearly: а – C12; б – C108




Рис. 5. Пример отрицательного случая: ложные срабатывания C12 и подавление ложной маски в C108: а – C12; б – C108

Fig. 5. Example of a negative case: false positives in C12 and suppression of the spurious mask in C108: а – C12; б – C108

Визуальный анализ выявляет три типовых различия между базовой и предложенной конфигурациями, согласующиеся с наблюдаемыми изменениями Dice_pos и FP_Rate в таблице 2:

1) слабый локальный сигнал на положительных снимках (см. рис. 3). В ряде случаев пневмоторакс проявляется как тонкая плевральная линия или локальное ослабление лёгочного рисунка. В таких примерах C12 чаще демонстрирует неполное покрытие или пропуск области, тогда как C108 формирует более устойчивую локализацию и более связную маску в зоне патологии;

2) топологическая целостность маски при выраженной патологии (см. рис. 4). На некоторых положительных снимках C12 склонна к фрагментации предсказания на отдельные «островки», что затрудняет интерпретацию локализации. В C108 в аналогичных примерах чаще наблюдается формирование связной области предсказания, согласующейся с контуром поражения;

3) структурно обусловленные ложные срабатывания на отрицательных снимках (см. рис. 5). На отрицательных случаях базовая модель чаще реагирует на контрастные костные структуры и

артефакты, формируя мелкие ложные области. В предложенной конфигурации ложные области, как правило, имеют меньшую выраженность / площадь и реже проходят клинический контур, что согласуется со снижением FP_Rate (см. табл. 2).

Полученные результаты показывают, что клинически ориентированный протокол валидации и выбора модели позволяет улучшить качество сегментации на положительных случаях при одновременном контроле ложных тревог на отрицательных снимках. В соответствии с заранее зафиксированным правилом первичной конечной точки выбранная конфигурация C108 (15-я эпоха) достигает Dice_pos 0,753 при FP_Rate 0,177 и Pos_any 0,948 на наборе разработки, тогда как базовая конфигурация C12 демонстрирует Dice_pos 0,488 при FP_Rate 0,464 и Pos_any 0,876. Важным является не только само улучшение показателей, но и то, что оно получено в рамках фиксированных клинических ограничений, что снижает риск неконтролируемого смещения модели в сторону высокой чувствительности ценой взрыва ложноположительных срабатываний.

С методической точки зрения результаты поддерживают два вывода. Во-первых, разнесение метрик по подмножествам позитивных и негативных изображений даёт интерпретируемую картину качества и устраняет неоднозначности, возникающие при использовании агрегированных показателей на дисбалансных данных. Во-вторых, демонстрируемое расхождение между динамикой функции потерь и клинических метрик подтверждает необходимость выбора эпохи не по минимуму функции потерь, а по клиническому правилу внутри допустимой области.

Предложенная двухконтурная схема оценки позволяет разделить две задачи, которые на практике часто смешиваются. Технический контур используется для контроля сходимости и мониторинга обучения, тогда как клинический контур задаёт прикладной смысл метрик – оценку бинаризованных масок после процедур, которые соответствуют будущему применению модуля в составе СППР.

Ключевой особенностью является то, что «лучшая модель» определяется не по локальным экстремумам функции потерь, а по первичной конечной точке: максимум $Dice_pos$ в допустимой области, заданной ограничениями на FP_Rate и Pos_any . Такой подход принципиально повышает воспроизводимость процесса выбора модели: правило выбора фиксировано и не зависит от постфактум предпочтений исследователя, а значит, снижает риск непреднамеренной подгонки результатов под ожидаемый эффект.

Следует подчеркнуть, что введённое ограничение FP_Rate в данной работе трактуется как ограничение вы-

полноты на этапе разработки, а не как эксплуатационная спецификация конечной клинической системы. Роль сегментатора в текущем исследовании – сформировать высокочувствительный модуль локализации, сохраняющий обнаружение патологии при контролируемом уровне ложных тревог. В этом режиме допустимо наличие остаточных ложноположительных срабатываний на отрицательных снимках, поскольку дальнейшее снижение FP рассматривается как задача системного согласования модулей на уровне СППР.

Тем самым ограничение FP_Rate используется как предохранитель от деградации специфичности при целенаправленной оптимизации чувствительности, но не как цель оптимизации. Такой дизайн согласуется с архитектурной декомпозицией: в последующих исследованиях предполагается введение внешнего механизма подавления ложных тревог, который позволит приблизить уровень ложных тревог к требованиям практического применения без разрушения чувствительности сегментатора.

Оценка выполнена на одном открытом наборе данных. Кроме того, в используемой выгрузке идентификатор $PatientID$ является уникальным для одного снимка, из-за чего разбиение по $PatientID$ эквивалентно разбиению на уровне изображений. Это ограничивает строгость вывода о переносимости на новых пациентов и повышает требования к дополнительным проверкам устойчивости. Кроме того, вычислительные ресурсы были ограничены, что не позволило обучать нейронную сеть с размером батч больше 4 на разрешении 1024 на 1024 пикселя, несмотря на ис-

пользование аккумуляции градиента между батчами, итоговый градиент на более мощных системах может отличаться.

В рамках текущей версии исследования не проводилась внешняя валидация, могут потребоваться проверки переносимости.

Несмотря на то, что улучшение качества согласуется с гипотезой о пользе повышения разрешения и модификации функции потерь, причинный вклад отдельных компонентов (разрешение, состав функции потерь, процедуры клинического контура) в данной версии не изолирован строгими абляциями. Следовательно, интерпретация носит инженерный характер и должна быть подтверждена отдельными сравнительными экспериментами.

Открытые наборы данных потенциально содержат шум разметки и неполноту аннотаций, включая случаи пропущенной патологии. Это может влиять на оценку, поскольку часть ложных срабатываний может соответствовать неразмеченным истинным проявлениям. В дальнейшем целесообразно формализовать и задокументировать процедуру аудита разметки и включить её результаты как ограничение валидности выводов.

Дальнейшая работа естественным образом следует из архитектурной постановки задачи. Во-первых, требуется системный механизм подавления ложных тревог на уровне СППР, позволяющий снизить до эксплуатационно приемлемого уровня при сохранении покрытия обнаружения. Во-вторых, необходимы абляционные эксперименты, изолирующие вклад повышения разрешения, состава функции потерь и пра-

вил клинического контура. В-третьих, требуется проверка переносимости на внешнем домене и анализ устойчивости метрик при изменении распределения данных.

Выводы

В настоящем исследовании решена актуальная методическая проблема объективной оценки и выбора нейросетевых моделей сегментации медицинских изображений в условиях выраженного дисбаланса классов. Предложенная двухконтурная схема валидации, разделяющая технический мониторинг обучения (RAW-контур) и оценку прикладной эффективности (CLIN-контур), позволяет преодолеть фундаментальное ограничение стандартных метрик – иллюзию высокого качества при агрегировании результатов по всей выборке.

В ходе работы эмпирически доказано наличие феномена расхождения между математическим оптимумом функции потерь и клинически значимым качеством модели. Установлено, что традиционная практика ранней остановки обучения по локальному минимуму валидационных потерь в задачах скрининга может приводить к выбору субоптимальных решений.

Применение формализованного протокола выбора рабочей эпохи на основе строгих априорных ограничений позволило извлечь максимальную пользу из гибридной функции потерь, ориентированной на высокую чувствительность. Выбранная таким образом модель успешно подтвердила свою эффективность на независимой отложенной выборке: обеспечена высокая точность локализации патологии. $\text{Dice_pos} = 0,737$, и надежное покрытие обнаружения

Pos_any = 0,924, при этом уровень ложных тревог на снимках здоровых пациентов удержан в безопасных рамках клинических ограничений: FP_Rate = 0,203.

Ключевой научно-практический вклад работы заключается в переходе от ретроспективного подбора порогов к фиксированному правилу первичной конечной точки. Данный подход принципиально повышает воспроизводимость экспериментов, исключает риск непреднамеренной подгонки результатов под ожидаемый эффект и демонстрирует, что сегментационный модуль

отвечает требованиям безопасности по частоте ложных срабатываний. Разработанная методика формирует надежный инженерный базис для проектирования алгоритмов лучевой диагностики и их последующей интеграции в клинические системы поддержки принятия решений. Дальнейшие исследования будут направлены на проведение строгих абляционных экспериментов, валидацию протокола на внешних клинических базах данных и разработку системных механизмов каскадного подавления остаточных ложных тревог, а также создание СППР.

Список литературы

1. Lung imaging methods: indications, strengths and limitations / D. L. Tárnoki, K. Karlinger, C. A. Ridge, F. J. Kiss, T. Györke, E. M. Grabczak, Á. D. Tárnoki // *Breathe (Sheff)*. 2024. Vol. 20, N 3. P. 230127. <https://doi.org/10.1183/20734735.0127-2023>.
2. Multidisciplinary Evaluation of an AI-Based Pneumothorax Detection Model: Clinical Comparison with Physicians in Edge and Cloud Environments / I. Dal, H. B. Kaya // *J. Multidiscip. Healthc*. 2025. Vol. 18. P. 4099–4111. <https://doi.org/10.2147/JMDH.S535405>.
3. Clinical adoption of deep learning target auto-segmentation for radiation therapy: challenges, clinical risks, and mitigation strategies / A. De Biase, N. M. Sijtsema, T. Janssen, C. Hurkmans, C. Brouwer, P. van Ooijen // *BJR Artificial Intelligence*. 2024. Vol. 1, N 1. P. ubae015. <https://doi.org/10.1093/bjrai/ubae015>.
4. Metrics reloaded: recommendations for image analysis validation / L. Maier-Hein, A. Reinke, P. Godau [et al.] // *Nat. Methods*. 2024. Vol. 21, N 2. P. 195–212. <https://doi.org/10.1038/s41592-023-02151-z>.
5. Understanding metric-related pitfalls in image analysis validation / A. Reinke, M. D. Tizabi, M. Baumgartner [et al.] // *Nat. Methods*. 2024. Vol. 21, N 2. P. 182–194. <https://doi.org/10.1038/s41592-023-02150-0>.
6. Mohammadi M., Mollazade K., Behrooz-Khazaei N. Under- and over-segmentation: new metrics for image segmentation accuracy measurement // *Array*. 2025. Vol. 28. P. 100624. <https://doi.org/10.1016/j.array.2025.100624>.
7. Association Between False-Positive Results and Return to Screening Mammography in the Breast Cancer Surveillance Consortium Cohort / D. L. Miglioretti, L. Abraham, B. L. Sprague [et al.] // *Ann. Intern. Med*. 2024. Vol. 177, N 10. P. 1297–1307. <https://doi.org/10.7326/M24-0123>.

8. Conquering class imbalances in deep learning-based segmentation of dental radiographs with different loss functions / M. Büttner, L. Schneider, A. Krasowski [et al.] // J. Dent. 2024. Vol. 148. P. 105063. <https://doi.org/10.1016/j.jdent.2024.105063>.
9. Cabezas M., Diez Y. An Analysis of Loss Functions for Heavily Imbalanced Lesion Segmentation // Sensors. 2024. Vol. 24, N 6. P. 1981. <https://doi.org/10.3390/s24061981>.
10. Reinke A., Tizabi M. D., Maier-Hein L. Advancing standards in biomedical image analysis validation: A perspective on Metrics Reloaded // Clin. Transl. Med. 2025. Vol. 15, N 9. P. e70237. <https://doi.org/10.1002/ctm2.70237>.
11. Малютина И. А., Кузьмин А. А., Шаталова О. В. Методы и алгоритмы анализа рентгенограмм грудной клетки, использующие локальные окна в задачах обнаружения патологий // Прикаспийский журнал: управление и высокие технологии. 2017. № 3 (39). С. 131–138.
12. Моделирование морфологических образований на рентгенограммах грудной клетки в интеллектуальных диагностических системах медицинского назначения / П. С. Кудрявцев, А. А. Кузьмин, Д. Ю. Савинов, С. А. Филист, О. В. Шаталова // Прикаспийский журнал: управление и высокие технологии. 2017. № 3 (39). С. 109–120.
13. Математические модели для интеллектуальных систем классификации рентгенограмм грудной клетки / М. В. Дюдин, П. С. Кудрявцев, К. В. Подмастерьев, С. А. Филист, О. В. Шаталова // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2016. № 2 (19). С. 94–107.
14. Анализ биомедицинских изображений различными методами сегментации, основанными на операторах вычисления градиента / С. А. Филист, Е. А. Шашкова, О. В. Шаталова, Р. А. Томакова // Перспективы развития информационных технологий. 2011. № 3-1. С. 146–150.
15. An Automated System for Classification of Radiographs of the Breast / A. R. Dabagov, V. A. Gorbunov, S. A. Filist [et al.] // Biomedical Engineering. 2020. Vol. 53, N 6. P. 425–428. <https://doi.org/10.1007/s10527-020-09957-7>.
16. Hybrid neural networks with virtual flows in medical risk classifiers / K. Khatatneh, S. Filist, O. Shatalova [et al.] // Journal of Intelligent and Fuzzy Systems. 2022. Vol. 43, N 1. P. 1621–1632. <https://doi.org/10.3233/JIFS-212617>.
17. Коровин Е. Н., Шаталова О. В., Жилин В. В. Применение гибридной нейронной сети с макрослоями для классификации сердечно-сосудистых заболеваний // Биомедицинская радиоэлектроника. 2014. № 9. С. 32–37.
18. Biotechnical neural network system for predicting cardiovascular health state using processing of bio-signals / S. Filist, R. T. Al-Kasasbeh, O. V. Shatalova [et al.] // International Journal of Medical Engineering and Informatics. 2024. Vol. 16, N 4. P. 324–349. <https://doi.org/10.1504/IJMEI.2024.139884>.

19. Сверточная нейронная сеть для моделей классификаторов медицинского риска с синергетическими каналами / Р. А. Крупчатников, Д. А. Медников, З. У. Протасова [и др.] // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2021. Т. 11, № 2. С. 25–50.
20. Multimodal neural network classifier of the functional state of the respiratory system / S. A. Filist, M. B. Myasnyankin, R. I. Safronov, A. A Kuzmin // Journal of Physics: Conference Series. 2021. Vol. 2094. P. 032064. <https://doi.org/10.1088/1742-6596/2094/3/032064>.
21. A multitask approach for automated detection and segmentation of thyroid nodules in ultrasound images / A. Radhachandran, A. Kinzel, J. Chen, V. Sant, M. Patel, R. Masamed, C. W. Arnold, W. Speier // Comput. Biol. Med. 2024. Vol. 170. P. 107974. <https://doi.org/10.1016/j.compbimed.2024.107974>.
22. UNet++: A Nested U-Net Architecture for Medical Image Segmentation / Z. Zhou, M. M. R. Siddiquee, N. Tajbakhsh, J. Liang // Deep Learn Med Image Anal Multimodal Learn Clin Decis Support. 2018. Vol. 11045. P. 3–11. https://doi.org/10.1007/978-3-030-00889-5_1.
23. Deeply-Supervised Nets / C. Y. Lee, S. Xie, P. Gallagher, Z. Zhang, Z. Tu // arXiv. URL: <https://arxiv.org/abs/1409.5185> (дата обращения: 16.03.2026).
24. Effect of image resolution on automated classification of chest X-rays / M. I. U. Haque, A. K. Dubey, I. Danciu, A. C. Justice, O. S. Ovchinnikova, J. D. Hinkle // J. Med. Imaging (Bellingham). 2023. Vol. 10, N 4. P. 044503. <https://doi.org/10.1117/1.JMI.10.4.044503>.
25. CACSNet for automatic robust classification and segmentation of carotid artery calcification on panoramic radiographs using a cascaded deep learning network / S. W. Yoo, S. Yang, J. E. Kim [et al.] // Sci. Rep. 2024. Vol. 14. P. 13894. <https://doi.org/10.1038/s41598-024-64265-4>.
26. How threshold customisation affects the performance of a multiclass X-ray AI model for primary care triage: a retrospective study / J. Z. T. Sim, J. Lin, Q. W. Fong, A. Y. Q. Soon, L. W. Khin, S. Balakrishnan, T. Lin, S. Wong, C. H. Tan // BMJ Open. 2026. Vol. 16, N 2. P. e111127. <https://doi.org/10.1136/bmjopen-2025-111127>.
27. Tabassum M., Di Ieva A., Liu S. Meta transfer learning for brain tumor segmentation using nnUNet in meningioma and metastasis cases // Sci. Rep. 2025. Vol. 15. P. 37599. <https://doi.org/10.1038/s41598-025-20957-z>.

References

1. Tárnoki D.L., Karlinger K., Ridge C.A., Kiss F.J., Györke T., Grabczak E.M., Tárnoki Á.D. Lung imaging methods: indications, strengths and limitations. *Breathe (Sheff)*. 2024;20(3):230127. <https://doi.org/10.1183/20734735.0127-2023>.

2. Dal I., Kaya H.B. Multidisciplinary Evaluation of an AI-Based Pneumothorax Detection Model: Clinical Comparison with Physicians in Edge and Cloud Environments. *J. Multidiscip. Healthc.* 2025;18:4099-4111. <https://doi.org/10.2147/JMDH.S535405>.
3. De Biase A., Sijtsema N.M., Janssen T., Hurkmans C., Brouwer C., van Ooijen P. Clinical adoption of deep learning target auto-segmentation for radiation therapy: challenges, clinical risks, and mitigation strategies. *BJR Artificial Intelligence.* 2024;1(1):ubae015. <https://doi.org/10.1093/bjrai/ubae015>.
4. Maier-Hein L., Reinke A., Godau P., et al. Metrics reloaded: recommendations for image analysis validation. *Nat. Methods.* 2024;21(2):195-212. <https://doi.org/10.1038/s41592-023-02151-z>.
5. Reinke A., Tizabi M.D., Baumgartner M., et al. Understanding metric-related pitfalls in image analysis validation. *Nat. Methods.* 2024;21(2):182-194. <https://doi.org/10.1038/s41592-023-02150-0>.
6. Mohammadi M., Mollazade K., Behroozi-Khazaei N. Under- and over-segmentation: new metrics for image segmentation accuracy measurement. *Array.* 2025;28:100624. <https://doi.org/10.1016/j.array.2025.100624>.
7. Miglioretti D.L., Abraham L., Sprague B.L., et al. Association Between False-Positive Results and Return to Screening Mammography in the Breast Cancer Surveillance Consortium Cohort. *Ann. Intern. Med.* 2024;177(10):1297-1307. <https://doi.org/10.7326/M24-0123>.
8. Büttner M., Schneider L., Krasowski A., et al. Conquering class imbalances in deep learning-based segmentation of dental radiographs with different loss functions. *J. Dent.* 2024;148:105063. <https://doi.org/10.1016/j.jdent.2024.105063>.
9. Cabezas M., Diez Y. An Analysis of Loss Functions for Heavily Imbalanced Lesion Segmentation. *Sensors.* 2024;24(6):1981. <https://doi.org/10.3390/s24061981>.
10. Reinke A., Tizabi M. D., Maier-Hein L. Advancing standards in biomedical image analysis validation: A perspective on Metrics Reloaded. *Clin. Transl. Med.* 2025;15(9):e70237. <https://doi.org/10.1002/ctm2.70237>.
11. Malyutina I.A., Kuz'min A.A., Shatalova O.V. Methods and algorithms for analyzing chest radiographs using local windows in pathology detection tasks. *Prikaspiiskii zhurnal: upravlenie i vysokie tekhnologii = Caspian Journal: Management and High Technologies.* 2017;(3):131-138. (In Russ.)
12. Kudryavtsev P.S., Kuz'min A.A., Savinov D.Yu., Filist S.A., Shatalova O.V. Modeling of morphological formations on chest radiographs in intelligent medical diagnostic systems. *Prikaspiiskii zhurnal: upravlenie i vysokie tekhnologii = Caspian Journal: Management and High Technologies.* 2017;(3):109-120. (In Russ.)
13. Dyudin M.V., Kudryavtsev P.S., Podmaster'ev K.V., Filist S.A., Shatalova O.V. Mathematical models for intelligent systems of chest radiograph classification. *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. 2016;2(19):94-107. (In Russ.)

14. Filist S.A., Shashkova E.A., Shatalova O.V., Tomakova R.A. Analysis of biomedical images by various segmentation methods based on gradient operators. *Perspektivy razvitiya informatsionnykh tekhnologii = Prospects for the Development of Information Technology.* 2011;(3-1):146-150. (In Russ.)

15. Dabagov A.R., Gorbunov V.A., Filist S.A., et al. An Automated System for Classification of Radiographs of the Breast. *Biomedical Engineering.* 2020;53(6):425-428. <https://doi.org/10.1007/s10527-020-09957-7>.

16. Khatatneh K., Filist S., Shatalova O., et al. Hybrid neural networks with virtual flows in medical risk classifiers. *Journal of Intelligent and Fuzzy Systems.* 2022;43(1):1621–1632. <https://doi.org/10.3233/JIFS-212617>.

17. Korovin E.N., Shatalova O.V., Zhilin V.V. Application of a hybrid neural network with macrolayers for the classification of cardiovascular diseases. *Biomeditsinskaya radioelektronika = Biomedical Radioelectronics.* 2014;(9):32-37. (In Russ.)

18. Filist S., Al-Kasasbeh R.T., Shatalova O.V., et al. Biotechnical neural network system for predicting cardiovascular health state using processing of bio-signals. *International Journal of Medical Engineering and Informatics.* 2024;16(4):324-349. <https://doi.org/10.1504/IJMEI.2024.139884>.

19. Krupchatnikov R.A., Mednikov D.A., Protasova Z.U., et al. Convolutional neural network for medical risk classifier models with synergetic channels. *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.* 2021;11(2):25–50. (In Russ.)

20. Filist S.A., Myasnyankin M.B., Safronov R.I., Kuzmin A.A. Multimodal neural network classifier of the functional state of the respiratory system. *Journal of Physics: Conference Series.* 2021;2094:032064. <https://doi.org/10.1088/1742-6596/2094/3/032064>.

21. Radhachandran A., Kinzel A., Chen J., Sant V., Patel M., Masamed R., Arnold C.W., Speier W. A multitask approach for automated detection and segmentation of thyroid nodules in ultrasound images. *Comput. Biol. Med.* 2024;170:107974. <https://doi.org/10.1016/j.compbimed.2024.107974>.

22. Zhou Z., Siddiquee M.M.R., Tajbakhsh N., Liang J. UNet++: A Nested U-Net Architecture for Medical Image Segmentation. *Deep Learn Med Image Anal Multimodal Learn Clin Decis Support.* 2018;11045:3–11. https://doi.org/10.1007/978-3-030-00889-5_1.

23. Lee C.Y., Xie S., Gallagher P., Zhang Z., Tu Z. Deeply-Supervised Nets. Available at: <https://arxiv.org/abs/1409.5185> (accessed 16.03.2026).

24. Haque M.I.U., Dubey A.K., Danciu I., Justice A.C., Ovchinnikova O.S., Hinkle J.D. Effect of image resolution on automated classification of chest X-rays. *J. Med. Imaging (Bellingham)*. 2023;10(4):044503. <https://doi.org/10.1117/1.JMI.10.4.044503>.
25. Yoo S.W., Yang S., Kim J.E., et al. CACSNet for automatic robust classification and segmentation of carotid artery calcification on panoramic radiographs using a cascaded deep learning network. *Sci. Rep.* 2024;14:13894. <https://doi.org/10.1038/s41598-024-64265-4>.
26. Sim J.Z.T., Lin J., Fong Q.W., Soon A.Y.Q., Khin L.W., Balakrishnan S., Lin T., Wong S., Tan C.H. How threshold customisation affects the performance of a multiclass X-ray AI model for primary care triage: a retrospective study. *BMJ Open*. 2026;16(2):e111127. <https://doi.org/10.1136/bmjopen-2025-111127>.
27. Tabassum M., Di Ieva A., Liu S. Meta transfer learning for brain tumor segmentation using nnUNet in meningioma and metastasis cases. *Sci. Rep.* 2025;15:37599. <https://doi.org/10.1038/s41598-025-20957-z>.

Информация об авторах / Information about the Authors

Косинов Александр Владимирович, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: skosinka@yandex.ru, ORCID: 0009-0008-0426-5045

Aleksandr V. Kosinov, Postgraduate at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: skosinka@yandex.ru, ORCID: 0009-0008-0426-5045

Крупчатников Роман Анатольевич, доктор технических наук, профессор, профессор кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: roman0406@yandex.ru, ORCID: 0000-0002-4951-8607, Scopus ID: 24471766700

Roman A. Krupchatnikov, Dr. Sci. (Engineering), Professor, Professor at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: roman0406@yandex.ru, ORCID: 0000-0002-4951-8607, Scopus ID: 24471766700

Серебровский Вадим Владимирович, доктор технических наук, профессор, профессор кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: SV1111@mail.ru, Researcher ID: O-8221-2015, ORCID: 0000-0002-1923-3862

Vadim V. Serebrovsky, Dr. of Sci. (Engineering), Professor, Professor of the Department of Software Engineering, Southwest State University, Kursk, Russian Federation, e-mail: SV1111@mail.ru, Researcher ID: O-8221-2015, ORCID: 0000-0002-1923-3862

Ефремов Михаил Александрович, кандидат технических наук, доцент кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: Efremov-ma@mail.ru, ORCID: 0000-0002-2828-6261, Scopus ID: 58712948800

Mihail A. Efremov, Cand. Sci. (Engineering), Associate Professor at the Department of Information Security, Southwest State University, Kursk, Russia Federation, e-mail: Efremov-ma@mail.ru, ORCID: 0000-0002-2828-6261, Scopus ID: 58712948800

Кондрашов Дмитрий Сергеевич, кандидат технических наук, преподаватель кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: kondrashov012@mail.ru, Researcher ID: KFT-0791-2024, ORCID: 0000-0002-3925-4601

Dmitry S. Kondrashov, Cand. Sci. (Engineering), Lecturer at the Department of Biomedical Engineering, Southwest State University, Kursk, Russia Federation, e-mail: kondrashov012@mail.ru, Researcher ID: KFT-0791-2024, ORCID: 0000-0002-3925-4601

<https://doi.org/10.21869/2223-1536-2026-16-2-150-166>



УДК 004.93, 004.896

Автоматизированное распознавание форм патологий верхнечелюстных пазух в цифровой диафаноскопии с помощью свёрточных нейронных сетей

Д. В. Герасин¹ ✉, Е. О. Брянская¹, А. В. Бакотина²,
В. В. Дрёмин¹, А. В. Дунаев¹

¹ Орловский государственный университет имени И. С. Тургенева
ул. Комсомольская, д. 95, г. Орёл 302026, Российская Федерация

² Российский университет медицины Министерства здравоохранения России
ул. Долгоруковская, д. 4, г. Москва 127006, Российская Федерация

✉ e-mail: G.D.V.1984@mail.ru

Резюме

Целями исследования являются разработка и обоснование системы поддержки принятия врачебных решений, использующей алгоритм классификации патологий верхнечелюстных пазух в цифровой диафаноскопии на базе свёрточной нейронной сети ResNet-50, для повышения точности выявления патологий (синусит и кистозное изменение) в условиях скрининга здоровья населения.

Методы. Рассмотрены особенности патологий, выявлены их формы, которые чаще всего встречаются у пациентов ринологического профиля. Разработан классификатор патологий верхнечелюстных пазух на три класса по результатам анализа диафаногамм, зарегистрированных с помощью программно-аппаратного комплекса цифровой диафаноскопии, с использованием свёрточной нейронной сети ResNet-50. В работе предложены алгоритмы для системы поддержки принятия врачебных решений.

Результаты. Разработано программное средство классификации состояния тканей верхнечелюстных пазух с использованием алгоритма свёрточной нейронной сети ResNet-50, реализующее алгоритмы обучения и классификации патологий верхнечелюстных пазух. Проведена апробация разработанной системы поддержки принятия врачебных решений. Получены следующие показатели точности при дифференцировании состояния верхнечелюстных пазух на три класса: «отсутствие патологии» – чувствительность 0,94, специфичность 0,96, точность 0,95; «синусит» – чувствительность 0,9, специфичность 0,95 и точность 0,88; «кистозное изменение» – чувствительность 0,86, специфичность 0,96 и точность 0,88.

Заключение. Предлагаемая система поддержки принятия врачебных решений обеспечивает более высокую точность диагностики по сравнению с существующими экономически доступными методами. Кроме того, предложенное решение способно дифференцировать типы патологических изменений на диафаногаммах в отличие от ранее предложенных подходов в цифровой диафаноскопии. Таким образом, разработанная технология оптической диагностики состояния тканей верхнечелюстных пазух совместно с разработанной на основе СНС моделью классификации в виде системы поддержки принятия врачебных решений может быть применена как в рамках скрининга здоровья населения (для раннего выявления патологии), так и в рамках диагностики и контроля эффективности назначаемой терапии в отоларингологии, ЛОР-онкологии и стоматологии, а также в телемедицине.

Ключевые слова: цифровая диафаноскопия; синусит; кистозные заболевания; алгоритм классификации; обучение модели; свёрточные нейронные сети.

Финансирование: Работа выполнена при финансовой поддержке гранта Российского научного фонда № 24-75-00144.

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

Для цитирования: Автоматизированное распознавание форм патологий верхнечелюстных пазух в цифровой диафаноскопии с помощью свёрточных нейронных сетей / Д. В. Герасин, Е. О. Брянская, А. В. Бакотина, В. В. Дрёмин, А. В. Дунаев // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 150–166. <https://doi.org/10.21869/2223-1536-2026-16-2-150-166>.

Поступила в редакцию 28.04.2026

Подписана в печать 25.05.2026

Опубликована 30.06.2026

Automated recognition of maxillary sinus pathology forms in digital diaphanoscopy using convolutional neural networks

Dmitrii V. Gerasin¹ ✉, Ekaterina O. Bryanskaya¹, Anna V. Bakotina²,
Viktor V. Dremine¹, Andrey V. Dunaev¹

¹ Orel State University named after I.S. Turgenev
95 Komsomolskaya Str., Orel 302026, Russian Federation

² Russian University of Medicine of the Ministry of Health of Russia
4 Dolgorukovskaya Str., Moscow 127006, Russian Federation

✉ e-mail: G.D.V.1984@mail.ru

Abstract

The purposes of the research are to develop and justify a medical decision support system that uses an algorithm for classifying maxillary sinus pathologies in digital diaphanoscopy based on the ResNet-50 convolutional neural network to increase the accuracy of detecting pathologies (sinusitis and cystic change) in the context of population health screening.

Methods. The features of pathologies were considered, their forms were revealed, which are most often found in rhinological patients. A classifier of maxillary sinus pathologies was developed into three classes based on the results of the analysis of diaphanograms recorded using a digital diaphanoscopy software and hardware complex using the ResNet-50 convolutional neural network. The work proposes algorithms for a system for supporting medical decision-making.

Results. A software tool has been developed for classifying the state of maxillary sinus tissues using the ResNet-50 convolutional neural network algorithm, which implements algorithms for learning and classifying maxillary sinus pathologies. The developed medical decision support system was tested. The following accuracy indicators were obtained when differentiating the condition of the maxillary sinuses into three classes: "absence of pathology" – sensitivity 0,94, specificity 0,96, accuracy 0,95; "sinusitis" – sensitivity 0,9, specificity 0,95 and accuracy 0,88; "cystic change" – sensitivity 0,86, specificity 0,96 and accuracy 0,88.

Conclusion. The proposed medical decision support system provides more accurate diagnostics than existing economically available methods. In addition, the proposed solution is able to differentiate the types of pathological changes on diaphanograms in contrast to the previously proposed approaches in digital diaphanoscopy. In this way, the developed technology for optical diagnostics of the condition of the maxillary sinuses, together with the classification model developed on the basis of the SNS in the form of a system for supporting the adoption of medical decisions, can be used both as part of population health screening (for early detection of pathology), and as part of the diagnosis and control of the effectiveness of the prescribed therapy in otolaryngology, ENT oncology and dentistry, as well as in telemedicine.

Keywords: digital diaphanoscopy; sinusitis; cystic changes; classification algorithm; model learning; convolutional neural networks.

Funding: The study was funded by Russian Science Foundation according to the research project № 24-75-00144.

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

For citation: Gerasin D.V., Bryanskaya E.O., Bakotina A.V., Dremine V.V., Dunaev A.V. Automated recognition of maxillary sinus pathology forms in digital diaphanoscopy using convolutional neural networks. *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(2):150–166. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-150-166>.

Received 28.04.2026

Accepted 25.05.2026

Published 30.06.2026

Введение

В современной оториноларингологии, в частности ринологии, особую актуальность приобретает вопрос выявления заболеваний верхнечелюстных пазух (ВЧП) на начальных стадиях их развития. Заболевания околоносовых пазух (верхнечелюстной, лобной, решетчатой, клиновидной) относятся к числу наиболее распространенных патологий¹ в оториноларингологии и, согласно статистическим данным, сохраняют стабильно высокий уровень заболеваемости в мире [1]. Различными формами этих заболеваний страдают от 5 до 15% взрослого населения планеты. В Российской Федерации за последние десять лет заболеваемость возросла с 4,6 до 13,7 случая на 1000 человек². Среди всех околоносовых пазух наиболее часто поражается ВЧП – 93,3% слу-

чаев³, затем клиновидная – 4,3%, на долю остальных пазух приходится 2,4%⁴. Основная доля заболеваний ВЧП (85%) представлена двумя группами: воспалительные заболевания (синусит) составляют 58% [2], кистозные – 27% [3]. В отличие от синусита кистозные заболевания длительное время протекают бессимптомно [4]. При этом уже на первой стадии формируется полость, заполненная жидкостью [5]. Таким образом, важно диагностировать заболевание на ранней стадии [6], при этом актуальной задачей своевременной ринологии является совершенствование методов диагностики ВЧП [7].

Одним из перспективных методов диагностики патологий ВЧП является метод цифровой диафаноскопии [8] – неинвазивный оптический метод, основанный на зондировании (просвечивании) тканей ВЧП [9] и прилегающих к ним тканям излучением в красном (650 нм) [10] и ближнем инфракрасном (850 нм)

¹ Summary Health Statistics: National Health Interview Survey, 2018. URL: https://docs.yandex.ru/docs/view?tm=1780991152&tld=ru&lang=en&name=2018_SHS_Table_A-4.pdf&text (дата обращения: 11.03.2026).

² Заболеваемость всего населения России в 2021 году: статистические материалы / Е. Г. Котова, О. С. Кобякова, Г. А. Александрова, Н. А. Голубев, Ю. И. Оськов, А. В. Поликарпов, Е. А. Шелепова. М.: ЦНИИОИЗ Минздрава России, 2022. 146 с.

³ Отчет о результатах деятельности Федерального фонда обязательного медицинского страхования в 2021 году. М.: Правление Федерального фонда обязательного медицинского страхования, 2022. 158 с.

⁴ Петряков В. А. Оториноларингология: учебник. 2-е изд., испр. Минск: Выш. шк., 2008. 240 с.

диапазонах [11] с последующей регистрацией диафаногамм (картин рассеяния света) при помощи КМОП-камеры [12].

В работе [13] классификацию состояний тканей ВЧП, зарегистрированных на диафаногаммах, предложено осуществлять при использовании методов машинного обучения [14], что открывает новые возможности для автоматизации и повышения точности диагностики [15]. Исходя из этого, целями настоящей работы является разработка и обоснование системы поддержки принятия врачебных решений (СППВР), использующей алгоритм классификации патологий ВЧП [16] в цифровой диафаноскопии на базе свёрточной нейронной сети ResNet-50 [17], для повышения точности выявления патологий (синусит и кистозное изменение) в условиях скрининга здоровья населения [18].

Материалы и методы

Структура системы поддержки принятия врачебных решений

На рисунке 1 представлена структура СППВР, включающая подсистему принятия решений, подсистему знаний и подсистему тестирования. Менеджером в схеме является лицо, принимающее решение (ЛПР) 1, а пациентом – исследуемый 2. Исследуемый 1 первоначально заполняет добровольное информированное согласие на проведение исследования (блок сбора данных 3). ЛПР осуществляет регулировку интенсивности излучения светового потока с учётом анатомических особенностей тканей ВЧП пациента, зависящих от пола и возраста (толщина костной ткани, размеры пазух), добиваясь отсутствия засвечивания и недостатка освещённости, и начинает процедуру регистрации состояния тканей ВЧП на диафаногаммах.




Рис. 1. Структура СППВР в цифровой диафаноскопии

Fig. 1. The structure of clinical decision support system in digital diaphanography

Регистрация диафаногамм производится с помощью программно-аппаратного комплекса цифровой диафаноскопии [19]. При этом реги-

страцию диафаногамм осуществляют с разрешением 2544×1920 пикселей в 8-битном формате и монохромном виде (рис. 2, а).




Рис. 2. Пример зарегистрированной диафаногаммы (а) и результат псевдоокрашивания (б)

Fig. 2. An example of a registered diaphanogram (a) and the result of pseudo-coloring (б)

ЛПР проводит регистрацию диафаногамм при положениях головы пациента прямо и с поворотами на $30-40^\circ$ в левую и правую стороны относительно КМОП-камеры. При этом осуществляется как минимум по 3 регистрации для каждого положения головы. В результате формируется по 9 диафаногамм на каждой из двух длин волн (всего 18 диафаногамм на каждого пациента). Все диафаногаммы используются для установления диагноза. При необходимости допускается формирование большего количества диафаногамм (как правило, при неоднократных попытках формирования более чётких незасвеченных диафаногамм). Сформированные диафаногаммы добавляются в базу данных 7 (см. рис. 1) к информа-

ции пациента и используются для определения диагноза.

В процессе определения диагноза в блоке 5 из каждой диафаногаммы вырезается область интереса средствами разработанного ПО (ЛПР указывает на диафаногамме центры левой и правой интересующих областей, вокруг которых отображаются два квадрата размерностью 448×448 пикселей). При этом из каждой диафаногаммы формируется пара изображений левой и правой ВЧП, для которых осуществляется псевдоокрашивание (рис. 2, б) – замена каждого монохромного пикселя изображения соответствующей цветовой составляющей, выбираемой в соответствии с выражениями:

$$ind_{(w,h)} = (b_{(w,h)} - Mean) / Step + 1, \quad (1)$$

$$n = \begin{cases} 17 & \text{при } ind_{(w,h)} \geq 17, \\ \max(0, ind_{(w,h)}) & \text{при } ind_{(w,h)} < 17, \end{cases} \quad (2)$$

$$px_{(w,h)} = c_n, \quad \text{где } c_n \in C, \quad (3)$$

где W , H – ширина и высота диафаногаммы соответственно; $Mean$ – значение, устанавливаемое в диапазоне $[0, 255]$; $Step$ – значение, устанавливаемое в диапазоне $[0.1, 10]$; b_{wh} – значение пикселя диафаногаммы в точке (w, h) , $w \in W$, $h \in H$; c_n – значения цвета из палитры C ($c_n \in C$); $px_{(w,h)}$ – значение пикселя в точке (w, h) , $w \in W$, $h \in H$; C – цветовая палитра, состоящая из 18 уникальных цветовых оттенков.

Для определения патологий используются два классификатора, реализующие алгоритм СНС ResNet-50: бинарный классификатор 8, классификатор патологий 10 (см. рис. 1). Классификаторы подключаются к базе знаний 21 для загрузки и использования модели классификации, обученной ранее на собранных данных.

Подсистема знаний

На этапе обучения из базы данных 7 (см. рис. 1) извлекаются пары изображений левой и правой ВЧП пациентов. Формируются две выборки: первая состоит из изображений в прямой проекции с наличием и отсутствием патологий, используемая для обучения бинарного классификатора; вторая включает изображения с верифицированными синуситом и кистозными изменениями, зафиксированными в трёх пространственных положениях головы, и используется для обучения классификатора патологий.

Для повышения точности классификации за счёт кратного увеличения количества обучающей выборки используется блок аугментации данных 14. Здесь выполняется искусственное изменение цветности за счёт последовательного изменения значений каждого RGB-канала на 5–15 единиц, а также применяются функции аффинных преобразований – поворот и сдвиг. Поворот изображений осуществляется на две позиции по часовой стрелке и на две – против часовой стрелки, что позволяет четырёхкратно увеличить количество данных. Затем выполняется сдвиг «по кольцу» (вправо-вверх, вправо, вправо-вниз, вниз, влево-вниз, влево, влево-вверх, вверх), благодаря которому достигается восьмикратное увеличение уже сформированного количества данных. Аугментированные данные используются обоими классификаторами.

В блоке 15 осуществляется разделение выборки данных на обучающую, валидационную и тестовую в соотношении 70, 20, 10% соответственно, которые используются при обучении моделей классификации и участвуют в оценке их результативности. Для исключения смешивания классов данных разбиение данных осуществляется по пациентам. Затем осуществляется обучение бинарного классификатора и отдельно классификатора патологий.

Бинарный классификатор

Первым используется бинарный классификатор 8, который для каждого изображения определяет наличие / отсутствие патологии. Рассмотрим схему алгоритма бинарной классификации

(рис. 3). Для текущего классификатора используются изображения, сформированные из диафаногамм с положением головы прямо. Классификатор определяет наличие или отсутствие патологии. При наличии патологии также определяется сторона расположения патологии (левосторонняя, правосторонняя, двухсторонняя) с использованием алгоритма, реализующего условные операторы. Окончательное решение форми-

руется в блоке принятия решения бинарного классификатора 9 (рис. 1) на основе

$$y = \max \left(\sum_{n=1}^N P(x_n)_s \right), \quad (4)$$

где $P(x_n)_s$ – вероятность принадлежности n -го изображения к классу s (двухсторонняя патология, левосторонняя патология, правосторонняя патология, отсутствие патологии).




Рис. 3. Схема алгоритма бинарной классификации

Fig. 3. The scheme of the binary classification algorithm

Классификатор патологий

При выявлении патологии задействуется классификатор патологий 10 (рис. 1), который относит каждое изображение с патологией к одному из двух состояний i : синусит, кистозное изменение. Если в блоке 8 патологии не выявлены, то классификатор патологий 10

не используется. При выявлении патологии с левой стороны классификатор проводит анализ изображений левой ВЧП пациента, для правой стороны – правой ВЧП, для обеих сторон – все пары изображений, сформированные из диафаногамм пациента с обеих сторон. Результаты классификации по всем изображениям направляются в блок 11

для принятия решения, где при использовании решающего правила (5) принимается окончательное решение о при-

надлежности патологии к классу i . Схема алгоритма бинарной классификации представлена ниже (рис. 4).




Рис. 4. Схема алгоритма классификации ВЧП на 3 класса: «патология отсутствует», «синусит», «кистозное изменение»

Fig. 4. The scheme of for classification maxillary sinuses into 3 classes: "absence of pathology", "sinusitis", "cystic change"

Окончательный результат формируется в блоке 12 и отображается ЛПР в интерфейсе программного средства 22 (см. рис. 1).

$$y = \max \left(\sum_{n=1}^N P(x_n)_i \right), \quad (5)$$

где $P(x_n)_i$ – вероятность принадлежности n -го изображения к классу i (синусит, кистозные изменения).

Таким образом, представленную СППВР предлагается использовать для определения наличия / отсутствия патологии, при наличии патологии – отнесение к одному из двух классов: синусит, кистозные изменения с указанием стороны расположения (левосторонняя, правосторонняя, двухсторонняя). Выработанные алгоритмы на основе машинного обучения [20] и предложенная СППВР позволяют ЛПР определять патологии в условиях скрининга здоровья населения [21].

Дополнительно проведена экспериментальная оценка альтернативных методов. К ним относятся: вычисление медианы вероятностей, характеризующееся повышенной робастностью к выбросам; перемножение вероятностей, а также взвешенное голосование, при котором каждому снимку присваивается индивидуальный вес, на который умножается предсказанная вероятность, после чего взвешенные значения суммируются и сравниваются между классами.

Каждый из перечисленных алгоритмов обладает недостатками, обусловившими отказ от их использования в финальной версии системы. Метод усреднения нивелирует информацию о распределении уверенности в ситуациях, когда большинство изображений

демонстрируют средние значения вероятностей. Перемножение вероятностей критически чувствительно к результатам с низкими значениями, что может приводить к неоправданному занижению итоговой оценки. Взвешенное голосование, в свою очередь, требует от ЛПР выполнения дополнительной разметки – присвоения весов каждому изображению. В условиях скрининга здоровья населения такой подход не отвечает поставленным требованиям, поскольку сопряжён с существенными временными затратами и необходимостью квалифицированной оценки качества каждой диафаногаммы. Ошибка при назначении весов может иметь серьёзные последствия, тогда как СППВР должна брать на себя рутинные задачи, а не перекладывать на ЛПР трудоёмкую ручную разметку. Следовательно, взвешенное голосование вступает в противоречие с фундаментальной концепцией разрабатываемой СППВР.

Исследуемая группа


Апробация предложенного классификатора проводилась на базе Клинического центра челюстно-лицевой, реконструктивно-восстановительной и пластической хирургии Российского университета медицины Минздрава России (г. Москва), а также НТЦ биомедицинской фотоники ОГУ имени И. С. Тургенева (г. Орёл). С использованием предложенной СППВР проанализировано более 100 пациентов в возрасте 45 лет [22] и более 100 условно-здоровых добровольцев в возрасте 23 лет [23].

Результаты и их обсуждение


Разработано программное средство классификации состояния тканей

ВЧП на три класса (синусит, кистозные изменения, отсутствие патологии) на зарегистрированных методом цифровой диафаноскопии диафанограммах с использованием алгоритма свёрточной нейронной сети ResNet-50 (рис. 5), реализующее представленные алгоритмы обучения и классифи-


кации патологий ВЧП. Основными функциональными возможностями программы являются: создание классификаторов, обучение моделей классификаторов, классификация состояния тканей ВЧП с использованием выбранного обученного классификатора [24].



а



б



в

Рис. 5. Интерфейс программного средства классификации патологий (а), интерфейс блока обучения (б), блока классификации (в)

Fig. 5. Interface of the pathology classification software (а), interface of the training unit (б), classification unit (в)

В режиме обучения выбранного классификатора (рис. 5, б) отображается интерфейс, в котором необходимо выбрать каталог, содержащий подкаталоги с изображениями, соответствующими обучаемым классам. В программе реализована настройка для ограничения максимального количества загружаемых изображений в процентном отношении. Также реализована возможность дообучения модели. В процессе обучения формируется новая модель либо дообучается существующая, которая становится доступной в режиме классификации.

В режиме классификации (рис. 5, в) реализована функция последовательной потоковой обработки изображений. Подготовленные пары изображений, отражающих состояние тканей ВЧП пациента, поочередно загружаются и передаются классификатору. Используя обученную модель, классификатор относит каждое анализируемое изображение к одному из заданных классов, а результат фиксируется во внутреннем буфере. Цикл повторяется для всех изображений. По завершении процесса пользователь нажимает кнопку «Сравнить статистику (для Python)», после чего накопленная статистика экспортируется в файл для вынесения окончательного диагноза.

Апробация предложенного классификатора позволила получить следующие показатели точности при дифференцировании состояния ВЧП на 3 класса: «отсутствие патологии» – чувстви-

тельность 0,94, специфичность 0,96, точность 0,95; «синусит» – чувствительность 0,9, специфичность 0,95 и точность 0,88; «кистозное изменение» – чувствительность 0,86, специфичность 0,96 и точность 0,88.

Выводы

В рамках исследования предложена СППВР, предназначенная для оказания практической помощи врачу при скрининговом обследовании населения методом цифровой диафаноскопии. Данная СППВР обеспечивает высокоточное распределение диафаногамм по трём классам (синусит, кистозные изменения, отсутствие патологии) с точностью 0,88; 0,88 и 0,95 соответственно. По сравнению с существующими экономически доступными методами (назальной эндоскопией, ультразвуковой диагностикой и рентгенографией) предлагаемый подход обеспечивает более высокую точность диагностики. Кроме того, он выгодно отличается от применявшегося ранее в диафаноскопии метода линейно-дискриминантного анализа. Последний представляет собой бинарный классификатор, позволяющий лишь констатировать наличие или отсутствие патологии, тогда как предложенное решение способно дифференцировать типы патологических изменений на диафаногаммах.

Таким образом, разработанная технология оптической диагностики состояния тканей ВЧП совместно с разработанной на основе СНС моделью клас-

сификации в виде СППВР может быть применена как в рамках скрининга здоровья населения (для раннего выявления патологии), так и в рамках диагно-

стики и контроля эффективности назначаемой терапии в отоларингологии, ЛОР-онкологии и стоматологии, а также в телемедицине.

Список литературы

1. Распространенность и структура заболеваний носа и околоносовых пазух среди взрослого населения мегаполиса / А. И. Крюков, Г. Ю. Царапкин, С. Г. Романенко, А. С. Товмасын, С. А. Панасов // Российская ринология. 2017. Т. 25, № 1. С. 3–6. <https://doi.org/10.17116/ROSRINO20172513-6>.

2. Применение метода терагерцовой газовой спектроскопии высокого разрешения для анализа состава продуктов термического разложения тканей кист околоносовых пазух / А. А. Айзенштадт, В. А. Анфертьев, В. Л. Вакс, К. А. Гаврилова, Е. Г. Домрачева, Р. А. Ларин, М. Б. Черняева // Оптический журнал. 2021. Т. 88, № 3. С. 72–76. <https://doi.org/10.17586/1023-5086-2021-88-03-72-76>.

3. Острый риносинусит: терапия с акцентом на ключевые звенья патогенеза / Е. В. Носуля, И. А. Ким, Ю. В. Лучшева, Д. С. Огородников // Российская ринология. 2023. Т. 31, № 3. С. 212–218. <https://doi.org/10.17116/rosrino202331031212>.

4. Пальчун В. Т., Гуров А. В. Болезни уха, горла и носа. 3-е изд., испр. М.: ГЭОТАР-Медиа, 2020. 336 с.

5. Методы оценки функционального состояния слизистой оболочки верхнечелюстных пазух (обзор литературы) / М. М. Магомедов, Ш. Ю. Авкаева, О. Н. Рождественская, Т. Н. Жоголева // Вестник оториноларингологии. 2026. Т. 91, № 1. С. 70–75. <https://doi.org/10.17116/10.17116/otorino20269101170>.

6. Whyte A., Boeddinghaus R. The maxillary sinus: physiology, development and imaging anatomy // Dentomaxillofacial Radiology. 2019. Vol. 48, N 8. P. 20190205. <https://doi.org/10.1259/dmfr.20190205>.

7. Исмаилова М. Х., Салиджанов У. М. Особенности диагностики хронических воспалительных заболеваний придаточных пазух носа // European Research: Innovation in Science, Education and Technology: Collection of scientific articles XLVIII International correspondence scientific and practical conference. London: United Kingdom: Problems of Science, 2019. P. 83–86.

8. Digital diaphanoscopy of the maxillary sinuses: A revival of optical diagnosis for rhinosinusitis / K. Stoezel, A. J. Szczepek, H. Olze, S. Koss, O. Minet, U. Zabarylo // American Journal of Otolaryngology. 2020. Vol. 41, N 3. P. 102444. <https://doi.org/10.1016/j.amjoto.2020.102444>.

9. Волков А. Г., Бойко Н. В., Стагниева И. В. Заболевания носа и околоносовых пазух у беременных. Особенности диагностики (обзор литературы) // Российская оториноларингология. 2017. № 2. С. 113–119. <https://doi.org/10.18692/1810-4800-2017-2-113-119>.

10. Optical Diagnostics of the Maxillary Sinuses by Digital Diaphanoscopy Technology / E. O. Bryanskaya, I. N. Novikova, V. V. Dremin, R. Y. Gneushev, O. A. Bibikova,

A. V. Dunaev, V. G. Artyushenko // *Diagnostics*. 2021. Vol. 77, N 11. P. 77. <https://doi.org/10.3390/diagnostics11010077>.

11. Digital diaphanoscopy of maxillary sinus pathologies supported by machine learning / E. O. Bryanskaya, V. V. Dremine, V. V. Shupletsov, A. V. Kornaev, M. Yu. Kirillin, A. V. Bakotina, D. N. Panchenkov, K. V. Podmasteryev, V. G. Artyushenko, A. V. Dunaev // *Journal of Biophotonics*. 2023. Vol. 17, is. 1. P. e202300138. <https://doi.org/10.1002/jbio.202300138>.

12. Брянская Е. О. Метод и устройство цифровой диафаноскопии для диагностики патологий верхнечелюстных пазух // *Медицинская техника*. 2023. № 3. С. 5–7.

13. The Use of Convolutional Neural Networks to Classify the States of the Maxillary Sinuses in Digital Diaphanoscopy / D. V. Gerasin, E. O. Bryanskaya, V. V. Dremine, A. V. Dunaev // *2024 Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex (TIRVED)*. Moscow: IEEE, 2024. P. 1–4. <https://doi.org/10.1109/TIRVED63561.2024.10769806>.

14. Erhan L., Liotta A., Cavallaro L. Comparing Training of Sparse to Classic Neural Networks for Binary Classification in Medical Data. *Advances in Mobile Computing and Multimedia Intelligence*. Cham: Springer, 2025. P. 15341. https://doi.org/10.1007/978-3-031-78049-3_10.

15. Artificial intelligence, machine learning, and deep learning in rhinology: a systematic review / A. M. Bulfamante, F. Ferella, A. M. Miller, C. Rosso, C. Pipolo, E. Fuccillo, G. Felisati, A. M. Saibene // *European Archives of Oto-Rhino-Laryngology*. 2022. Vol. 280, N 2. P. 1–14. <https://doi.org/10.1007/S00405-022-07701-3>.

16. Nibali A., He Z., Wollersheim D. Pulmonary nodule classification with deep residual networks // *Int. J. Comput. Assist. Radiol. and Surg.* 2017. Vol. 12, N 10. P. 1799–1808. <https://doi.org/10.1007/S11548-017-1605-6/FIGURES/10>.

17. Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning? / N. Tajbakhsh, J. Y. Shin, S. R. Gurudu, R. T. Hurst, C. B. Kendall, M. B. Gotway // *IEEE Transactions on Medical Imaging*. 2016. Vol. 35, N 5. P. 1299–1312. <https://doi.org/10.1109/TMI.2016.2535302>.

18. Artificial intelligence, machine learning, and deep learning in rhinology: a systematic review / A. M. Bulfamante, F. Ferella, A. M. Miller, C. Rosso, C. Pipolo, E. Fuccillo, G. Felisati, A. M. Saibene // *Eur. Arch. Otorhinolaryngol.* 2023. Vol. 280. P. 529–542. <https://doi.org/10.1007/s00405-022-07701-3>.

19. Классификация состояний верхнечелюстных пазух по данным цифровой диафаноскопии с применением машинного обучения / Е. О. Брянская, Д. В. Герасин, А. В. Бакотина, Ю. О. Николаева, А. Ю. Овчинников, В. В. Дрёмин, А. В. Дунаев // *Российская ринология*. 2026. Т. 34, № 1. С. 19–26. <https://doi.org/10.17116/ROSRINO20263401119>.

20. Conigliaro J., Kapoor S. Screening. Physical Exam. Health Maintenance // *Handbook of Outpatient Medicine* / ed. by E. Sydney, E. Weinstein, L. M. Rucker. Cham: Springer, 2022. P. 3–44. https://doi.org/10.1007/978-3-031-15353-2_1.

21. Screening. When is it appropriate and how can we get it right? / A. Sagan, D. McDaid, S. Rajan, J. Farrington, M. McKee. Denmark: World Health Organization, 2020. 22 p.

22. The application of ultrasound examination in the treatment of Acute Sinusitis. Comparing X-ray to ultrasound of paranasal sinuses / A. Valkov, G. Nikolov, B. Duhlenki, Tsv. Stoyanov, Tsv. Mladenov, M. Yildiz, Kr. Atanasova, St. Mirchev, Kr. Valcheva // *International Bulletin of Otorhinolaryngology*. 2021. Vol. 17, N 1. P. 40–41.

23. The Role of Diagnostic Nasal Endoscopy and a Computed Tomography Scan (Nose and PNS) in the Assessment of Chronic Rhinosinusitis: A Comparative Evaluation of the Two Techniques / K. Nathan, S. K. Majhi, R. Bhardwaj, A. Gupta, S. Ponnusamy, C. Basu, A. Kaushal // *Sinusitis*. 2021. Vol. 5, N 1. P. 59–66. <https://doi.org/10.3390/SINUSITIS5010007>.

24. Hsu C. C., Sheng C., Ho C. Y. Efficacy of sinus ultrasound in diagnosis of acute and subacute maxillary sinusitis // *J. Chinese Med. Assoc.* 2018. Vol. 81, N 10. P. 898–904. <https://doi.org/10.1016/J.JCMA.2018.03.005>.

References

1. Krukov A.I., Tsarapkin G.Yu., Romanenko S.G., Tovmasian A.S., Panasov S.A. The prevalence and structure of diseases of the nose and paranasal sinuses among the adult population of a megalopolis. *Rossiiskaya rinologiya = Russian rhinology*. 2017;25(1):3-6. (In Russ.) <https://doi.org/10.17116/ROSRINO20172513-6>.

2. Aisenstadt A.A., Anfertiev V.A., Vaks V.L., Gavrilova K.A., Domracheva E.G., Larin R.A., Chernyaeva M.B. Application of the high resolution terahertz gas spectroscopy method for analyzing the composition of thermal decomposition products of tissues of cysts of the sinuses. *Opticheskii Zhurnal = Optical Magazine*. 2021;88(3):72–76. (In Russ.) <http://doi.org/10.17586/1023-5086-2021-88-03-72-76>.

3. Nosulya E.V., Kim I.A., Luchsheva Yu.V., Ogorodnikov D.S. Acute rhinosinusitis: treatment with a focus on key elements of pathogenesis. *Rossiiskaya rinologiya = Russian Rhinology*. 2023;31(3):212-218. (In Russ.) <https://doi.org/10.17116/rosrino202331031212>.

4. Palchun V. T., Gurov A.V. Diseases of the ear, throat and nose. 3rd ed. Moscow: GEOTAR-Media; 2020. 336 p. (In Russ.)

5. Magomedov M.M., Avkaeva Sh.Yu., Rozhdestvenskaya O.N., Zhogoleva T.N. Methods for assessing the functional state of the mucous membrane of the maxillary sinuses (literature review). *Vestnik otorinolaringologii = Bulletin of Otorhinolaryngology*. 2026;91(1):70-75. (In Russ.) <https://doi.org/10.17116/10.17116/otorino20269101170>.

6. Whyte A., Boeddinghaus R. The maxillary sinus: physiology, development and imaging anatomy. *Dentomaxillofacial Radiology*. 2019;48(8):20190205. <https://doi.org/10.1259/dmfr.20190205>.

7. Ismailova M.H., Salidzhanov U.M. Features of diagnosis of chronic inflammatory diseases of the paranasal sinuses. In: *European Research: Innovation in Science, Education and Technology: Collection of scientific articles XLVIII International correspondence scientific and practical conference*. London: United Kingdom: Problems of Science; 2019. P. 83–86. (In Russ.)

8. Stoelzel K., Szczepek A.J., Olze H., Koss S., Minet O., Zabarylo U. Digital diaphanoscopy of the maxillary sinuses: A revival of optical diagnosis for rhinosinusitis. *American Journal of Otolaryngology*. 2020;41(3):102444. <https://doi.org/10.1016/J.amjoto.2020.102444>.
9. Volkov A.G., Boyko N.V., Stagnieva I.V. Diseases of the nose and paranasal sinuses in pregnant women. Diagnostic features (literature review). *Rossiiskaya otorinolaringologiya* = Russian otorhinolaryngology. 2017;(2):113-119. (In Russ.) <https://doi.org/10.18692/1810-4800-2017-2-113-119>.
10. Bryanskaya E.O., Novikova I.N., Dremin V.V., Gneushev R.Y., Bibikova O.A., Dunaev A.V., Artyushenko V.G. Optical Diagnostics of the Maxillary Sinuses by Digital Diaphanoscopy Technology. *Diagnostics*. 2021;77(11):77. <https://doi.org/10.3390/diagnostics11010077>.
11. Bryanskaya E.O., Dremin V.V., Shupletsov V.V., Kornaev A.V., Kirillin M.Yu., Bakotina A.V., Panchenkov D.N., Podmasteryev K.V., Artyushenko V.G., Dunaev A.V. Digital diaphanoscopy of maxillary sinus pathologies supported by machine learning. *Journal of Biophotonics*. 2023;17(1):e202300138. <https://doi.org/10.1002/jbio.202300138>.
12. Bryanskaya E.O. Method and device of digital diaphanoscopy for the diagnosis of maxillary sinus pathologies. *Meditsinskaya tekhnika* = Medical Technology. 2023;(3):5-7. (In Russ.)
13. Gerasin D.V., Bryanskaya E.O., Dremin V.V., Dunaev A.V. The use of convolutional neural networks to classify the states of the maxillary sinuses in digital diaphanoscopy. In: *2024 Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex (TIRVED)*. Moscow: IEEE; 2024. P. 1–4. <https://doi.org/10.1109/TIRVED63561.2024.10769806>.
14. Erhan L., Liotta A., Cavallaro L. Comparing Training of Sparse to Classic Neural Networks for Binary Classification in Medical Data. *Advances in Mobile Computing and Multimedia Intelligence*. Cham: Springer; 2025. P. 15341. https://doi.org/10.1007/978-3-031-78049-3_10.
15. Bulfamante A.M., Ferella F., Miller A.M., Rosso K., Pipolo K., Fuccillo E., Felisati G., Saibene A.M. Artificial intelligence, machine learning, and deep learning in rhinology: a systematic review. *European Archives of Oto-Rhino-Laryngology*. 2022;280(2):1-14. <https://doi.org/10.1007/S00405-022-07701-3>.
16. Nibali A., He Z., Wollersheim D. Pulmonary nodule classification with deep residual networks. *Int. J. Comput. Assist. Radiol. and Surg.* 2017;12(10):1799-1808. <https://doi.org/10.1007/S11548-017-1605-6/FIGURES/10>.
17. Taybakhsh N., Shin J.Y., Gurudu S.R., Hurst R.T., Kendall K.B., Gotway M.B. Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning? *IEEE Transactions on Medical Imaging*. 2016;35(5):1299-1312. <https://doi.org/10.1109/TMI.2016.2535302>.
18. Bulfamante A.M., Ferella F., Miller A.M., Rosso K., Pipolo K., Fuccillo E., Felisati G., Saibene A.M. Artificial intelligence, machine learning, and deep learning in rhinology: a systematic review. *Eur. Arch. Otorhinolaryngol.* 2023;280:529-542. <https://doi.org/10.1007/s00405-022-07701-3>.

19. Bryanskaya E.O., Gerasin D.V., Bakotina A.V., Nikolaeva Yu.O., Ovchinnikov A.Y., Dremine V.V., Dunaev A.V. Classification of maxillary sinus conditions according to digital diaphanoscopy using machine learning. *Rossiiskaya rinologiya = Russian Rhinology*. 2026;34(1):19-26. (In Russ.) <https://doi.org/10.17116/ROSRINO20263401119>.
20. Conigliaro J., Kapoor S. Screening. Physical Exam. Health Maintenance. In: Sidney E., Weinstein E., Rucker L.M. (eds.). *Handbook of outpatient Medicine*. // Handbook of Outpatient Medicine / ed. by E. Sydney, E. Weinstein, L. M. Rucker. Cham: Springer; 2022. P. 3–44. https://doi.org/10.1007/978-3-031-15353-2_1.
21. Sagan A., McDade D., Rajan S., Farrington J., McKee M. Screening. When is it appropriate and how can we get it right? Denmark: World Health Organization; 2020. 22 p.
22. Valkov A., Nikolov G., Duhlenky B., Stoyanov C., Mladenov C., Yildiz M., Atanasova K., Mirchev S., Valcheva K. The application of ultrasound examination in the treatment of Acute Sinusitis. Comparing X-ray to ultrasound of paranasal sinuses. *International Bulletin of Otorhinolaryngology*. 2021;17(1):40-41.
23. Nathan K., S. Maji K., Bhardwaj R., Gupta A., Ponnusamy S., Basu S., Kaushal A. The Role of Diagnostic Nasal Endoscopy and a Computed Tomography Scan (Nose and PNS) in the Assessment of Chronic Rhinosinusitis: A Comparative Evaluation of the Two Techniques. *Sinusitis*. 2021;5(1):59-66. <https://doi.org/10.3390/SINUSITIS5010007>.
24. Hsu C.C., Sheng C., Ho C.Y. Efficacy of sinus ultrasound in diagnosis of acute and subacute maxillary sinusitis. *J. Chinese Med. Assoc.* 2018;81(10):898-904. <https://doi.org/10.1016/J.JCMA.2018.03.005>.

Информация об авторах / Information about the Authors

Дмитрий Владимирович Герасин, стажер-исследователь научно-технологического центра биомедицинской фотоники, Орловский государственный университет имени И. С. Тургенева, г. Орёл, Российская Федерация, e-mail: G.D.V.1984@mail.ru, ORCID: 0009-0002-1936-8545, Author ID: 1326548

Dmitrii V. Gerasin, Research Assistant at the Research and Development Center of Biomedical Photonics, Orel State University named after I. S. Turgenev, Orel, Russian Federation, e-mail: G.D.V.1984@mail.ru, ORCID: 0009-0002-1936-8545, Author ID: 1326548

Екатерина Олеговна Брянская, кандидат технических научных, научный сотрудник научно-технологического центра биомедицинской фотоники, Орловский государственный университет имени И. С. Тургенева, г. Орёл, Российская Федерация, e-mail: branskayae@mail.ru, ORCID: 0000-0002-2950-4443, Author ID: 1015210

Ekaterina O. Bryanskaya, Candid. Sci. (Engineering), Research Fellow at the Research and Development Center of Biomedical Photonics, Orel State University named after I. S. Turgenev, Orel, Russian Federation, e-mail: branskayae@mail.ru, ORCID: 0000-0002-2950-4443, Author ID: 1015210

Анна Васильевна Бакотина, кандидат медицинских наук, ассистент кафедры оториноларингологии, Российский университет медицины Министерства здравоохранения России, г. Москва, Российская Федерация, e-mail: bakotina88@gmail.com, ORCID: 0000-0003-2750-6899, Author ID: 1343762

Виктор Владимирович Дрёмин, кандидат технических наук, старший научный сотрудник научно-технологического центра биомедицинской фотоники, Орловский государственный университет имени И. С. Тургенева, г. Орёл, Российская Федерация, e-mail: dremin_viktor@mail.ru, ORCID: 0000-0001-6974-3505, Author ID: 787806

Андрей Валерьевич Дунаев, доктор технических, доцент, ведущий научный сотрудник научно-технологического центра биомедицинской фотоники, Орловский государственный университет имени И. С. Тургенева, г. Орёл, Российская Федерация, e-mail: dunaev@bmecenter.ru, ORCID: 0000-0003-4431-6288, Author ID: 212404

Anna V. Bakotina, Candid. Sci. (Medical), Assistant at the Department of Otorhinolaryngology, Russian University of Medicine of the Ministry of Health of Russia, Moscow, Russian Federation, e-mail: bakotina88@gmail.com, ORCID: 0000-0003-2750-6899, Author ID: 1343762

Viktor V. Dremine, Candid. Sci. (Medical), Senior Researcher at the Biomedical Photonics Research and Technology Center, Orel State University named after I. S. Turgenev, Orel, Russian Federation, e-mail: dremin_viktor@mail.ru, ORCID: 0000-0001-6974-3505, Author ID: 787806

Andrey V. Dunaev, Dr. Sci. (Engineering), Associate Professor, Leading Researcher Fellow at the Research and Development Center of Biomedical Photonics, Orel State University named after I. S. Turgenev, Orel, Russian Federation, e-mail: dunaev@bmecenter.ru, ORCID: 0000-0003-4431-6288, Author ID: 212404

Сравнительное исследование инструментов статического анализа PHP-кода

Я. В. Огневой¹, А. Г. Спеваков¹✉, И. В. Калущкий¹, П. А. Клименко²

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

² Курский филиал Финансового университета при Правительстве Российской Федерации
ул. Ломоносова, д. 3, г. Курск 305016, Российская Федерация

✉ e-mail: aspev@yandex.ru

Резюме

Целью исследования является сравнительный анализ инструментов статического анализа PHP-кода для оценки их эффективности в выявлении ошибок, потенциальных уязвимостей и проблем типизации на ранних этапах разработки веб-приложений. Особое внимание уделяется определению практической применимости рассматриваемых решений в проектах различного масштаба, а также их влиянию на повышение качества программного обеспечения, снижение числа дефектов в коде и минимизацию рисков безопасности.

Методы. В исследовании использован метод сравнительного анализа, основанный на тестировании инструментов на наборе типовых сценариев, отражающих распространённые ошибки и уязвимости PHP-приложений. Оценка инструментов проводилась по критериям полноты выявления ошибок, точности диагностики, гибкости настройки правил, удобства интеграции в процесс разработки, производительности и потребления ресурсов. Дополнительно был выполнен анализ документации и возможностей конфигурации. Все эксперименты проводились многократно для обеспечения статистической достоверности результатов.

Результаты. В ходе исследования выявлены различия в глубине анализа, строгости проверки типов и механизмах настройки правил. Установлено, что инструменты демонстрируют различную чувствительность к логическим ошибкам, несоответствиям типов и потенциально небезопасным конструкциям. Определены их сильные и слабые стороны в контексте использования в малых и крупных проектах.

Заключение. Результаты подтверждают эффективность применения инструментов статического анализа как средства повышения качества и безопасности PHP-кода. Выбор конкретного решения должен основываться на требованиях проекта, уровне строгости анализа и особенностях процесса разработки. Регулярное использование таких инструментов позволяет существенно снизить риск появления дефектов и уязвимостей, повышая надёжность и устойчивость веб-приложений.

Ключевые слова: статический анализ кода; безопасность PHP; анализ уязвимостей; качество программного обеспечения; безопасная разработка; автоматизированные инструменты анализа.

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

Для цитирования: Сравнительное исследование инструментов статического анализа PHP-кода / Я. В. Огневой, А. Г. Спеваков, И. В. Калутский, П. А. Клименко // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 167–181. <https://doi.org/10.21869/2223-1536-2026-16-3-167-181>.

Поступила в редакцию 08.04.2026

Подписана в печать 07.05.2026

Опубликована 30.06.2026

Comparative study of PHP code static analysis tools

Yaroslav V. Ognevoy¹, Alexander G. Spevakov¹ ✉,
Igor V. Kalutskiy¹, Pavel A. Klimenko²

¹ Moscow Polytechnic University
38 Bolshaya Semyonovskaya Str., Moscow 107023, Russian Federation

² Kursk Branch of the Financial University under the Government of the Russian Federation
3 Lomonosova Str., Kursk 305016, Russian Federation

✉ e-mail: aspev@yandex.ru

Abstract

The purpose of the research is a comparative analysis of static PHP code analysis tools to assess their effectiveness in identifying errors, potential vulnerabilities, and typing problems in the early stages of web application development. Particular attention is paid to determining the practical applicability of the solutions under consideration in projects of various scales, as well as their impact on improving software quality, reducing the number of defects in the code and minimizing security risks.

Methods. The study uses a comparative analysis method based on testing tools on a set of typical scenarios reflecting common errors and vulnerabilities of PHP applications. The tools were evaluated according to the criteria of completeness of error detection, accuracy of diagnosis, flexibility of rule configuration, ease of integration into the development process, productivity and resource consumption. Additionally, an analysis of documentation and configuration options was performed. All experiments were carried out repeatedly to ensure the statistical reliability of the results.

Results. The study revealed differences in the depth of analysis, the rigor of type checking, and the mechanisms for configuring rules. It has been found that the tools exhibit varying sensitivity to logical errors, type inconsistencies, and potentially unsafe designs. Their strengths and weaknesses have been identified in the context of use in small and large projects.

Conclusion. The results confirm the effectiveness of using static analysis tools as a means of improving the quality and security of PHP code. The choice of a specific solution should be based on the requirements of the project, the level of rigor of the analysis and the specifics of the development process. Regular use of such tools can significantly reduce the risk of defects and vulnerabilities, increasing the reliability and stability of web applications.

Keywords: static code analysis; PHP security; vulnerability analysis; software quality; secure development; automated analysis tools.

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

For citation: Ognevoy Y.V., Spevakov A.G., Kalutskiy I.V., Klimenko P.A. Comparative study of PHP code static analysis tools. *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(2):167–181. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-167-181>.

Received 08.04.2026

Accepted 07.05.2026

Published 30.06.2026

Введение

PHP остаётся одной из наиболее востребованных платформ для создания веб-приложений. Вместе с ростом сложности проектов увеличивается вероятность появления ошибок, которые могут негативно повлиять на безопасность системы. Наиболее уязвимыми оказываются участки исходного кода, в которых разработчик допускает логические неточности, неверно обрабатывает данные или нарушает принципы безопасного программирования. Поэтому задача своевременного выявления подобных проблем имеет большое значение.

Практика показывает, что проверка качества и безопасности кода может выполняться двумя основными способами – динамическим и статическим анализом. Динамический анализ основывается на исполнении программы, в то время как статический позволяет выявлять потенциальные ошибки без запуска кода, на этапе разработки. Эта особенность делает статический анализ ценным для среды PHP-разработки, где ошибки нередко проявляются во время выполнения и могут оставаться незамеченными [1].

Современные инструменты статического анализа для PHP (такие как PHPStan, Psalm и Phan) предоставляют широкий набор механизмов для выявления типичных ошибок, нарушений типизации, некорректных зависимостей и потенциальных уязвимостей [2]. Несмотря на общую цель, каждый из них использует собственные подходы и имеет различную глубину анализа, что приводит к различиям в полноте обнаружения проблем и количестве ложных предупреждений [3]. Это делает актуальным проведение сравнительного ис-

следования, позволяющего оценить сильные и слабые стороны данных инструментов на основе единых критериев и типичных сценариев ошибок.

Материалы и методы

Верификация программного обеспечения без запуска анализируемых программ

Статический анализ кода позволяет проводить верификацию программного обеспечения без запуска анализируемых программ. Вместо выполнения кода, инструменты статического анализа исследуют исходный код на предмет соответствия заданным правилам, шаблонам уязвимостей и потенциально опасным конструкциям. Это позволяет выявлять ошибки и уязвимости безопасности на ранних этапах разработки [4].

Рассмотрим обобщённый процесс работы инструментов статического анализа (рис. 1).

В данном исследовании рассматриваются три наиболее распространённых средства статического анализа с открытым исходным кодом для PHP. Ниже приведено краткое описание каждого из них.

PHPStan – один из наиболее распространённых статических анализаторов; работает на основе строгой проверки типов и анализа структуры программы. Использует собственную иерархию уровней строгости (от 0 до 9), где каждый уровень добавляет более детализированные проверки. PHPStan помогает обнаруживать ошибки типизации, недостижимый код, некорректные сигнатуры методов, ошибки в работе с массивами и данные, которые потенциально могут привести к логическим уязвимостям. Имеет модульную

архитектуру и поддержку расширений, легко интегрируется в существующие проекты и CI/CD-пайплайны [5].

Psalm – мощный статический анализатор, часто рассматриваемый в роли альтернативы PHPStan. Известен глубоким анализом типов, поддержкой аннотаций и встроенными механизмами проверки кода, помогающими выявлять потенциальные проблемы безопасности

[6]. В Psalm реализована система уровней строгости, где каждый уровень включает всё более детализированные проверки: от базовой типизации и поиска ошибок до сложного анализа логики программы и потенциально небезопасных операций. Такая структура позволяет гибко настраивать глубину анализа под конкретный проект и требования к качеству кода [7].




Рис. 1. Этапы статического анализа кода

Fig. 1. The stages of static code analysis

Phan один из первых статических анализаторов, ориентированных на современные версии PHP и систему типов, введённую в PHP 7+. Способен выявлять широкий спектр ошибок: использование неопределённых переменных и методов, несоответствие типов, ошибки в наследовании и типовые нарушения. Phan часто обнаруживает дополнительные логические несоответствия, однако может быть более склонен к ложным предупреждениям по сравнению с PHPStan и Psalm. Поддерживает плагины, позволяющие расширять его возможности, и интеграцию с редакторами кода.

Сравнительный анализ инструментов статического анализа PHP-кода

В данном разделе представлено сравнительное исследование трёх средств статического анализа для PHP: PHPStan, Psalm и Phan. Целью исследования была оценка их возможностей по обнаружению различных категорий

уязвимостей и дефектов кода [8], классифицированных согласно Common Weakness Enumeration (CWE) [9].

При настройке анализаторов был применен единый подход с использованием стандартных конфигураций: для PHPStan установлен уровень 5, для Psalm – уровень 3, для Phan использована конфигурация по умолчанию. Данные настройки отражают типичный сценарий использования инструментов в реальных проектах без экстремальных требований к строгости анализа.

Для формирования списка возможностей анализаторов был составлен набор категорий уязвимостей и дефектов. Из обширного списка CWE были отобраны наиболее характерные для экосистемы PHP категории с акцентом на те из них, которые представляют наибольший риск для веб-приложений (рис. 2). Оценка возможностей каждого средства проводилась путём тщательного изучения их официальной документации и репозитория.




Рис. 2. Сравнительная характеристика инструментов по коэффициенту обнаружения уязвимостей

Fig. 2. Comparative effectiveness of the tools by vulnerability detection rate

Результаты и их обсуждение

Рассмотрим результаты оценки (табл. 1).

Для количественной оценки эффективности был рассчитан коэффициент

обнаружения каждого инструмента – отношение количества поддерживаемых категорий уязвимостей к их общему количеству в выбранном наборе. Результаты представлены ниже (табл. 2).

Таблица 1. Сравнительный анализ инструментов статического анализа PHP-кода [10]**Table 1.** Comparative analysis of PHP static analysis tools [10]

Категория уязвимости (CWE)	Описание	PHPStan	Psalm	Phan
CWE-78	Инъекция команд ОС	×	✓*	✓
CWE-79	Межсайтовый скриптинг (XSS)	×	✓*	✓
CWE-89	SQL-инъекция	×	✓*	✓
CWE-327	Использование ненадёжного криптоалгоритма	×	✓*	×
CWE-369	Divide By Zero (Деление на ноль)	✓	✓	✓
CWE-390	Detection of Error Condition Without Action (Игнорирование ошибок)	✓	✓	✓
CWE-401	Memory Leak (Утечка памяти)	×	×	×
CWE-476	NULL Pointer Dereference (Обращение к нулевому указателю)	✓	✓	✓
CWE-522	Insufficiently Protected Credentials (Недостаточная защита учетных данных)	×	✓*	×
CWE-561	Dead Code (Мёртвый код)	✓	✓	✓
CWE-563	Assignment to Variable without Use (Присвоение значения неиспользуемой переменной)	✓	✓	✓
CWE-570	Expression is Always False (Выражение всегда ложно)	✓	✓	✓
CWE-571	Expression is Always True (Выражение всегда истинно)	✓	✓	✓
CWE-591	Sensitive Data Storage in Improperly Locked Memory (Недостаточная блокировка)	×	×	×
CWE-690	Unchecked Return Value (Непроверенное возвращаемое значение)	✓	✓	✓
CWE-772	Missing Release of Resource (Неосвобожденный ресурс)	×	✓*	×
CWE-776	XML Injection (XXE)	×	×	✓
CWE-835	Infinite Loop (Бесконечный цикл)	×	✓	✓

Примечание. Знаком «✓» отмечены поддерживаемые категории уязвимостей, а знаком «×

Для практической оценки эффективности анализаторов был использован специально разработанный тестовый PHP-проект, содержащий код с известными уязвимостями [11]. Проект состоит из 22 файлов, в которые было преднамеренно внедрено 75 уязвимостей различных типов, соответствующих рассмотренным ранее категориям CWE. Такой подход позволил создать

среду для объективного сравнения возможностей.

На основе анализа этого набора была составлена детальная статистика для каждого инструмента. В таблицах 3–5 представлен полный перечень всех типов предупреждений [12], сгенерированных при анализе тестового проекта, что позволяет оценить характер и специфику обнаруживаемых дефектов [13].

Таблица 3. Детальная статистика предупреждений PHPStan

Table 3. Detailed statistics of PHPStan warnings

Кол.	Описание предупреждения	Идентификатор
8	Unreachable statement - code above always terminates.	deadCode.unreachable
4	Method should return ... but returns ...	return.type
4	Offset ... does not exist on ...	offsetAccess.notFound
3	Comparison operation ">=" between ... is always true.	greaterOrEqual.alwaysTrue
3	Call to method ... on a separate line has no effect.	method.resultUnused
2	Result of && is always false.	booleanAnd.alwaysFalse
2	Result of is always true.	booleanOr.alwaysTrue
2	Parameter ... of method ... expects ..., ... given.	argument.type
2	Variable ... on left side of ?? always exists and is not nullable.	nullCoalesce.variable
2	Variable ... might not be defined.	variable.undefined
2	Call to function ... with ... will always evaluate to true.	function.alreadyNarrowedType
2	Variable ... in empty() always exists and is not falsy.	empty.variable
2	Strict comparison using !== between ... will always evaluate to true.	notIdentical.alwaysTrue
2	Comparison operation "<" between <i>NEVER</i> and ... results in an error.	smaller.invalid
1	Method ... is unused.	method.unused
1	Path in include() ... is not a file or it does not exist.	include.fileNotFound
1	While loop condition is always true.	while.alwaysTrue
1	Cannot call method ... on null.	method.nonObject
1	Comparison operation "<" between ... is always false.	smaller.alwaysFalse
1	Comparison operation ">" between <i>NEVER</i> and ... results in an error.	greater.invalid
1	Comparison operation "==" between <i>NEVER</i> and ... results in an error.	equal.invalid
1	Comparison operation ">" between ... is always false.	greater.alwaysFalse

Таблица 4. Детальная статистика предупреждений Psalm**Table 4.** Detailed statistics of Psalm warnings

Кол.	Описание предупреждения	Идентификатор
10	Condition is always true or false	RedundantCondition
8	Type for variable is never of type	TypeDoesNotContainType
4	The declared return type is incorrect	InvalidReturnType
4	The inferred type does not match the declared return type	InvalidReturnStatement
2	Argument expects string, but int provided	InvalidScalarArgument
2	Cannot access value on empty array variable	EmptyArrayAccess
2	Possibly undefined variable	PossiblyUndefinedVariable
2	Type for variable does not contain null	TypeDoesNotContainNull
2	Cannot access array value on null variable	NullArrayAccess
1	Unsafe shell_exec	ForbiddenCode
1	Cannot find file to include	MissingFile
1	Cannot call method on null value	NullReference
1	Cannot get property on null variable	NullPropertyFetch

Таблица 5. Детальная статистика предупреждений Phan**Table 5.** Detailed statistics of Phan warnings

Кол.	Описание предупреждения	Идентификатор
4	Method has no return type and will inconsistently return or not return	PhanPluginInconsistentReturnMethod
3	Returning type does not match declared return type	PhanTypeMismatchReturn
2	Suspicious array access to variable of type null	PhanTypeArraySuspiciousNull
2	Argument type does not match the declared parameter type	PhanTypeMismatchArgument
2	Invalid offset of array type array{}	PhanTypeInvalidDimOffset
2	Variable is possibly undeclared	PhanPossiblyUndeclaredVariable
2	Call to deprecated function	PhanDeprecatedFunctionInternal
1	Missing required file	PhanMissingRequireFile
1	Unreachable statement detected	PhanPluginUnreachableCode
1	Call to method on non-class type null	PhanNonClassMethodCall
1	Returning type does not match declared return type (probably real)	PhanTypeMismatchReturnProbablyReal

Для сравнительной оценки производительности инструментов был раз-

работан PHP-скрипт, осуществляющий замер времени выполнения (рис. 3) и

потребления памяти (рис. 4) при идентичных условиях [14]. Для повышения достоверности результатов каждый анализатор запускался 10 раз, после чего

были вычислены средние значения метрик [15]. Скрипт автоматически запускал каждый анализатор и фиксировал метрики производительности.




Рис. 3. Сравнение времени выполнения инструментов статического анализа

Fig. 3. Comparison of execution time of static analysis tools




Рис. 4. Сравнение показателя потребления памяти инструментов статического анализа

Fig. 4. Comparison of memory consumption of static analysis tools

Сравнительный анализ инструментов статического анализа PHP-кода [16] позволил выявить различия в их воз-

можностях обнаружения уязвимостей и производительности (табл. 6).

Таблица 6. Сравнение производительности инструментов статического анализа (средние значения за 10 запусков)**Table 6.** Performance comparison of static analysis tools (average values over 10 runs)

Инструмент	Время анализа, с	Использование памяти, МВ	Количество файлов	Количество проблем
PHPStan	$0,89 \pm 0,07$	$0,021 \pm 0,002$	22	48
Psalm	$0,39 \pm 0,02$	$0,031 \pm 0,001$	22	40
Phan	$0,35 \pm 0,02$	$0,011 \pm 0,002$	22	21

В части обнаружения уязвимостей результаты (см. табл. 1) характеризуют возможности инструментов по обнаружению различных категорий уязвимостей CWE. Наибольший охват демонстрирует Psalm, который поддерживает 15 из 18 категорий (83,3%). Большую роль в этом играет taint-анализ, позволяющий выявлять такие уязвимости, как инъекции (CWE-78, CWE-89) [17], XSS (CWE-79) [18] и недостаточная защита учетных данных (CWE-522).

Phan занимает второе место с поддержкой 13 категорий (72,2%), демонстрируя сильные стороны в обнаружении специфических, таких как XML-инъекции (CWE-776), что не поддерживается другими средствами.

PHPStan демонстрирует наименьший охват уязвимостей – 8 категорий (44,4%). Преимущество инструмента заключается в анализе типов и логических конструкций, но он не ориентирован на выявление высокоуровневых уязвимостей безопасности без использования расширений.

В части обнаружения дефектов на тестовом наборе PHPStan выявил наибольшее количество проблем (48),

проявив себя как эффективное решение для обнаружения логических несоответствий, недостижимого кода [19] и нарушений типизации. Psalm обнаружил 40 проблем, основная часть которых связана с избыточными условиями, несоответствиями типов и потенциально опасными операциями доступа к данным. Phan обнаружил 21 проблему, большая часть которых связана с согласованностью возвращаемых типов и использованием устаревших конструкций.

При оценке производительности наиболее быстрым инструментом оказался Phan ($0,35 \pm 0,02$ с), тогда как PHPStan показал наибольшее время анализа ($0,89 \pm 0,07$ с). По потреблению памяти все инструменты продемонстрировали схожие низкие показатели, однако Phan и PHPStan использовали минимальный объем памяти ($0,011 \pm 0,002$ МВ и $0,021 \pm 0,002$ МВ соответственно).

Анализ показал, что ни одно средство не покрывает все категории уязвимостей, что подтверждает целесообразность их комбинированного использования [20] в процессе разработки для достижения максимального охвата проверок безопасности.

Выводы

Проведённое сравнительное исследование инструментов статического анализа PHP-кода показало, что PHPStan, Psalm и Phan демонстрируют разную эффективность при анализе кодовой базы. Psalm продемонстрировал наилучшие результаты в поиске уязвимостей безопасности. Встроенный taint-анализ эффективно выявляет риски инъекций и межсайтового скриптинга, что важно для веб-приложений, работающих с пользовательскими данными. Phan показал себя как наиболее сбалансированное решение. Он сочетает хорошее покрытие категорий уязвимостей с высокой производительностью, что делает его оптимальным для ежедневного использо-

вания в процессе разработки. PHPStan показал лучшие результаты в обнаружении логических ошибок и дефектов кода, таких как недостижимый код и проблемы с типами данных. Имеет строгую систему типов и способен выявлять избыточные проверки, что делает его предпочтительным решением для поддержания читаемости кода.

На практике оптимальным подходом становится комбинирование этих инструментов. Например, можно использовать Phan для ежедневных проверок, Psalm – для аудита безопасности, PHPStan – для глубокого анализа логики и рефакторинга. Такой комплексный подход позволяет выявить максимальное количество проблем на разных уровнях кодовой базы.

Список литературы

1. Проверка кода на уязвимости на всех стадиях разработки / А. В. Скрыпников, В. В. Денисенко, И. А. Высоцкая, И. И. Савченко, К. С. Евтеева // Современные наукоемкие технологии. 2021. № 3. С. 77–81.
2. Методика поиска уязвимостей в программном обеспечении, написанном на нескольких языках программирования / Б. А. Позин [и др.] // Труды Института системного программирования РАН. 2025. Т. 37, № 1. С. 122–132.
3. Кубрин Г. С., Зегжда Д. П. Поиск уязвимостей программного обеспечения с применением ансамбля алгоритмов анализа графового представления кода // Проблемы информационной безопасности. Компьютерные системы. 2023. № 4. С. 148–158.
4. Seara J. P., Serrão C. Automation of system security vulnerabilities detection using open-source software // Electronics. 2024. Vol. 13, N 5. P. 873.
5. Rio A., Fernando Brito e Abreu. PHP code smells in web apps: Evolution, survival and anomalies // Journal of Systems and Software. 2023. Vol. 200. P. 111644.
6. A critical comparison on six static analysis tools: Detection, agreement, and precision / V. Lenarduzzi [et al.] // Journal of Systems and Software. 2023. Vol. 198. P. 111575. <https://doi.org/10.48550/arXiv.2101.08832>.
7. Benchmarking static analysis for PHP applications security / J. Zhao [et al.] // Entropy. 2025. Vol. 27, N 9. P. 926.

8. Анализ методов предобработки программного кода для повышения эффективности применения больших языковых моделей в задачах обнаружения уязвимостей / В. В. Чаругин [и др.] // *Computational nanotechnology*. 2025. Vol. 12, N 3. P. 67–79.
9. Schuckert F., Katt B., Langweg H. Insecurity refactoring: Automated injection of vulnerabilities in source code // *Computers & Security*. 2023. Vol. 128, N 10. P. 103121. <https://doi.org/10.1016/j.cose.2023.103121>.
10. Analysis of IoT security challenges and its solutions using artificial intelligence / T. Mazhar [et al.] // *Brain sciences*. 2023. Vol. 13, N 4. P. 683.
11. Benzekki K., Messai M. L. Empowering Cybersecurity Analysis: Unifying CVE, CWE, and CPE through Knowledge Graphs // *Computers & Security*. 2025. Vol. 160. P. 104726. <https://doi.org/10.1016/j.cose.2025.104726>.
12. Shaikhelislamov D. S., Drobyshevskiy M. D., Belevantsev A. A. Ensuring Trustworthy Code: Leveraging a Static Analyzer to Identify and Mitigate Defects in Generated Code // *Journal of Mathematical Sciences*. 2024. Vol. 540. P. 233–251.
13. Пилькевич П. В., Спевиков А. Г., Калущкий И. В. Модель системы принятия решений на основании мониторинга инцидентов // *Труды МАИ*. 2025. № 143. С. 1–27.
14. Воротникова Т. Ю. Надежный код: статический анализ программного кода как средство повышения надежности программного обеспечения информационных систем // *Информационные технологии в УИС*. 2020. № 2. С. 22–27.
15. Сравнительный анализ и выбор статических анализаторов безопасности кода / А. С. Марков, И. С. Антипов, С. С. Арустамян, Н. А. Магакелова // *Вопросы кибербезопасности*. 2024. № 5 (63). С. 79–88.
16. Alqaradaghi M., Morse G., Kozsik T. Detecting security vulnerabilities with static analysis – A case study // *Pollack Periodica*. 2022. Vol. 17, N 2. С. 1–7.
17. SQL injection attack detection in network flow data / Ignacio Samuel Crespo-Martínez, Ángel Manuel Guerrero-Higueras, Adrián Campazas Vega, Virginia Riego // *Computers & Security*. 2023. Vol. 127, N 4. P. 103093.
18. An XSS Attack Detection Model Based on Two-Stage AST Analysis / Qiuhua Wang, Chuangchuang Li, Lifeng Yuan, Dong Wang, Yeru Wang, Yizhi Ren, Weizhi Meng // *IEEE Transactions on Dependable and Secure Computing*. 2026. Vol. 23, is. 2. P. 4071–4084.
19. Vasileva V. I., Borodin A. E., Volkov A. E. Detection of dead function calls as source code defects through static analysis // *Труды Института системного программирования РАН*. 2025. Т. 37, № 4. С. 65–78.
20. A large scale analysis of code security in public repositories / Ciprian Oprisa, Dominic Octavian Grigoruț, Haralambos Mouratidis, Eftychia Lakka // *International Journal of Information Security*. 2026. Vol. 25, N 1. P. 24. <https://doi.org/10.1007/s10207-025-01187-w>.

References

1. Skripnikov A.V., Denisenko V.V., Vysotskaya I.A., Savchenko I.I., Evteeva K.S. Checking code for vulnerabilities at all stages of development. *Sovremennye naukoemkie tekhnologii = Modern Science-Intensive Technologies*. 2021;(3): 77-81. (In Russ.)
2. Pozin B.A., et al. A methodology for searching for vulnerabilities in software written in several programming languages. *Trudy Instituta sistemnogo programmirovaniya RAN = Proceedings of the Institute for System Programming of the Russian Academy of Sciences*. 2025;37(1):122–132. (In Russ.)
3. Kubrin G.S., Zegzhda D.P. Search for software vulnerabilities using an ensemble of algorithms for analyzing graph representation of code. *Problemy informatsionnoi bezopasnosti. Komp'yuternye sistemy = Problems of Information Security. Computer Systems*. 2023;(4):148–158. (In Russ.)
4. Seara J.P., Serrão C. Automation of system security vulnerabilities detection using open-source software. *Electronics*. 2024;13(5):873.
5. Rio A., Fernando Brito e Abreu. PHP code smells in web apps: Evolution, survival and anomalies. *Journal of Systems and Software*. 2023;200:111644.
6. Lenarduzzi V., et al. A critical comparison on six static analysis tools: Detection, agreement, and precision. *Journal of Systems and Software*. 2023;198:111575.
7. Zhao J., et al. Benchmarking static analysis for PHP applications security. *Entropy*. 2025;27(9):926.
8. Charugin V.V., et al. Analysis of software code preprocessing methods to improve the efficiency of using large language models in vulnerability detection tasks. *Computational Nanotechnology*. 2025;12(3):67-79. (In Russ.)
9. Schuckert F., Katt B., Langweg H. Insecurity refactoring: Automated injection of vulnerabilities in source code. *Computers & Security*. 2023;128(10):103121. <https://doi.org/10.1016/j.cose.2023.103121>.
10. Mazhar T., et al. Analysis of IoT security challenges and its solutions using artificial intelligence. *Brain Sciences*. 2023;13(4):683.
11. Benzekki K., Messai M.L. Empowering Cybersecurity Analysis: Unifying CVE, CWE, and CPE through Knowledge Graphs. *Computers & Security*. 2025;160:104726. <https://doi.org/10.1016/j.cose.2025.104726>.
12. Shaikhelislamov D.S., Drobyshevskiy M.D., Belevantsev A.A. Ensuring Trustworthy Code: Leveraging a Static Analyzer to Identify and Mitigate Defects in Generated Code. *Journal of Mathematical Sciences*. 2024;540:233-251.
13. Pilkevich P.V., Spevakov A.G., Kalutskiy I.V. Model of a Decision-Making System Based on Incident Monitoring. *Trudy MAI = Proceedings of the MAI*. 2025;(143):1-27. (In Russ.)

14. Vorotnikova T.Yu. Reliable Code: Static Analysis of Program Code as a Means of Improving the Reliability of Information Systems Software. *Informatsionnye tekhnologii v UIS = Information Technologies in the UIS*. 2020;(2):22–27. (In Russ.)
15. Markov A.S., et al. Comparative Analysis and Selection of Static Code Security Analyzers. *Voprosy kiberbezopasnosti = Cybersecurity Issues*. 2024;(5):79–88. (In Russ.)
16. Alqaradaghi M., Morse G., Kozsik T. Detecting Security Vulnerabilities with Static Analysis – A Case Study. *Pollack Periodica*. 2022;17(2):1–7.
17. Ignacio Samuel Crespo-Martínez, Ángel Manuel Guerrero-Higueras, Adrián Campazas Vega, Virginia Riego. SQL injection attack detection in network flow data. *Computers & Security*. 2023;127(4):103093.
18. Qiuhua Wang, Chuangchuang Li, Lifeng Yuan, Dong Wang, Yeru Wang, Yizhi Ren, Weizhi Meng. An XSS Attack Detection Model Based on Two-Stage AST Analysis. *IEEE Transactions on Dependable and Secure Computing*. 2026;23(2):4071–4084.
19. Vasileva V.I., Borodin A.E., Volkov A.E. Detection of dead function calls as source code defects through static analysis. *Trudy Instituta sistemnogo programmirovaniya RAN = Proceedings of ISP RAS*. 2025;37(4):65–78.
20. Ciprian Oprisa, Dominic Octavian Grigoruț, Haralambos Mouratidis, Eftychia Lakka. A large scale analysis of code security in public repositories. *International Journal of Information Security*. 2026;25(1):24. <https://doi.org/10.1007/s10207-025-01187-w>.

Информация об авторах / Information about the Authors

Огневой Ярослав Владимирович, студент факультета информационных технологий, Московский политехнический университет, г. Москва, Российская Федерация, e-mail: ya.ognevoy@yandex.ru, ORCID: 0009-0009-5291-4561

Yaroslav V. Ognevoy, Student at the Faculty of Information Technologies, Moscow Polytechnic University, Moscow, Russian Federation, e-mail: ya.ognevoy@yandex.ru, ORCID: 0009-0009-5291-4561

Спеваков Александр Геннадьевич, кандидат технических наук, доцент, Московский политехнический университет, г. Москва, Российская Федерация, e-mail: aspev@yandex.ru, ORCID: 0000-0003-3940-9607

Alexander G. Spevakov, Cand. Sci. (Engineering), Associate Professor, Moscow Polytechnic University, Moscow, Russian Federation, e-mail: aspev@yandex.ru, ORCID: 0000-0003-3940-9607

Калущий Игорь Владимирович, кандидат технических наук, доцент, Московский политехнический университет, г. Москва, Российская Федерация, e-mail: kalutsky_igor@mail.ru, ORCID: 0000-0003-0575-3055

Клименко Павел Алексеевич, кандидат экономических наук, доцент, Курский филиал Финансового университета при Правительстве Российской Федерации, г. Курск, Российская Федерация, e-mail: paaklimenko@fa.ru, ORCID: 0000-0003-2577-4144

Igor V. Kalutskiy, Cand. Sci. (Engineering), Associate Professor, Moscow Polytechnic University, Moscow, Russian Federation, e-mail: kalutsky_igor@mail.ru, ORCID: 0000-0003-0575-3055

Pavel A. Klimenko, Cand. Sci. (Economics), Associate Professor, Kursk Branch of the Financial University under the Government of the Russian Federation, Kursk, Russian Federation, e-mail: paaklimenko@fa.ru, ORCID: 0000-0003-2577-4144

МОДЕЛИРОВАНИЕ В МЕДИЦИНСКИХ И ТЕХНИЧЕСКИХ СИСТЕМАХ

MODELING IN MEDICAL AND TECHNICAL SYSTEMS

Оригинальная статья / Original article

<https://doi.org/10.21869/2223-1536-2026-16-2-182-196>



УДК 621.311

Методология прогнозирования генерации возобновляемых источников энергии для обеспечения качества электроэнергии в сетях

И. В. Брежнев¹ ✉, И. Е. Чернецкая¹

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

✉ e-mail: b89038750930@gmail.com

Резюме

Цель исследования. С увеличением доли генерации на основе солнечных станций в распределительных сетях растут требования к качеству поставляемой электроэнергии, так как нестабильность солнечной генерации непосредственно влияет на нагрузку сети и параметры напряжения электроэнергии, поставляемой потребителю.

Цель исследования – экспериментальная проверка методов прогноза выработки солнечной станции на ближайшие сутки с почасовым планированием, при котором можно связать величину ошибки прогноза с показателями качества электроэнергии по ГОСТ 32144-2013.

Методы. Для решения поставленной задачи выполнено сравнительное исследование трёх подходов: моделей ARIMA/ARIMAX, ансамбля Random Forest и гибридной схемы STL+RF. Во всех вариантах анализировалось влияние метеорологических факторов на точность прогноза солнечной генерации.

Результаты. Установлено, что включение погодных данных существенно повышает качество прогноза по сравнению с моделями, использующими только историю потребления. Лучшие результаты показала гибридная модель STL+RF с метеорологическими признаками, которая обеспечила оптимальный компромисс между точностью и стабильностью прогноза. Данная оценка показывает, что в задачах управления режимами сети применение гибридных моделей должно быть более оправданно, чем использование только статистических моделей.

Заключение. Предложенный подход может быть использован как основа для систем раннего предупреждения о рисках ухудшения качества электроэнергии в сетях с высокой долей возобновляемых источников энергии. Практическая ценность работы состоит в увязке результатов прогнозирования солнечной генерации с нормативными требованиями ГОСТ 32144-2013 и задачами диспетчерского управления.

Ключевые слова: фотоэлектрическая генерация; краткосрочное прогнозирование; STL-декомпозиция; гибридные модели; качество электроэнергии; управление рисками.

© Брежнев И. В., Чернецкая И. Е., 2026

Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026;16(2):182–196

Конфликт интересов: Авторы декларируют отсутствие конфликта интересов, связанных с публикацией данной статьи.

Для цитирования: Брежнев И. В., Чернецкая И. Е. Методология прогнозирования генерации возобновляемых источников энергии ВИЭ для обеспечения качества электроэнергии в сетях // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 182–196. [https://doi.org/ 10.21869/2223-1536-2026-16-2-182-196](https://doi.org/10.21869/2223-1536-2026-16-2-182-196).

Поступила в редакцию 12.04.2026

Подписана в печать 11.05.2026

Опубликована 30.06.2026

A methodology for short-term forecasting of solar generation to manage power quality in distribution networks

Igor V. Brezhnev¹ ✉, Irina E. Chernetskaya¹

¹ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: b89038750930@gmail.com

Abstract

Purpose of research. With the increasing share of generation from solar plants in distribution networks, the requirements for the quality of supplied electricity are growing, as the instability of solar generation directly affects the network load and the voltage parameters of the electricity supplied to the consumer.

The purpose of the research is experimental validation of methods for forecasting the output of a PV plant for the next day with hourly planning, which makes it possible to link the magnitude of the forecast error with the electric power quality indicators according to GOST 32144-2013.

Methods. To solve this problem, a comparative study of three approaches was carried out: ARIMA/ARIMAX models, the Random Forest ensemble, and the hybrid STL+RF scheme. In all cases, the influence of meteorological factors on the accuracy of solar generation forecasting was analyzed.

Results. It was found that the inclusion of weather data significantly improves the forecast quality compared to models using only the history of consumption. The best results were shown by the hybrid STL+RF model with meteorological features, which provided an optimal compromise between forecast accuracy and stability. This assessment shows that in the tasks of network operation management, the use of hybrid models is more justified than the use of statistical models alone.

Conclusion. The proposed approach can be used as a basis for early warning systems for the risks of electric power quality deterioration in networks with a high share of RES. The practical value of the work lies in linking the results of solar generation forecasting with the regulatory requirements of GOST 32144-2013 and the tasks of dispatch control.

Keywords: photovoltaic generation; short-term forecasting; STL decomposition; hybrid models; electric power quality; risk management.

Conflict of interest: The authors declares no conflict of interest related to the publication of this article.

For citation: Brezhnev I.V., Chernetskaya I.E. A methodology for short-term forecasting of solar generation to manage power quality in distribution networks. *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(2):182–196. (In Russ.) [https://doi.org/ 10.21869/2223-1536-2026-16-2-182-196](https://doi.org/10.21869/2223-1536-2026-16-2-182-196).

Received 12.04.2026

Accepted 11.05.2026

Published 30.06.2026

Введение

Повсеместное развитие возобновляемых источников энергии (ВИЭ) в России и мире создаёт сложную ситуацию: с одной стороны, они необходимы для декарбонизации энергосистемы, а с другой – их высокая волатильность создаёт новые задачи для принятия решений в диспетчерских службах. По данным Международного агентства по возобновляемым источникам энергии (IRENA), доля ВИЭ в мировой генерации возросла с 28% в 2020 г. до 32% в 2023 г.¹ В России установленная мощность солнечной генерации превышает 1 ГВт, создавая ощутимую нагрузку на распределительные сети региональных энергосистем, особенно в Крыму, Астраханской и Оренбургской областях. Однако следует признать, что в некоторых регионах солнечная генерация остаётся слабо представленной, что ограничивает обобщаемость результатов на всю территорию страны.

Рост доли ВИЭ в энергобалансе позволяет выявить критическое противоречие: оперативные решения в диспетчеризации требуют прогнозирования генерации с горизонтом в несколько часов, однако погодные условия могут быть совершенно непредсказуемы. Согласно ГОСТ 32144-2013, в точках передачи энергии потребителям должны соблюдаться нормы по отклонению

напряжения ($\pm 5\%$ номинального), частоте ($50 \pm 0,2$ Гц), гармоническому составу и фликеру². Ошибки в прогнозе генерации ВИЭ создают дефициты или избытки мощности, которые приводят к отклонениям напряжения, в крайних случаях – к провалам напряжения и нарушению электроснабжения объектов. Однако связь между точностью прогноза и параметрами качества остаётся недостаточно изученной, что является актуальным для исследования.

Материалы и методы

В литературе выделяют четыре основных класса подходов к прогнозированию генерации ВИЭ [1]. Физические методы основаны на моделях NWP и расчёте солнечной энергии [2]. Они эффективны для долгосрочного прогнозирования [3]. Однако такие методы имеют две серьёзные проблемы. Первая – это задержка в получении результатов 8–12 ч. Вторая – низкая точность на краткосрочных горизонтах менее 4–6 ч. Статистические методы включают семейство моделей ARIMA/SARIMA и близкие подходы [4]. Их главный плюс – это простая реализация и возможность работы в реальном времени, но есть ключевое допущение: процесс считается линейным. При резких внешних изменениях это допущение нарушается, и ошибки мо-

¹ Renewable Capacity Statistics 2024 // IRENA. URL: <https://www.irena.org/Publications/2024/Mar/Renewable-capacity-statistics-2024> (дата обращения: 11.03.2026).

² ГОСТ 32144–2013. Качество электрической энергии. Нормы показателей качества электрической энергии при её передаче по электросетям общего назначения. М.: Стандартинформ, 2014. 19 с.

дели резко возрастают. Методы машинного обучения используют ансамбли деревьев [5] и нейронные сети [6]. При достаточном объёме данных они демонстрируют высокую точность прогноза. При этом возникают два риска: переобучение и изменение концепции при смене сезонов или изменении условий работы станции. Гибридные схемы совмещают перечисленные подходы. Обычно временной ряд сначала раскладывают на тренд, сезонную компоненту и остаток. Затем к тренду и сезонности применяют статистические модели, а к остатку – методы машинного обучения. Это позволяет лучше описывать нелинейные отклонения [7].

Новизна предлагаемого подхода состоит в явной связи точности прогноза генерации с показателями качества электроэнергии по российским стандартам [8]. В большинстве работ рассматриваются только метрики точности модели, без перехода к параметрам качества энергии. При этом важно подчеркнуть ограничение. Предполагается связь между ошибкой прогноза и отклонениями параметров качества электроэнергии. Динамические эффекты сети в такой постановке не учитываются. Это допустимая аппроксимация для задач краткосрочного управления, но не полное описание поведения энергосистемы.

Исследование выполнено на открытом архивном датасете станции UG Hall 4. Использован период с 2023-10-01 по 2023-12-31, т. е. 92 дня наблюдений. Такой интервал является существенным ограничением. Три месяца недостаточ-

но для полноценного анализа сезонного поведения; для этого требуется не менее одного-двух лет данных. Однако выбранный период включает переход от осени к зиме и широкий набор облачных ситуаций. Это позволило провести детальный анализ на управляемом объёме данных. Мощность генерации исходно измерялась с минутным шагом. Метеорологические параметры: освещённость, температура, влажность, скорость ветра усреднялись за час. Осадки, наоборот, суммировались за часовой интервал. В данных присутствовали пропуски, их доля была менее 2%. Такие пропуски заполнялись линейной интерполяцией, что приемлемо при небольшой доле отсутствующих значений. Внешние переменные вводились в модель с временным сдвигом на 1 ч. Это исключало утечку информации при прогнозе генерации на момент t ; в модели использовались только метеоусловия на момент t^{-1} , а не фактические значения в момент t . На практике модель будет работать с прогнозами погоды, которые менее точны, чем фактические метеоданные. Анализ чувствительности к ошибкам NWP остался за рамками данной работы, но является необходимым для практического внедрения.

Для ARIMA использовалась авторегрессионная интегрированная модель скользящего среднего порядка (p, d, q) , подбираемого по критерию AIC. Вариант ARIMAX расширял ARIMA внешними переменными [9]. Random Forest использовал ансамбль из 60 деревьев решений, обучаемых на лаговых при-

знаках целевой переменной (сдвиги на 1, 2, 3, 6, 12, 24 ч.) [10]. Гибридная архитектура STL+RF, успешно применявшаяся для прогнозирования солнечной генерации [11], использует сезонно-трендовую декомпозицию (STL) [12] для разделения ряда на тренд, сезонность и остаток, после чего Random Forest обучается на остатке [13].

Качество прогнозов оценивалось по трём метрикам: RMSE (Root Mean Squared Error), чувствительная к крупным ошибкам, MAE (Mean Absolute Error), отражающая среднетипичное отклонение, и R^2 (коэффициент детерминации), показывающий долю объяснённой дисперсии. Использовалась формула для R^2 :

$$R^2 = 1 - \frac{\sum (P_{\text{факт}} - P_{\text{прогноз}})^2}{\sum (P_{\text{факт}} - \text{mean}(P_{\text{факт}}))^2},$$

где $P_{\text{факт}}$ и $P_{\text{прогноз}}$ — фактические и прогнозируемые значения мощности [13].

Для проверки статистической значимости различий между прогнозами двух моделей применялся тест Диболда-Мариано с использованием двустороннего критерия при уровне значимости $\alpha = 0,05$. Статистика теста строилась на основе квадратов ошибок и учитывала автокорреляцию ошибок, чтобы

установить, является ли различие между моделями статистически значимым или возникает случайно.

На основе реального датасета получены следующие результаты, которые представлены в таблице 1, где показаны метрики для моделей без метеорологических признаков.

На рисунке 1 показан прогноз модели ARIMA без метеорологических данных. Модель демонстрирует крайне низкую точность с $\text{RMSE} = 6,017$ кВт/ч и отрицательным коэффициентом детерминации $R^2 = -0,395$. Прогноз практически не отражает резкие пики генерации и остаётся близким к постоянному значению, что указывает на неспособность статистической модели улавливать нелинейные колебания солнечной генерации [7].

На рисунке 2 представлены результаты ансамблевого алгоритма Random Forest, обученного только на исторических лагах мощности. Благодаря обучению на временных шаблонах модель лучше улавливает суточную повторяемость: $\text{RMSE} = 1,214$ кВт/ч, $R^2 = 0,943$. Однако RF систематически недооценивает пики в ясные дни, так как не имеет информации о текущих погодных условиях и прямой солнечной радиации.

Таблица 1. Метрики без метеорологических данных

Table 1. Metrics without meteorological data

Модель	RMSE (kWh/h)	MAE (kWh/h)	R^2
ARIMA	6,017	3,203	-0,395
Random Forest	1,214	0,548	0,943
STL+RF	1,26	0,595	0,939




Рис. 1. ARIMA без метеоданных

Fig. 1. ARIMA without meteorological data




Рис. 2. Random Forest без метеоданных

Fig. 2. Random Forest without meteorological data

На рисунке 3 показана гибридная схема STL+RF. Выделение суточного цикла посредством STL-декомпозиции позволяет Random Forest моделировать остаточную компоненту более стабильно и с меньшей подверженностью шуму. Метрики практически идентичны чистому RF: RMSE = 1,26 кВт/ч, $R^2 = 0,939$. Преимущество гибридного подхода проявляется в большей устойчивости к выбросам и аномалиям.

Дальше произведены расчеты уже с учетом метеоданных, и результаты представлены ниже (табл. 2).

На рисунке 4 показан результат добавления метеорологических данных к модели ARIMA (вариант ARIMAX). Включение экзогенных факторов заметно улучшает качество. RMSE снижается с 6,017 до 5,195 кВт/ч (снижение на 0,822 кВт/ч), а коэффициент R^2 возрастает с $-0,395$ до $-0,04$ (улучшение на 0,355). Хотя эти показатели существенно лучше, чем для ARIMA без метеоданными, ARIMAX всё равно остаётся менее точной, чем методы машинного обучения.




Рис. 3. STL +RF без метеоданных

Fig. 3. STL +RF without meteorological data

Таблица 2. Метрики с метеорологическими данными

Table 2. Performance metrics with meteorological data

Модель	RMSE (kWh/h)	MAE (kWh/h)	R ²
ARIMAX	5,195	4,595	–0,04
RF+метео	1,163	0,55	0,948
STL+RF+метео	1,204	0,607	0,944




Рис. 4. ARIMA с метеоданными

Fig. 4. ARIMA with meteorological data

На рисунке 5 показаны результаты Random Forest с подключением метеорологических данных (RF+метео). При добавлении информации об освещённости, температуре, влажности и других параметрах модель практически совпадает с фактической кривой генерации в ясные дни. Метрики показывают высо-

кую точность: $RMSE = 1,163$ кВт/ч, $R^2 = 0,948$. Модель точно передаёт дневные максимумы и спады, хотя на участках хаотичной облачности остаются локальные ошибки.

На рисунке 6 представлена гибридная архитектура STL+RF+метео, которая показывает наилучший результат

среди всех рассмотренных методов. $RMSE = 1,204$ кВт/ч, $R^2 = 0,944$. Профиль прогноза практически неотличим от фактического в периоды ясной погоды благодаря комбинации трёх факто-

ров: учёта метеорологических данных, выделения структурного тренда посредством STL-декомпозиции и способности Random Forest улавливать нелинейные остатки.




Рис. 5. Random Forest с метеоданными

Fig. 5. Random Forest with meteorological data




Рис. 6. STL +RF с метеоданными

Fig. 6. STL+RF with meteorological data

Среди метеорологических параметров ключевую роль играют освещённость в предыдущий час и температура воздуха в предыдущий час. Эти параметры напрямую определяют интенсивность солнечной генерации: освещённость – это мера солнечной радиации, достигающей панели, а температура влияет на эффективность преобразования. Остальные метеорологические

параметры вносят менее 10% важности каждый. Для малых станций, номинальная мощность которых менее 10 кВт, ошибка часового прогноза в 1-2 кВт уже критична.

Результаты и их обсуждение

Полученные результаты согласуются с данными из литературы по прогнозированию солнечной генерации. Со-

гласно современным обзорам, добавление метеорологических признаков к статистическим моделям снижает ошибку прогноза на 50–80 % за счёт учёта прямой связи выработки с погодными условиями. В нашем исследовании переход от ARIMA к ARIMAX дал аналогичный эффект: RMSE снизился с 6,017 до 5,195 кВт·ч, а R^2 вырос с –0,395 до –0,04. Это указывает на то, что метеоданные помогают статистической модели частично компенсировать её линейные ограничения.

Для методов машинного обучения базовая точность оказалась значительно выше [14]. Это соответствует опубликованным работам, где Random Forest при использовании исторических данных и погодных условий показывает R^2 на уровне 0,9–0,97 [15]. В нашем эксперименте RF без метеоданных дал $RMSE = 1,214$ кВт·ч и $R^2 = 0,943$, а с добавлением погодных факторов RMSE снизился до 1,163 кВт·ч, R^2 вырос до 0,948. Хотя улучшение меньше, чем для ARIMA. Random Forest уже учитывает нелинейные зависимости и автокорреляцию, поэтому внешняя информация даёт локальную оптимизацию, а не радикальный скачок.

Гибридная архитектура STL + RF + метео показала лучший результат. Предварительное выделение тренда и сезонности, а затем обучение модели на остатке – это подход, который широко обсуждается в литературе. В ряде работ показано, что декомпозиция снижает риск переобучения и повышает устойчивость алгоритмов для процессов с выраженной сезонностью. STL+RF без метеоданных показал $RMSE = 1,26$ кВт·ч

и $R^2 = 0,939$, что сопоставимо с чистым RF, но с более стабильным поведением. После подключения метеоданных гибридная схема достигла $RMSE = 1,204$ кВт·ч и $R^2 = 0,944$. Этот результат обеспечил лучший баланс между ошибкой и стабильностью среди всех архитектур.

Анализ важности признаков подтвердил ключевую роль суточного цикла и основных метеопараметров. Лаг мощности на 24 ч дал около 35 % суммарной важности, освещённость за час – порядка 25 %, температура воздуха – около 18 %. Такая структура хорошо согласуется с физикой солнечной генерации и результатами других исследований. Параметры ветра и осадков продемонстрировали низкую важность, что не удивительно для регионов с устойчивой инсоляцией; их влияние опосредуется в основном через облачность, уже отражённую в показателях освещённости.

Если сравнивать с обзорами по ансамблям и нейросетям, полученные значения R^2 на уровне 0,94–0,95 можно смело считать хорошими для прогноза электроэнергии на 1 ч вперед. Более сложные модели, например LSTM, если у них будет огромное количество данных, смогут добавить больше точности, но взамен потребуют большей вычислительные затраты и настройку [16]. Гибридный ансамбль STL + RF оказывается оптимальным сочетанием точности, интерпретируемости и затратами на вычисления. На основе проведённого исследования предлагается применить четырёхуровневый подход к управлению рисками [7]. Это не совсем новая

идея, но комбинация прогнозирования с остальными компонентами даёт хороший результат. На выходе получаем прогноз на 1, 3 и 6 ч вперёд и диапазон неопределённости (обычно 90-процентный интервал) [17]. Диапазон важен, потому что при облачной погоде ошибка выше, а при ясном небе – ниже.

Первый уровень, собственно говоря, прогнозирование. Используется гибридная модель STL + RF + метео, которая показала лучшие результаты. Она лучше других справляется с внезапными изменениями облачности и одновременно достаточно стабильна. Модель нужно переучивать каждый месяц или даже чаще, если погода меняется сезонно. Входные данные, которые необходимы: измеренная мощность станции и текущие метеопараметры.

Второй уровень – анализ рисков. Тут берутся прогнозные значения генерации, известные параметры сети (сопротивления, ёмкости, пропускные способности линий), ожидаемая нагрузка потребителей и прочее. Вычисляется, насколько напряжение отклонится от номинального при этом прогнозе. Основной расчёт будет линейным, но включает попытки учесть адаптивные фильтры напряжения и регуляторы, если они есть в сети. Главный момент: нужно учесть не только центральное значение ошибки прогноза, но и её разброс. Если облачно и непредсказуемо, разброс большой, соответственно, больше и риск. Это реализуется через адаптивные коэффициенты, которые меняются в зависимости от прогноза погоды.

Третий уровень – сигналы. Когда вероятность нарушения качества превышает определённый порог, система выдаёт сигнал диспетчеру. Обычно двухступенчатая система: жёлтое предупреждение (вероятность ~10–15%), красный сигнал (вероятность ~35–40%). Пороги можно настраивать под конкретную сеть, потому что где-то дорого резервировать мощность, а где-то дорого платить штрафы за нарушение качества.

Четвёртый уровень реагирования – то, что диспетчер или автоматика делают, получив сигнал. Вариантов несколько. Можно управлять батарейным накопителем: зарядить его заранее перед ожидаемым провалом солнца или разрядить при избытке генерации. Можно просто ограничить выдачу мощности от ФЭ-станции, снизив угол наклона панелей. Можно попробовать перенести нагрузку потребителей (например, отложить зарядку электромобилей на более благоприятный час). И наконец, можно включить дизель-генератор, если критично. Лучший результат получается, когда используется комбинация этих методов одновременно.

Ограничения этого подхода: во-первых, используются фактические метеоданные, а не прогнозы. На практике нужны прогнозы погоды, и они не всегда точны (ошибка может быть 15–30%); во-вторых, горизонт в нашем исследовании всего один час. Для длинных горизонтов (6–24 ч) точность падает; в-третьих, все расчёты основаны на линейных моделях сети, а реальные сети нелинейны. И наконец, всё это рабо-

тает хорошо только в том случае, если есть батарея или гибкая нагрузка.

Метеорологические параметры критичны. При добавлении информации об освещённости, температуре и влажности все три модели улучшились. ARIMA дал наибольший выигрыш – RMSE упал с 6,017 до 5,195 (улучшение – 86%). R^2 при этом изменился с $-0,395$ до $-0,04$. Формально R^2 остался отрицательным, но это огромный скачок в правильном направлении. Random Forest показал меньший процентный прирост (около 4%), потому что уже хорошо работал на данных. Но даже небольшое улучшение статистически значимо. Это совпадает с тем, что пишут в научной литературе: линейным моделям метеоданные нужны больше, чем нелинейным.

Также машинное обучение работает намного лучше, чем статистика. Random Forest достиг $R^2 = 0,943 - 0,948$ в зависимости от варианта. Это соответствует лучшим опубликованным работам по краткосрочному прогнозированию солнечной генерации. ARIMA даже с метеоданными остался на минусовых R^2 , потому что линейная модель просто не может отразить нелинейность солнечной генерации. Когда облако закрывает солнце, мощность падает не по формуле, а скачком. ARIMA предсказывать скачки не может. Гибридный подход (STL + RF + метео) показал лучший баланс. Не самую высокую точность, но самую стабильную. Ошибки распределены равномерно, без больших выбросов. Для практики это важнее, чем максимальная точность в среднем. Когда вы управляете энергосистемой, предска-

зуемые ошибки лучше, чем отличная средняя точность с редкими катастрофическими промахами.

Анализ важности признаков показал, что мощность 24 ч. назад получила 35 % важности. Это логично: погода примерно повторяется каждые сутки. Освещённость за час до этого получила 25 % – это прямая физическая связь между интенсивностью солнца и выработкой. Температура – 18 %, потому что КПД панелей падает при нагреве. Ветер и осадки почти ничего – менее 1 %. В других регионах структура была бы другой. Но для этого региона модель выучила правильные физические зависимости, хотя мы её этому не учили специально.

На практике результаты говорят о том, что такую методику можно использовать для построения систем раннего предупреждения в электрических сетях с большой долей ВИЭ [18]. Прогноз генерации даёт диспетчеру несколько часов на подготовку к скачкам мощности. Это позволяет заранее зарядить батарею, перенести потребление или включить резерв.

Выводы

Проведенные исследования были выполнены при следующих ограничениях и допущениях:

1. Анализ выполнен для одной станции, и для более глубокого анализа необходимо использовать данные других станций и в других климатических условиях.
2. Использование фактических метеоданных. На практике диспетчер анализирует прогноз погоды, который в

некоторых случаях бывает недостоверным. Включение данной ошибки повлечет за собой снижение точности.

3. Горизонт прогноза – один час. Для диспетчеризации необходимы прогнозы на 6, 12 или 24 ч. На более длинные горизонты ошибка растёт экспоненциально.

4. Электрическая сеть не совсем линейна, как мы предполагали. Регуляторы напряжения, трансформаторы, другие устройства вносят нелинейности. Полный расчёт требует электромагнитного моделирования. Также в трёхмесячном датасете не охвачены все возможные погодные режимы, которые можно было

бы описать при анализе годовых погодных данных, что является основанием для дальнейших исследований.

В отличие от других работ, ориентированных только на минимизацию ошибки, мы предложили методологию, позволяющую на основе прогноза оценивать риски для качества электроэнергии, в основе которой лежит четырёхуровневая схема. Гибридная модель STL + RF с метеоданными даёт лучший баланс точности и стабильности, чем статистические методы и чистый Random Forest. Такой подход может стать основой для систем раннего реагирования.

Список литературы

1. PV Power Forecasting Based on Data-Driven Models: A Review / S. Al-Dahidi, O. Ayadi, J. Adeeb, M. Louzazni // *International Journal of Sustainable Engineering*. 2021. Vol. 14, N 4. P. 1733–1755.
2. Методы краткосрочного прогнозирования выработки электрической энергии солнечными электростанциями и их классификация / Д. А. Тюньков, А. А. Сапилова, А. С. Грицай, Д. А. Алексеенко, Р. Н. Хамитов // *Электротехнические системы и комплексы*. 2020. № 3 (48). С. 4–10.
3. Сергеев Н. Н., Матренин П. В. Обзор международного опыта в прогнозировании генерации возобновляемых источников энергии с помощью методов машинного обучения // *iPolytech Journal*. 2023. Т. 27, № 2. С. 354–369.
4. Нильсен Э. Практический анализ временных рядов: прогнозирование со статистикой и машинное обучение: [пер. с англ.]. СПб.: Диалектика, 2021. 544 с.
5. Николаев А. А., Исмаилов Н. В. Применение нейросетевых технологий для вычисления потоков суммарной солнечной радиации // *Известия высших учебных заведений. Поволжский регион. Естественные науки*. 2017. № 3. С. 68–77.
6. Ahmad T., Zhang H. A Data-Driven Approach to Composite Building Energy Modeling with Machine Learning Algorithms // *Applied Energy*. 2020. Vol. 267. P. 114863.
7. Кончаков В. Ю., Панов А. И., Юсупов Р. М. Интеллектуальные методы управления энергосистемами с возобновляемыми источниками // *Информационные и математические технологии в науке и управлении*. 2023. № 3. С. 15–28.

8. Кузнецов А. В., Иванов С. П. Возобновляемые источники энергии в автономных системах электроснабжения: влияние на качество электроэнергии // *Электроэнергетика*. 2020. № 4. С. 112–120.
9. Chodakowska E., Nazarko J., Nazarko Ł. ARIMA Models in Solar Radiation Forecasting // *Energies*. 2023. Vol. 16, N 13. P. 5029.
10. Breiman L. Random Forests // *Machine Learning*. 2001. Vol. 45, N 1. P. 5–32.
11. Лосев А. С., Массель А. Г. Прогнозирование солнечной радиации и импутация данных для цифрового двойника солнечной электростанции // *Информационные и математические технологии в науке и управлении*. 2022. № 1 (25). С. 91–101.
12. STL: A Seasonal-Trend Decomposition Procedure Based on Loess / R. B. Cleveland, W. S. Cleveland, J. E. McRae, I. Terpenning // *Journal of Official Statistics*. 1990. Vol. 6, N 1. P. 3–73.
13. Hyndman R. J., Athanasopoulos G. *Forecasting: Principles and Practice*. 3rd ed. Melbourne: OTexts, 2021. 442 p.
14. Сокур П. В., Полякова А. С. Прогнозирование выработки солнечной электростанции на основе алгоритмов машинного обучения // *Вестник Торайгыров университета. Энергетическая серия*. 2022. № 1. С. 45–52.
15. Meng M., Song C. Daily Photovoltaic Power Generation Forecasting Model Based on Random Forest Algorithm for North China in Winter // *Sustainability*. 2020. Vol. 12, N 6. P. 2247.
16. Mellit A., Pavan A. M., Lughi V. Deep Learning Neural Networks for Short-Term PV Output Forecasting // *Energies*. 2021. Vol. 14, N 1. P. 112.
17. Zamo M., Meunier P. Quantile-Based Probabilistic Forecasts of Solar Irradiance Using Quantile Regression Forests // *Energies*. 2016. Vol. 9, N 6. P. 494.
18. A Survey on Deep Learning Methods for Power Load and Renewable Energy Forecasting in Smart Microgrids / S. Aslam, H. Herodotou, S. M. Mohsin, N. Javaid, N. Ashraf, S. Aslam // *Renewable and Sustainable Energy Reviews*. 2021. Vol. 144. P. 110992.

References

1. Al-Dahidi S., Ayadi O., Adeeb J., Louzazni M. PV Power Forecasting Based on Data-Driven Models: A Review. *International Journal of Sustainable Engineering*. 2021;14(4):1733-1755.
2. Tyunkov D.A. Sapilova A.A., Gritsai A.S., Alekseenko D.A., Khamitov R.N. Methods for short-term forecasting of solar power plant generation and their. *Elektrotekhnicheskie sistemy i komplekсы = Electrical Systems and Complexes*. 2020;(3):4-10.
3. Sergeev N.N., Matrenin P.V. Review of international experience in forecasting renewable energy generation using machine learning methods. *iPolytech Journal*. 2023;27(2):354-369. (In Russ.)

4. Nielsen E. Practical time series analysis: forecasting with statistics and machine learning. Saint Petersburg: Dialektika, 2021. 544 p. (In Russ.)
5. Nikolaev A.A., Ismagilov N.V. Application of neural network technologies for calculating total solar radiation fluxes. *Izvestiya vysshikh uchebnykh zavedenii. Povolzhskii region. Estestvennye nauki = University Proceedings. Volga Region. Natural Sciences*. 2017;(3):68-77. (In Russ.)
6. Ahmad T.A, Zhang H. Data-Driven Approach to Composite Building Energy Modeling with Machine Learning Algorithms. *Applied Energy*. 2020;267: 114863.
7. Konchakov V.Yu., Panov A.I., Yusupov R.M. Intelligent methods for controlling power systems with renewable sources. *Informatsionnye i matematicheskie tekhnologii v nauke i upravlenii = Information and Mathematical Technologies in Science and Management*. 2023;(3):15-28. (In Russ.)
8. Kuznetsov A.V., Ivanov S.P. Renewable energy sources in autonomous power supply systems: impact on electric energy quality. *Elektroenergetika = Electric Power Engineering*. 2020;(4):112–120. (In Russ.)
9. Chodakowska E., Nazarko J., Nazarko Ł. ARIMA Models in Solar Radiation Forecasting. *Energies*. 2023;16(13):5029.
10. Breiman L. Random Forests. *Machine Learning*. 2001;45(1):5-32.
11. Losev A.S., Massel A.G. Solar radiation forecasting and data imputation for a digital twin of a solar power plant. *Informatsionnye i matematicheskie tekhnologii v nauke i upravlenii = Information and Mathematical Technologies in Science and Management*. 2022;(1):91-101. (In Russ.)
12. Cleveland R.B., Cleveland W.S., McRae J.E., Terpenning I. STL: A Seasonal-Trend Decomposition Procedure Based on Loess. *Journal of Official Statistics*. 1990;6(1):3-73.
13. Hyndman R.J., Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. Melbourne: OTexts; 2021. 442 p.
14. Sokur P.V., Polyakova A.S. Forecasting solar power plant generation based on machine learning algorithms. *Vestnik Toraigrov universiteta. Energeticheskaya seriya = Bulletin of Toraigrov University. Energy Series*. 2022;(1):45-52. (In Russ.)
15. Meng M., Song C. Daily Photovoltaic Power Generation Forecasting Model Based on Random Forest Algorithm for North China in Winter. *Sustainability*. 2020;12(6):2247.
16. Mellit A., Pavan A. M., Lughi V. Deep Learning Neural Networks for Short-Term PV Output Forecasting. *Energies*. 2021;14(1):112.
17. Zamo M., Meunier P. Quantile-Based Probabilistic Forecasts of Solar Irradiance Using Quantile Regression Forests. *Energies*. 2016;9(6):494.
18. Aslam S., Herodotou H., Mohsin S. M., Javaid N., Ashraf N., Aslam S. A Survey on Deep Learning Methods for Power Load and Renewable Energy Forecasting in Smart Microgrids. *Renewable and Sustainable Energy Reviews*. 2021;144:110992.

Информация об авторах / Information about the Authors

Брежнев Игорь Вадимович, аспирант,
Юго-Западный государственный университет,
г. Курск, Российская Федерация,
e-mail: b89038750930@gmail.com,
ORCID: 0009-0000-4048-4861

Igor V. Brezhnev, Postgraduate,
Southwest State University,
Kursk, Russian Federation,
e-mail: b89038750930@gmail.com,
ORCID: 0009-0009-3117-5595

Чернецкая Ирина Евгеньевна, доктор
технических наук, заведующий кафедрой
вычислительной техники, Юго-Западный
государственный университет,
г. Курск, Российская Федерация,
e-mail: white731@yandex.ru,
ORCID: 0009-0009-8254-9606

Irina E. Chernetskaya, Dr. Sci.
(Engineering), Head of the Department
of Computer Science, Southwest State
University, Kursk, Russian Federation,
e-mail: white731@yandex.ru,
ORCID: 0009-0009-8254-9606

<https://doi.org/10.21869/2223-1536-2026-16-2-197-208>



УДК 534.8+57.087.1

Исследование мозговой активности и концентрации внимания при выполнении интеллектуальных задач

Д. А. Кравчук¹ ✉, В. Л. Сахаров², И. А. Кириченко²

¹ Институт нанотехнологий, электроники и приборостроения Южного федерального университета
ул. Шевченко, д. 2, корп. «Е», Ростовская область, г. Таганрог 347922, Российская Федерация

² Научно-медицинская фирма «Нейротех»
ул. Дзержинского, д. 119А, Ростовская область, г. Таганрог 347905, Российская Федерация

✉ e-mail: kravchukda@sfedu.ru

Резюме

Цель исследований – изучить особенности мозговой активности при выполнении интеллектуальных задач в условиях низкого (индивидуальное задание) и высокого (экзамен) уровня стресса на основе анализа спектральных характеристик электроэнцефалограммы.

Методы. В исследовании приняли участие 32 человека (18 женщин, 14 мужчин, средний возраст $19,4 \pm 1,2$ года). Регистрация электроэнцефалограммы проводилась с использованием портативного 4-канального нейроинтерфейса BrainBit (ООО НМФ «Нейротех», Россия) в положениях Fp1, Fp2, O1, O2. Проведено сравнения двух видов интеллектуальных задач: защита индивидуального задания и устный экзамен. Рассчитывалась относительная мощность тета-, альфа- и бета-ритмов. Статистический анализ проводился с применением критерия Вилкоксона для связанных выборок ($p < 0,05$).

Результаты. При переходе от индивидуального задания к экзамену выявлено достоверное снижение альфа-ритма (с $42,3$ до $36,5$ %; $Z = -4,12$, $p < 0,001$, $r = 0,73$) и значимый рост бета-ритма (с $28,5$ до $36,1$ %; $Z = -4,37$, $p < 0,001$, $r = 0,77$). Тета-ритм продемонстрировал умеренное снижение (с $29,2$ до $27,4$ %; $Z = -2,04$, $p = 0,041$, $r = 0,36$).

Заключение. Экзаменационная ситуация вызывает у участников переключение нейродинамики в сторону активационного профиля: снижается расслабленность (α), усиливается когнитивная активация и концентрация внимания (β). Полученные данные подтверждают возможность использования количественного анализа электроэнцефалограммы как объективного инструмента оценки функционального состояния обучающихся в реальных образовательных условиях.

Ключевые слова: нейроинтерфейс; электроэнцефалограмма; мозговая активность; интеллектуальные задачи.

Конфликт интересов: Авторы декларируют отсутствие конфликта интересов, связанных с публикацией данной статьи.

Для цитирования: Кравчук Д. А., Сахаров В. Л., Кириченко И. А. Исследование мозговой активности и концентрации внимания при выполнении интеллектуальных задач // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2 С. 197–208. <https://doi.org/10.21869/2223-1536-2026-16-2-197-208>.

Поступила в редакцию 16.04.2026

Подписана в печать 14.05.2026

Опубликована 30.06.2026

A study of students' brain activity and concentration while performing intellectual tasks

Denis A. Kravchuk¹ ✉, Vadim L. Sakharov², Igor A. Kirichenko²

¹ Institute of Nanotechnology, Electronics and Instrument Engineering at the Southern Federal University
2/E Shevchenko Str., Rostov Region, Taganrog 347922, Russian Federation

² Neurotech Scientific and Medical Company
119A Dzerzhinskogo Str., Rostov Region, Taganrog 347905, Russian Federation

✉ e-mail: kravchukda@sfedu.ru

Abstract

The purpose of the research is to study the characteristics of students' brain activity while performing intellectual tasks under low (individual assignment) and high (exam) stress conditions based on the analysis of electroencephalogram spectral characteristics.

Methods. Thirty-two students (18 women, 14 men; average age $19,4 \pm 1,2$ years) participated in the study. Electroencephalogram recordings were conducted using a portable 4-channel BrainBit neural interface (Neurotech LLC, Russia) in the Fp1, Fp2, O1, and O2 positions. Two conditions were compared: completing an individual assignment and taking an oral exam. The relative power of theta, alpha and beta rhythms was calculated. Statistical analysis was performed using the Wilcoxon signed-rank test for related samples ($p < 0,05$).

Results. When transitioning from the individual assignment to the exam, a significant decrease in the alpha rhythm (from 42,3 to 36,5 %; $Z = -4,12$, $p < 0,001$, $r = 0,73$) and a significant increase in the beta rhythm (from 28,5 to 36,1 %; $Z = -4,37$, $p < 0,001$, $r = 0,77$) were observed. The theta rhythm demonstrated a moderate decrease (from 29,2 to 27,4 %; $Z = -2,04$, $p = 0,041$, $r = 0,36$).

Conclusion. The exam situation causes students' neurodynamics to shift toward an activation profile: relaxation (α) decreases, while cognitive activation and concentration (β) increase. The obtained data confirm the feasibility of using quantitative electroencephalogram analysis as an objective tool for assessing the functional state of students in real-world educational settings.

Keywords: neurointerface; electroencephalogram; brain activity; intellectual tasks.

Conflict of interest: The authors declares no conflict of interest related to the publication of this article.

For citation: Kravchuk D.A., Sakharov V.L., Kirichenko I.A. A study of students' brain activity and concentration while performing intellectual tasks. *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(2):197–208. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-197-208>.

Received 16.04.2026

Accepted 14.05.2026

Published 30.06.2026

Введение

Современная образовательная среда характеризуется высокой интенсивностью когнитивных нагрузок, особенно в периоды промежуточной и итоговой

аттестации. В этих условиях особую значимость приобретает объективная оценка функционального состояния студентов, основанная не только на поведенческих, но и на нейрофизиологи-

ческих показателях. Электроэнцефалография (ЭЭГ) позволяет в реальном времени регистрировать динамику мозговой активности через анализ спектральных характеристик ритмов: тета (θ), альфа (α) и бета (β), что делает её ценным инструментом для исследования механизмов внимания, стресса и когнитивной перегрузки [1].

Несмотря на широкое применение ЭЭГ в когнитивной нейронауке, остаётся недостаточно исследований, посвящённых сравнительному анализу нейродинамики в реальных учебных ситуациях, отличающихся по уровню эмоционального напряжения (например, при выполнении индивидуального задания и сдаче экзамена). Такие данные необходимы для разработки адаптивных образовательных технологий, профилактики когнитивного истощения и оптимизации экзаменационных процедур [2].

Особую актуальность приобретает проблема экзаменационного стресса, который у значительной части студентов сопровождается тревожностью, снижением продуктивности и нарушением саморегуляции [3]. Нейрофизиологические маркеры, такие как снижение α -ритма и усиление β -активности, могут служить объективными индикаторами перехода мозга в режим повышенной концентрации и напряжения [4]. При этом роль θ -ритма в контексте учебной деятельности остаётся дискуссионной: одни исследования связывают его с глубокой концентрацией [5], другие – с креативностью или даже когнитивным истощением [6].

Таким образом, комплексный анализ изменений спектрального профиля ЭЭГ у студентов в условиях различной когнитивной и эмоциональной нагрузки

представляет собой важное направление, способствующее интеграции нейронаук в педагогическую практику и повышению качества высшего образования [7].

Исследования последних лет подтверждают, что альфа-ритм (8–13 Гц) является ключевым маркером «идлинг-состояния» коры головного мозга. Его мощность снижается при включении внимания, рабочей памяти и обработке внешней информации – феномен, известный как альфа-десинхронизация [8]. У студентов это проявляется при решении задач любой сложности, особенно в условиях ограниченного времени [9].

В противоположность этому бета-ритм (13–30 Гц) отражает активацию префронтальных и теменных зон, ответственных за исполнительные функции, когнитивный контроль и принятие решений [10]. Его усиление достоверно коррелирует с уровнем когнитивной нагрузки и тревожности [11]. Например, исследования, проведенные в [12], показали, что у студентов-медиков в экзаменационный период мощность β -ритма возрастает на 6–9%, что связано с активацией систем стресс-реакции.

Тета-ритм (4–7 Гц) демонстрирует более сложную динамику. С одной стороны, он ассоциируется с глубокой внутренней концентрацией, особенно у студентов технических специальностей [13], с другой – его рост может указывать на когнитивное истощение при длительной умственной работе [14]. Анализ существующих подходов [15] отмечают, что у успешных студентов θ -активность локализована в лобных отделах и связана с эффективной обработкой информации, тогда как у тре-

возможных – с эмоциональной дезорганизацией.

Ряд работ посвящён индивидуальным различиям в нейрофизиологическом ответе на нагрузку. Показано, что уровень академической успеваемости, тип нервной системы и базовая тревожность модулируют выраженность ЭЭГ-изменений [16]. Например, у студентов с высокой мотивацией наблюдается более выраженная β -активация без падения α -ритма, что свидетельствует о «эффективной» нейродинамике [17].

Особое внимание уделяется практическому применению ЭЭГ-мониторинга в образовании [18]. Предложены модели раннего выявления когнитивного перенапряжения [19], а также методы персонализации обучения на основе нейрофизиологического профиля [20]. Однако большинство исследований проводится в лабораторных условиях, что ограничивает их экологическую валидность.

Настоящее исследование восполняет этот пробел, анализируя ЭЭГ-показатели в естественных учебных условиях – при защите индивидуально-го задания и сдаче экзамена. Это позволяет получить данные, имеющие прямое прикладное значение для педагогики и психофизиологии труда студентов. Полученные результаты согласуются с современными представлениями о нейрофизиологических механизмах когнитивной активации и стресса.

Материалы и методы

В исследовании приняли участие 32 студента (18 женщин, 14 мужчин, средний возраст – $19,4 \pm 1,2$ года), обучающихся на 3-4 курсах технического вуза. Все участники дали письменное

информированное согласие на участие в исследовании. Критерии включения: отсутствие неврологических и психиатрических заболеваний, нормальное или скорректированное зрение, регулярное посещение занятий. Исследование проведено в соответствии с этическими принципами Хельсинкской декларации.

Регистрация ЭЭГ осуществлялась с использованием портативного 4-канального нейроинтерфейса BrainBit (производитель: ООО НМФ «Нейротех», Россия). Система обеспечивает запись биоэлектрической активности мозга в диапазоне частот 0,5–45 Гц с частотой дискретизации 250 Гц. Электроды размещались в соответствии с международной системой «10–20» в положениях T3, T4, Fp2, O1, O2 (лобно-полюсные и затылочные области), что позволяет оценить как префронтальную (внимание, исполнительные функции), так и затылочную (зрительная обработка, альфа-активность) кортикальную активность [1].

Данные передавались по Bluetooth в ПО BrainBit Recorder, где проводилась фильтрация (полосовой фильтр 2–30 Гц), удаление артефактов движения и миганий с использованием адаптивного алгоритма на основе порогового детектирования амплитуды. Для каждого участника регистрировались два сеанса:

1. Индивидуальное задание – защита курсовой работы в спокойной обстановке (длительность – 10 минут);
2. Экзамен – устный ответ на билет (длительность – 10 минут).

Спектральный анализ выполнялся в программной среде Python 3.10 с использованием библиотек MNE, SciPy и NumPy. Для каждого канала рассчиты-

валась относительная мощность ритмов в стандартных диапазонах: тета: 4–7 Гц; альфа: 8–13 Гц; бета: 14–30 Гц.

Относительная мощность (%) определялась как отношение мощности в данном диапазоне к общей мощности сигнала (2–30 Гц), усреднённое по всем каналам и по времени записи. Полученные значения усреднялись по каждому участнику для каждого условия.

Статистическая обработка выполнена в SPSS Statistics 28. Для проверки нормальности распределения использовался тест Шапиро – Уилка. Поскольку распределение большинства переменных не соответствовало нормальному ($p < 0,05$), для сравнения двух зависимых выборок (индивидуальное задание vs. экзамен) применён непараметрический критерий Вилкоксона для связанных выборок. Уровень статистической значимости принят за $p < 0,05$.

Для оценки величины эффекта рассчитан коэффициент r по формуле

$$r = \frac{Z}{\sqrt{N}},$$

где Z – значение статистики Вилкоксона; N – количество наблюдений.

Интерпретация: $r = 0,1$ – малый эффект; $r = 0,3$ – средний; $r = 0,5$ – большой [2].

Результаты и их обсуждение

Полученные результаты согласуются с современными представлениями о нейрофизиологических механизмах когнитивной активации. Снижение мощности альфа-ритма при переходе от спокойного выполнения индивидуального задания к экзаменационной ситуации подтверждает его роль как маркера «идлинг-состояния» мозга: при вклю-

чении внимания и рабочей памяти альфа-активность подавляется, что позволяет кортикальным сетям перейти в режим обработки внешней информации [1]. Это явление, известное как альфа-десинхронизация, является надёжным ЭЭГ-коррелятом когнитивной нагрузки.

Рассмотрим среднее распределение ритмов при сдаче индивидуального задания студентами всей группы (рис. 1).

Защита индивидуального задания




Рис. 1. Среднее распределение ритмов при сдаче индивидуального задания студентами всей группы

Fig. 1. Average distribution of rhythms when submitting an individual assignment

Одновременный рост бета-ритма на 7,6% указывает на активацию префронтальных и теменных кортикальных зон, ответственных за исполнительные функции, контроль внимания и принятие решений [2]. Увеличение бета-активности в условиях стресса (рис. 2) также связано с повышенным уровнем тревожности и внутреннего напряжения, что типично для экзаменационной среды [3]. Интересно, что тета-ритм, несмотря на его связь с глубокой концентрацией у студентов [4], в нашем исследовании продемонстрировал незначительное снижение. Это может

свидетельствовать о том, что в условиях оценочной тревоги доминирует не творческая или медитативная концентрация, а напряжённая, контролируемая активность, характеризующаяся преимущественно бета-доминантой.




Рис. 2. Среднее распределение ритмов при сдаче экзамена студентами всей группы

Fig. 2. Average distribution of rhythms during the exam

Важно отметить, что наблюдаемые изменения носят функциональный и обратимый характер, что подчёркивает адаптивную природу нейрофизиологического ответа на учебную нагрузку. Однако хроническое повторение подобных состояний без достаточного восстановления может способствовать развитию когнитивного истощения и снижению учебной эффективности [5].

На экзамене по сравнению с индивидуальным заданием (см. рис. 1) наблюдается:

- значительный рост β -ритма (+7,6%) → усиление когнитивной активности, концентрации, напряжённости (табл. 1);

- снижение α -ритма (–5,8%) → потеря расслабленности, переход в режим «рабочего» состояния;

- незначительное снижение θ -ритма (–1,8%) → минимальное уменьшение «спокойного» фонового состояния.

Таблица 1. Изменение ритмов, интерпретация результатов, %

Table 1. Change of rhythms, interpretation of results, %

Ритм	Индивид. задание	Экзамен	Изменение	Интерпретация
θ (тета)	29,2	27,4	**–1,8**	Незначительное снижение – возможное уменьшение расслабленного / снарядного состояния
α (альфа)	42,3	36,5	**–5,8**	Заметное снижение – снижение спокойствия, расслабленности, внутреннего покоя
β (бета)	28,5	36,1	**+7,6**	Существенное увеличение – рост активности, концентрации, напряжения, тревожности

Экзаменационная ситуация вызывает у студентов значительное повышение мозговой активности (β -ритм), сопровождающееся снижением расслабленности (α -ритм). Это соответ-

ствует психофизиологическим закономерностям: при стрессе и когнитивной нагрузке мозг переключается в режим высокой концентрации и активности.

Сравнительный анализ спектральных характеристик ЭЭГ выявил достоверные различия между условиями

«индивидуальное задание» и «экзамен» по всем трём ритмам (табл. 2).

Таблица 2. Результаты обработки ритмов, оценка отклонений

Table 2. Results of rhythm processing, assessment of deviations

Ритм	Условие	Среднее (M)	Стандартное отклонение (SD)	Медиана	Интерквартильный размах
θ (%)	Индивидуальное задание	29,2	6,8	28,9	[24,1–33,7]
	Экзамен	27,4	7,1	26,8	[22,3–31,5]
α (%)	Индивидуальное задание	42,3	8,4	41,7	[36,2–47,9]
	Экзамен	36,5	9,2	35,8	[29,4–42,1]
β (%)	Индивидуальное задание	28,5	7,9	27,6	[22,8–33,4]
	Экзамен	36,1	8,6	35,9	[29,7–41,2]

Описательная статистика относительной мощности ритмов ЭЭГ (% , $M \pm \pm SD$; медиана [25–75 %]).

Такое представление информации позволяет выявить статистические различия:

1. По альфа-ритму – снижение на 5,8 % при переходе к экзамену. Критерий Вилкоксона: $Z = -4,12$, $p < 0,001$, величина эффекта $r = 0,73$ (большой эффект).

2. По бета-ритму – увеличение на 7,6 %. Критерий Вилкоксона: $Z = -4,37$, $p < 0,001$, $r = 0,77$ (большой эффект).

3. По тета-ритму – снижение на 1,8 %. Критерий Вилкоксона: $Z = -2,04$, $p = 0,041$, $r = 0,36$ (средний эффект).

Таким образом, наиболее выраженные изменения наблюдаются в альфа- и бета-диапазонах, что указывает на значимый сдвиг в сторону активационного профиля мозговой активности в условиях экзаменационного стресса.

Выводы

Настоящее исследование имеет ограничения: анализ проводился на основе усреднённых данных по группе, без учёта индивидуальных различий в нейрофизиологическом профиле (например, базового уровня тревожности или типа нервной системы). Тем не менее выявленные тенденции открывают перспективы для использования ЭЭГ-мониторинга в образовательной практике (например, для объективной оценки уровня стресса во время онлайн-экзаменов или для персонализации темпа обучения).

При переходе от выполнения индивидуального задания к сдаче экзамена у студентов наблюдается достоверное изменение спектрального профиля ЭЭГ: снижение альфа-ритма на 5,8 % и увеличение бета-ритма на 7,6 %.

Эти изменения отражают переключение мозга в режим повышенной ко-

гнитивной активации, концентрации внимания и исполнительного контроля, что является адаптивной реакцией на экзаменационный стресс.

Полученные данные подтверждают возможность использования количественного анализа ЭЭГ-ритмов как объективного инструмента оценки функ-

ционального состояния студентов в условиях интеллектуальной нагрузки.

Результаты могут быть использованы для разработки рекомендаций по оптимизации экзаменационных процедур, снижению учебного стресса и повышению качества образовательного процесса на основе нейрофизиологических данных.

Список литературы

1. Говорухина А. А., Левчук А. А. Факторы, влияющие на умственную работоспособность студентов (обзор литературы) // Современные вопросы биомедицины. 2024. Т. 8, № 1. URL: <https://svbskfmba.ru/arkhiv-nomerov/2024-1/govorukhina2024> (дата обращения: 04.03.2026). https://doi.org/10.24412/2588-0500-2024_08_01_6.
2. Различия ЭЭГ при восприятии своего и чужого лица: применение комплексного подхода к анализу данных ЭЭГ / Г. В. Портнова, Л. Б. Окнина, Е. Л. Машеров, А. А. Слезкин, В. В. Подлепич // Журнал высшей нервной деятельности им. И. П. Павлова. 2022. Т. 72, № 4. С. 576–586. <https://doi.org/10.31857/S0044467722030091>.
3. Биоэлектрическая активность головного мозга и церебральная гемодинамика у спортсменов при сочетании когнитивной и физической нагрузки / Л. В. Капилевич, Г. С. Ежова, А. Н. Захарова, А. В. Кабачкова, С. Г. Кривошеков // Физиология человека. 2019. Т. 45, № 2. С. 58–69. <https://doi.org/10.1134/S0131164619010089>.
4. Гуляев С. А. Электроэнцефалография и исследования функциональной активности головного мозга // Русский журнал детской неврологии. 2021. Т. 16, № 4. С. 59–68. <https://doi.org/10.17650/2073-8803-2021-16-4-59-68>.
5. Влияние тревожности, связанной с экзаменационным стрессом, на смещение зрительного внимания и электрическую активность фронтальных зон мозга / А. П. Астащенко, Н. П. Горбатенко, Е. В. Дорохов, С. И. Варварова, П. В. Зяблова // Ульяновский медико-биологический журнал. 2020. № 2. С. 100–111. <https://doi.org/10.34014/2227-1848-2020-2-100-111>.
6. Биоэлектрическая активность мозга студентов при когнитивной деятельности в условиях ограничения времени / Н. В. Звягина, А. И. Талеева, К. В. Новоселова, А. С. Черкасова, Т. Ч. Чанг, Н. В. Попов // Siberian Journal of Life Sciences and Agriculture. 2025. Т. 17, № 6-1. С. 51–75. <https://doi.org/10.12731/2658-6649-2025-17-6-1-1317>.
7. Леонтьева А. Д., Зубарев А. С. Тревожность и нейрофизиологические маркеры: анализ с использованием мобильной ЭЭГ // Национальный психологический журнал. 2025. Т. 20, № 1. С. 75–85. <https://doi.org/10.11621/npj.2025.0107>.
8. Кижеватова Е. А., Караханян К. С., Болдырева М. А. Особенности электроэнцефалограммы у студентов с разным уровнем личностной и ситуативной тревожности в

условиях экзаменационного стресса // *Universum: медицина и фармакология*. 2026. № 4 (133). С. 29–38.

9. Максимова М. В., Этуев Х. Х. Опыт применения ЭЭГ в образовании: анализ зарубежных исследований // *Отечественная и зарубежная педагогика*. 2023. Т. 1, № 2 (91). С. 169–185. <https://doi.org/10.24412/2224-0772-2023-91-169-185>. EDN HKLMWP.

10. Костромина С. Н., Гнедых Д. С. Нейронаука в системе профессионального образования // *Профессиональное образование и рынок труда*. 2021. № 4 (47). С. 8–29.

11. Рустамова Т. В. Влияние экзаменационного стресса на амплитуду волн ЭЭГ в теменной доле головного мозга у студентов факультета биологии-химии с различными индивидуально-типологическими особенностями // *Siberian Journal of Life Sciences and Agriculture*. 2020. Т. 12, № 5. С. 97–112. <https://doi.org/10.12731/2658-6649-2020-12-5-97-112>.

12. Рустамова Т. В. Изменение ЭЭГ в лобной доле коры головного мозга под влиянием экзаменационного процесса у 18-летних студентов флегматического типа // *Международный научно-исследовательский журнал*. 2022. № 7 (121). С. 87–90. <https://doi.org/10.23670/IRJ.2022.121.7.054>.

13. Рустамова Т. В. Сравнительный анализ влияния экзаменационного стресса на уровень ситуативной и личностной тревожности студентов // *Siberian Journal of Life Sciences and Agriculture*. 2021. Т. 13, № 1. С. 222–236. <https://doi.org/10.12731/2658-6649-2021-13-1-222-236>.

14. Попова М. А., Чеберяк М. И. Методологические аспекты исследования нейрофизиологических характеристик когнитивных нагрузок студентов в процессе обучения (обзор литературы) // *Современные вопросы биомедицины*. 2024. Т. 8, № 4 (30). С. 1–10. https://doi.org/10.24412/2588-0500-2024_08_04_10.

15. Шляхов И. С., Горбунов И. А., Тихонова К. А. Спектральная динамика электроэнцефалографических ритмов при вербальном обучении: анализ этапов теста Рея // *Психология и Психотехника*. 2025. № 2. С. 15–28. <https://doi.org/10.7256/2454-0722.2025.2.74313>.

16. Дик О. Е., Ноздрачев А. Д. Динамика паттернов электрической активности мозга при нарушениях его функционального состояния // *Успехи физиологических наук*. 2020. Т. 51, № 2. С. 68–87. <https://doi.org/10.31857/S0301179820020046>.

17. Пушкин А. А., Сухов А. Г. Особенности влияния фазозависимой экзогенной афферентации на мощность фоновых ритмов ЭЭГ человека // *Физиология человека*. 2020. Т. 46, № 1. С. 46–53. <https://doi.org/10.31857/S0131164619060109>.

18. Исследование нейрофизиологических показателей и смещения внимания как процесса, влияющего на формирование психоэмоционального поведения / А. П. Астащенко, О. В. Комиссарова, Е. В. Дорохов, С. А. Комиссаров, С. И. Никоненко, С. И. Варварова // *Журнал эволюционной биохимии и физиологии*. 2020. Т. 56, № 7. С. 534. <https://doi.org/10.31857/S0044452920070128>.

19. 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>.

20. Кравчук Д. А., Переселков С. А., Грачев В. И. Идентификация эмоционального состояния по амплитудно-частотным характеристикам речевого сигнала // Радиотехника. Наносистемы. Информационные технологии. 2026. Т. 18, № 1. С. 61–70. <https://doi.org/10.17725/rensit.2026.18.061>. EDN CECQOF.

References

1. Govorukhina A.A., Levchuk A.A. Factors influencing the mental performance of students (literature review). *Sovremennyye voprosy biomeditsiny = Modern Issues of Biomedicine*. 2024;8(1). (In Russ.) Available at: <https://svbskfmba.ru/arkhiv-nomerov/2024-1/govorukhina2024> (accessed 04.03.2026). https://doi.org/10.24412/2588-0500-2024_08_01_6.

2. Portnova G.V., Oknina L.B., Masherov E.L., Slezkin A.A., Podlepich V.V. EEG differences in the perception of one's own and another's face: application of an integrated approach to the analysis of EEG data. *Zhurnal vysshei nervnoi deyatel'nosti im. I. P. Pavlova = Journal of Higher Nervous Activity named after I.P. Pavlova*. 2022;72(4):576-586. (In Russ.) <https://doi.org/10.31857/S0044467722030091>.

3. Kapilevich L.V., Ezhova G.S., Zakharova A.N., Kabachkova A.V., Krivoshekov S.G. Bioelectrical activity of the brain and cerebral hemodynamics in athletes with a combination of cognitive and physical activity. *Fiziologiya cheloveka = Human Physiology*. 2019;45(2):58-69. (In Russ.) <https://doi.org/10.1134/S0131164619010089>.

4. Gulyaev S.A. Electroencephalography and studies of functional activity of the brain. *Russkii zhurnal detskoi nevrologii = Russian Journal of Child Neurology*. 2021;16(4):59-68. (In Russ.) <https://doi.org/10.17650/2073-8803-2021-16-4-59-68>.

5. Astashchenko A.P., Gorbatenko N.P., Dorokhov E.V., Varvarova S.I., Zyblov P.V. The influence of anxiety associated with exam stress on the shift of visual attention and electrical activity of the frontal zones of the brain. *Ulyanovskii mediko-biologicheskii zhurnal = Ulyanovsk Medical and Biological Journal*. 2020;(2):100-111. (In Russ.) <https://doi.org/10.34014/2227-1848-2020-2-100-111>.

6. Zvyagina N.V., Taleeva A.I., Novoselova K.V., Cherkasova A.S., Chang T.Ch., Popov N.V. Bioelectrical activity of the brain of students during cognitive activity under time constraints. *Siberian Journal of Life Sciences and Agriculture*. 2025;17(6-1):51-75. (In Russ.) <https://doi.org/10.12731/2658-6649-2025-17-6-1-1317>.

7. Leontyeva A.D., Zubarev A.S. Anxiety and neurophysiological markers: analysis using mobile EEG. *Natsional'nyi psikhologicheskii zhurnal = National Psychological Journal*. 2025;20(1):75-85. (In Russ.) <https://doi.org/10.11621/npj.2025.0107>.

8. Kizhevatoeva E.A., Karakhanyan K.S., Boldyreva M.A. Features of the electroencephalogram in students with different levels of personal and situational anxiety under examina-

tion stress. *Universum: meditsina i farmakologiya = Universum: Medicine and Pharmacology*. 2026;(4):29-38. (In Russ.)

9. Maksimova M.V., Etuev Kh. Kh. Experience of using EEG in education: analysis of foreign studies. *Otechestvennaya i zarubezhnaya pedagogika = Domestic and Foreign Pedagogy*. 2023;1(2):169-185. (In Russ.) <https://doi.org/10.24412/2224-0772-2023-91-169-185>. EDN HKLMWP.

10. Kostromina S.N., Gnedykh D.S. Neuroscience in the system of vocational education. *Professional'noe obrazovanie i rynek truda = Vocational Education and Labor Market*. 2021;(4):8-29. (In Russ.)

11. Rustamova T.V. The influence of examination stress on the amplitude of EEG waves in the parietal lobe of the brain in students of the Faculty of Biology and Chemistry with various individual typological characteristics. *Siberian Journal of Life Sciences and Agriculture*. 2020;12(5):97-112. (In Russ.) <https://doi.org/10.12731/2658-6649-2020-12-5-97-112>.

12. Rustamova T.V. Changes in EEG in the frontal lobe of the cerebral cortex under the influence of the examination process in 18-year-old students of the phlegmatic type. *Mezhdunarodnyi nauchno-issledovatel'skii zhurnal = International Research Journal*. 2022;(7)87-90. (In Russ.) <https://doi.org/10.23670/IRJ.2022.121.7.054>.

13. Rustamova T.V. Comparative analysis of the impact of examination stress on the level of situational and personal anxiety of students. *Siberian Journal of Life Sciences and Agriculture*. 2021;13(1):222-236. (In Russ.) <https://doi.org/10.12731/2658-6649-2021-13-1-222-236>.

14. Popova M.A., Cheberyak M.I. Methodological aspects of the study of neurophysiological characteristics of students' cognitive loads during the learning process (literature review). *Sovremennye voprosy biomeditsiny = Modern Issues of Biomedicine*. 2024;8(4):1-10. (In Russ.) https://doi.org/10.24412/2588-0500-2024_08_04_10.

15. Shlyakhov I.S., Gorbunov I.A., Tikhonova K.A. Spectral dynamics of electroencephalographic rhythms during verbal learning: analysis of the stages of the Rey test. *Psikhologiya i Psikhotekhnika = Psychology and Psychotechnics*. 2025;(2):15-28. (In Russ.) <https://doi.org/10.7256/2454-0722.2025.2.74313>.

16. Dik O.E., Nozdrachev A.D. Dynamics of patterns of electrical activity of the brain in violations of its functional state. *Uspekhi fiziologicheskikh nauk = Advances in Physiological Sciences*. 2020;51(2):68-87. (In Russ.) <https://doi.org/10.31857/S0301179820020046>.

17. Pushkin A.A., Sukhov A.G. Features of the influence of phase-dependent exogenous afferentation on the power of background rhythms of the human EEG. *Fiziologiya cheloveka = Human Physiology*. 2020;46(1):46-53. (In Russ.) <https://doi.org/10.31857/S0131164619060109>.

18. Astashchenko A.P., Komissarova O.V., Dorokhov E.V., Komissarov S.A., Nikonenko S.I., Varvarova S.I. Study of neurophysiological indicators and attention shift as a process influencing the formation of psychoemotional behavior. *Zhurnal evolyutsionnoi biokhimii i*

fiziologii = *Journal of Evolutionary Biochemistry and Physiology*. 2020;56(7):534. (In Russ.) <https://doi.org/10.31857/S0044452920070128>.

19. Kravchuk D.A., Kotenko A.S. Analysis of methods of processing and studying a speech signal to establish a person's psychoemotional state. *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):93-106. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-93-106>.

20. Kravchuk D.A., Pereselkov S.A., Grachev V.I. Identification of emotional state by amplitude-frequency characteristics of speech signal. *Radioelektronika. Nanosistemy. Informatsionnye tekhnologii* = *Radioelectronics. Nanosystems. Information Technologies*. 2026;18(1):61-70. (In Russ.) <https://doi.org/10.17725/rensit.2026.18.061>. EDN CECQOF.

Информация об авторах / Information about the Authors

Кравчук Денис Александрович, доктор технических наук, профессор, Институт нанотехнологий, электроники и приборостроения Южного федерального университета, Ростовская область, г. Таганрог, Российская Федерация, e-mail: kravchukda@sfedu.ru, ORCID: 0000-0002-4220-3928

Denis A. Kravchuk, Dr. Sci. (Engineering), Professor, Institute of Nanotechnology, Electronics and Instrument Engineering at the Southern Federal University, Rostov Region, Taganrog, Russian Federation, e-mail: kravchukda@sfedu.ru, ORCID: 0000-0002-4220-3928

Сахаров Вадим Леонидович, кандидат технических наук, доцент, директор, Научно-медицинская фирма «Нейротех», Ростовская область, г. Таганрог, Российская Федерация, e-mail: vadim@neurotech.ru

Vadim L. Sakharov, Cand. Sci. (Engineering), Associate Professor, Director, Neurotech Scientific and Medical Company of Neurotech, Rostov Region, Taganrog, Russian Federation, e-mail: vadim@neurotech.ru

Кириченко Игорь Алексеевич, кандидат технических наук, доцент, ведущий специалист по верификации и валидации оборудования, Научно-медицинская фирма «Нейротех», Ростовская область, г. Таганрог, Российская Федерация, e-mail: kirichenko@neurotech.ru, ORCID: 0000-0002-0607-3441

Igor A. Kirichenko, Cand. Sci. (Engineering), Associate Professor, Leading Specialist in Equipment Verification and Validation, Neurotech Scientific and Medical Company, Rostov Region, Taganrog, Russian Federation, e-mail: kirichenko@neurotech.ru, ORCID: 0000-0002-0607-3441

<https://doi.org/10.21869/2223-1536-2026-16-2-209-217>

УДК 621.391.26

Прогностическое моделирование неблагоприятных исходов лечения травм коленного сустава у пациентов с сахарным диабетом

С. Н. Родионова¹, Я. Н. Тишин¹ ✉, А. А. Бабкин¹¹ Юго-Западный государственный университет

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

✉ e-mail: tisinaroslav5@gmail.com

Abstract

Цель исследования. Выявление ключевых факторов риска и создание математической модели для прогнозирования результатов лечения травм коленного сустава у пациентов с сахарным диабетом – цели исследования.

Методы. Для решения поставленной задачи использован комплекс методов, позволяющих учитывать множество факторов, влияющих на риск травматизации колена у пациентов с сахарным диабетом. В их числе – дескриптивная статистика для характеристики выборки (среднее значение, стандартное отклонение, медиана, квартили), корреляционный анализ коэффициентов Спирмена и Пирсона для выявления взаимосвязей между переменными, а также логистическая регрессия и методы машинного обучения (Random Forest и SVM) для построения и оценки прогностических моделей. Такой подход обеспечивает глубокое изучение взаимосвязей между клиническими и функциональными показателями, что позволяет создать точные и надёжные прогностические модели. В результате это способствует улучшению оценки риска и разработки индивидуальных профилактических подходов, а также персонализированных методов терапии, что значительно повышает эффективность лечения.

Результаты. Обнаружена корреляция между уровнем HbA1c и частотой инфекционных осложнений ($r = 0,68$, $p < 0,01$). Разработана математическая модель, позволяющая прогнозировать неблагоприятный исход лечения с точностью до 89 % (AUC = 0,89). Прогностическая модель выявила ключевые факторы риска неблагоприятных исходов лечения, включая уровень HbA1c, превышающий 7,5 %, ИМТ более 30 кг/м² и возраст старше 60 лет.

Заключение. В данной работе прогностическая модель работает с точностью 86 %, что является хорошим диагностическим показателем и инструментом оценки риска для решения важной задачи медицинского прогнозирования и профилактики осложнений.

Ключевые слова: сахарный диабет; травмы коленного сустава; факторы риска; прогностическое моделирование; машинное обучение; медицинские информационные системы.

Конфликт интересов: Авторы декларируют отсутствие конфликта интересов, связанных с публикацией данной статьи.

Для цитирования: Родионова С. Н., Тишин Я. Н., Бабкин А. А. Прогностическое моделирование неблагоприятных исходов лечения травм коленного сустава у пациентов с сахарным диабетом // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 209–217. <https://doi.org/10.21869/2223-1536-2026-16-2-209-217>.

Поступила в редакцию 19.04.2026

Подписана в печать 17.05.2026

Опубликована 30.06.2026

© Родионова С. Н., Тишин Я. Н., Бабкин А. А., 2026

Prognostic modeling of adverse outcomes of knee joint injury treatment in patients with diabetes mellitus

Sofia N. Rodionova¹, Yaroslav N. Tishin¹✉, Andrey A. Babkin¹

¹ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: tisin Yaroslav5@gmail.com

Резюме

Purpose of research. The objectives of the study are to identify key risk factors and create a mathematical model for predicting treatment outcomes for knee injuries in patients with diabetes mellitus.

Methods. To solve this problem, a set of methods was used to take into account many factors affecting the risk of knee injury in patients with diabetes mellitus. These include descriptive statistics for sample characteristics (such as mean, standard deviation, median, quartiles), correlation analysis of Spearman and Pearson coefficients to identify relationships between variables, as well as logistic regression and machine learning methods (Random Forest and SVM) for building and evaluating predictive models. This approach provides an in-depth study of the relationships between clinical and functional indicators, which makes it possible to create accurate and reliable predictive models. As a result, this contributes to improved risk assessment and the development of individual preventive approaches, as well as personalized therapies, which significantly increases the effectiveness of treatment.

Results. A correlation was found between the level of HbA1c and the frequency of infectious complications ($r = 0,68$, $p < 0,01$). A mathematical model was developed that allows predicting an unfavorable treatment outcome with an accuracy of 89 % (AUC = 0,89). The prognostic model identified key risk factors for adverse treatment outcomes, including HbA1c levels exceeding 7,5 %, BMI over 30 kg/m² and age over 60 years.

Conclusion. In this work the predictive model works with an accuracy of 86 %, which is a good diagnostic indicator and a risk assessment tool for solving the important task of medical forecasting and prevention of complications.

Keywords: diabetes mellitus; knee injuries; risk factors; predictive modeling; machine learning; medical information systems.

Conflict of interest: The authors declares no conflict of interest related to the publication of this article.

For citation: Tishin Y.N., Babkin A.A., Rodionova S.N. Prognostic modeling of adverse outcomes of knee joint injury treatment in patients with diabetes mellitus. *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(2):209–217. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-209-217>.

Received 19.04.2026

Accepted 17.05.2026

Published 30.06.2026

Введение

Травмы коленного сустава представляют собой серьезную проблему в ортопедической практике, особенно у пациентов с хроническими заболеваниями,

такими как сахарный диабет [1]. Сахарный диабет характеризуется стойкой гипергликемией, приводящей к различным осложнениям, включая микро- и макроангиопатию, невропатию и повышенный риск инфицирования [2].

Эти осложнения могут затруднить лечение травм колена, замедляя процесс заживления и повышая вероятность неблагоприятных исходов [3].

Прогностическое моделирование предоставляет мощные инструменты для анализа сложных медицинских задач, позволяя оценивать вероятность нежелательных исходов на основе имеющихся данных [4]. В данном исследовании используются эти методы с целью повышения понимания факторов риска и разработки рекомендаций по лечению травм колена у пациентов с сахарным диабетом [5].

В связи с тем, что у людей больных сахарным диабетом высока степень к травмам коленного сустава, данная проблема является актуальной. Согласно последним исследованиям, у большинства больных сахарным диабетом наблюдается повышенная вероятность развития остеоартрита и травм колена, что приводит к снижению качества жизни и увеличению числа госпитализаций. Так, по данным российских и зарубежных источников, у пациентов с сахарным диабетом риск травм колена возрастает в 1,5-2 раза по сравнению с людьми без этого заболевания. В связи с этим разработка прогностических моделей для оценки риска травматизации становится важной задачей для своевременного профилактического вмешательства [3].

Травмы коленного сустава относятся к числу наиболее распространенных травм опорно-двигательного аппарата. Сочетание травмы и диабета осложняет клиническую картину, повышает риск

инфекционных осложнений, задерживает консолидацию костей и заживление мягких тканей и негативно влияет на отдаленные функциональные результаты [6].

Несмотря на успехи в хирургическом лечении травм колена, разработка персонализированных подходов, учитывающих системные последствия диабета, остается важной задачей. Традиционные клинические методы не всегда позволяют эффективно прогнозировать результаты лечения. Использование передовых методов обработки данных открывает новые возможности для объективной оценки риска и поддержки принятия клинических решений [7].

В данном исследовании целью является выявление ключевых факторов риска и создание математической модели для прогнозирования результатов лечения травм коленного сустава у пациентов с сахарным диабетом.

Материалы и методы

Исследование проводилось в травматологическом отделении с 2024 по 2025 гг. Основную группу составили 150 пациентов с подтвержденными повреждениями коленного сустава (такими, как разрывы менисков, повреждения передней крестообразной связки и внутрисуставные переломы) на фоне сахарного диабета 1-го или 2-го типа. В контрольную группу вошли 100 пациентов без нарушений углеводного обмена, но с аналогичными видами травм и лечения. Средний возраст пациентов основной группы составил $54,2 \pm 5,1$ года.

По каждому пациенту были собраны и проанализированы следующие данные:

1. Клинические и демографические факторы: возраст, пол, индекс массы тела (ИМТ), курение и наличие сопутствующих сердечно-сосудистых заболеваний.

2. Показатели углеводного обмена: уровень гликированного гемоглобина (HbA1c) при поступлении, средний уровень гликемии во время госпитализации и длительность сахарного диабета в анамнезе [8].

3. Характеристики травмы и лечения: механизм травмы, тип травмы (классифицируемый соответствующим образом), тип хирургического вмешательства и продолжительность иммобилизации [9].

4. Показатели результата лечения: сроки заживления ран, наличие инфекционных осложнений (поверхностных или глубоких) и сроки восстановления функции сустава (оцениваются по шкалам Лисхольма и КООСА через 3, 6 и 12 месяцев после лечения) [3].

Для статистической обработки данных и построения прогностической модели использовались:

1. Дескриптивная статистика: для характеристики выборки (среднее значение, стандартное отклонение, медиана и квартили). Эта часть анализа позволяет получить общее представление о распределении ключевых параметров и определить характер.

2. Корреляционный анализ: с помощью коэффициентов Спирмена и Пир-

сона для выявления взаимосвязи между факторами риска и исходами [10].

3. Логистическая регрессия: для построения модели бинарного прогнозирования, позволяющей определить влияние отдельных факторов на вероятность неблагоприятных исходов.

4. Методы машинного обучения (Random Forest и метод опорных векторов, SVM) для сравнения точности и повышения надежности прогноза [11].

Обработка данных выполнена с помощью языка программирования Python, используя библиотеки Pandas (для обработки данных), Scikit-learn (для моделирования и оценки алгоритмов) и SciPy (для статистического анализа).

Пример фрагмента окна проведения расчетов:

```
import pandas as pd
from sklearn.model_selection import
train_test_split
from sklearn.ensemble import RandomForestClassifier
from sklearn.svm import SVC
from sklearn.metrics import
roc_auc_score, accuracy_score
```

```
# Загрузка подготовленных данных
data = pd.read_csv('dataset.csv')
```

```
# Определение признаков и целевой переменной
X = data[['HbA1c', 'ИМТ', 'Возраст']]
y = data['неблагоприятный_исход']
```

```
# Разделение на обучающую и тестовую выборки
```

```

X_train, X_test, y_train, y_test =
train_test_split(X, y, test_size=0.2, ran-
dom_state=42)

# Обучение модели Random Forest
rf_model = RandomForestClassifier()
rf_model.fit(X_train, y_train)
preds_rf = rf_model.predict(X_test)
roc_rf = roc_auc_score(y_test,
preds_rf)

# Обучение модели SVM
svm_model = SVC(probability=True)
svm_model.fit(X_train, y_train)
preds_svm =
svm_model.predict(X_test)
roc_svm = roc_auc_score(y_test,
preds_svm)

print(f'AUC Random Forest:
{roc_rf}')
print(f'AUC SVM: {roc_svm}')

```

Использование Python обусловлено его широкими возможностями для быстрой и эффективной обработки данных, автоматизации аналитических

процедур и построения модели машинного обучения. Это обеспечивает повторяемость и масштабируемость анализа, облегчая внедрения разработанных моделей в практику [12].

Результаты и их обсуждение

Корреляционный анализ выявил значительную связь между концентрацией HbA1c при госпитализации и частотой возникновения инфекционных осложнений в области операционных ран (коэффициент $r = 0,68$, $p < 0,01$). Это свидетельствует о том, что повышенные значения гликированного гемоглобина непосредственно перед операцией существенно повышают риск послеоперационной инфекции. Также было выяснено, что продолжительность истории заболевания сахарным диабетом связана с увеличением периода восстановления функций сустава (коэффициент $r = 0,55$, $p < 0,05$).

Риск осложнений значительно возрастает с ухудшением степени компенсации (табл. 1).

Таблица 1. Зависимость частоты осложнений от степени компенсации СД

Table 1. Dependence of the complication rate on the degree of DM compensation

Степень компенсации СД (HbA1c)	Количество пациентов		Инфекционные осложнения	
	n	%	n	%
Хорошая (<6,5 %)	45	30	2	4,4
Удовлетворительная (6,5–8,0 %)	75	50	15	20
Неудовлетворительная (>8,0 %)	30	20	12	40

Это выделяет необходимость мониторинга уровня сахара в крови у больных сахарным диабетом, прошедших хирургическое вмешательство на ко-

ленном суставе, так как высокий уровень гликированного гемоглобина способен ухудшить процесс восстановления и повысить риск последствий [12].

Результаты исследования подтверждают гипотезу о том, что хроническая гипергликемия оказывает системное негативное влияние на процессы регенерации. Хронически высокий уровень сахара в крови может привести к нарушению микроциркуляции, снижению иммунного ответа и нарушению образования коллагена, которые имеют решающее значение для заживления связок и костной ткани [13].

Модель логистической регрессии, разработанная для прогнозирования неблагоприятных исходов, продемонстрировала высокую прогностическую ценность: площадь под кривой (AUC)

составила 0,89. Это считается убедительным показателем эффективности модели в биомедицинских исследованиях. В ходе анализа были выявлены ключевые предикторы неблагоприятных исходов: уровень HbA1c более 7,5%, индекс массы тела (ИМТ) более 30 кг/м² и возраст старше 60 лет [2]. Выбор логистической регрессии обусловлен ее высокой интерпретируемостью, способностью точно прогнозировать бинарные исходы, подтвержденной высокой AUC, а также устойчивостью и простотой внедрения в клиническую практику.

Модель выражается уравнением вероятности неблагоприятного исхода:

$$P(\text{неблагоприятный исход}) = \frac{1}{1 + e^{-(0,45 \cdot \text{HbA1c} + 0,12 \cdot \text{ИМТ} + 0,08 \cdot \text{Возраст} - 8,5)}}.$$

Эти результаты подчеркивают важность мониторинга и управления этими факторами для улучшения результатов хирургического вмешательства и восстановления пациентов с сахарным диабетом, проходящих лечение от травм коленного сустава [14]. Учитывая эти факторы, медицинские работники могут потенциально снизить риск осложнений и ускорить процесс заживления.

Для оценки надежности модели была проведена проверка на отдельной выборке из 30 новых пациентов, не входивших в обучающую выборку.

Полученные результаты продемонстрировали:

- точности предсказаний – 85 %;
- ROS-AUC – 87 %;
- чувствительность – 83 %;
- специфичность – 87 %.

Это подтверждает высокую обобщающую способность модели и ее практическую применимость.

Выводы

Проведенное исследование подтвердило, что сахарный диабет является значимым фактором риска осложнений при лечении травм коленного сустава. Ключевыми факторами неблагоприятных исходов являются уровень HbA1c, ИМТ и возраст пациента. Разработанная модель логистической регрессии демонстрирует точность (AUC = 0,89) и может быть эффективно использована для индивидуализации планов лечения и прогнозирования результатов. Использование методов машинного обучения и анализа данных в сочетании с программным обеспечением Python позволяет создавать надежные инструменты поддержки клинических решений. Внедрение такой модели в практику способно значительно снизить риск осложнений, улучшить качество восстановления и повысить эффективность лечения пациентов с сахарным диабетом и травмами колена.

Список литературы

1. Determining the Threshold for HbA1c as a Predictor for Adverse Outcomes After Total Joint Arthroplasty: A Multicenter, Retrospective Study / M. Tarabichi, N. Shohat, M. M. Kheir [et al.] // *The Journal of Arthroplasty*. 2017. Vol. 32, N 9. P. S263–S267.e1. <https://doi.org/10.1016/j.arth.2017.04.065>
2. Бондарь И. А., Шабельникова О. Ю. Особенности клинического течения и частоты осложнений у пациентов с сахарным диабетом 2 типа различных кластеров в Новосибирской области // *Проблемы эндокринологии*. 2023. Т. 69, № 5. С. 84–92. <https://doi.org/10.14341/probl13259>
3. Diabetes and total knee arthroplasty: A nationwide analysis of short-term complications, healthcare utilization and costs / Yaara Berkovich, Ela Cohen Nissan, David Maman, Michael Tobias Hirschmann, Yaniv Yonai, Yaniv Steinfeld, Yaron Berkovich // *Knee Surgery, Sports Traumatology, Arthroscopy*. 2025. Vol. 33, N 9. P. 3250–3260. <https://doi.org/10.1002/ksa.12696>
4. Machine learning prediction models in orthopedic surgery: A systematic review in transparent reporting / O. Q. Groot, P. T. Ogink, A. Lans [et al.] // *Journal of Orthopaedic Research*. 2022. Vol. 40, N 2. P. 475–483. <https://doi.org/10.1002/jor.25036>
5. A development of machine learning models to preoperatively predict insufficient clinical improvement after total knee arthroplasty / G. Gimm, D.-W. Shin, J. Lee [et al.] // *J. Orthop. Surg. Res*. 2025. N 20. P. 778. <https://doi.org/10.1186/s13018-025-06206-z>
6. Индексы системного воспаления для прогнозирования ранних инфекций после артропластики крупных суставов / Л. В. Любимова, Е. А. Микишанина, Н. С. Николаев, Е. А. Любимов, Е. В. Преображенская // *Травматология и ортопедия России*. 2025. Т. 31, № 4. С. 41–52. <https://doi.org/10.17816/2311-2905-17754>
7. Evaluation of Machine Learning Methods Developed for Prediction of Diabetes Complications: A Systematic Review / Kuo Ren Tan, Jun Jie Benjamin Seng, Yu Heng Kwan, Ying Jie Chen, Sueziani Binte Zainudin, Dionne Hui Fang Loh, Nan Liu, Lian Leng Low // *Journal of Diabetes Science and Technology*. 2021. Vol. 17, N 2. P. 474–489. <https://doi.org/10.1177/19322968211056917>
8. Outcomes of total knee arthroplasty in people with diabetes: An overview of systematic reviews and meta-analysis / R. Vaishya, M. K. Patralekh, A. Misra, A. Vaish // *Journal of Orthopaedics*. 2025. Vol. 65. P. 336–345. <https://doi.org/10.1016/j.jor.2025.06.023>
9. Influence of Diabetes Mellitus on Postoperative Complications After Total Knee Arthroplasty: A Systematic Review and Meta-Analysis / Seok Ho Hong, Seung Cheol Kwon, Jong Hwa Lee, Shinje Moon, Joong Il Kim // *Medicina*. 2024. Vol. 60, N 11. P. 1757. <https://doi.org/10.3390/medicina60111757>
10. What Are the Game Changers in Total Knee Arthroplasty? A Narrative Review of Evidence-Based Interventions That Transform Patient Outcomes / Andrea Baldini, Damiano Ardiri, Lorenzo Benvenuti, Mattia Chirico, Enrico Fiorilli, Alessandro Singlitico, Filippo Leggieri // *Journal of Personalized Medicine*. 2025. Vol. 15. N 8. P. 389. <https://doi.org/10.3390/jpm15080389>
11. Machine learning prediction models in orthopedic surgery: A systematic review in transparent reporting / O. Q. Groot, P. T. Ogink, A. Lans [et al.] // *Journal of Orthopaedic Research*. 2022. Vol. 40, N 2. P. 475–483. <https://doi.org/10.1002/jor.25036>

12. A development of machine learning models to preoperatively predict insufficient clinical improvement after total knee arthroplasty / Geunwu Gimm, Byoungjun Jeon, Sung Eun Kim, Byeong Soo Kim, Hyuk-Soo Han, Sungwan Kim // *J. Orthop. Surg. Res.* 2025. Vol. 20. P. 778. <https://doi.org/10.1186/s13018-025-06206-z>.

13. Бондарь И. А., Шабельникова О. Ю. Риски смертельных исходов при различных клинических фенотипах у больных сахарным диабетом 2 типа в Новосибирской области // *Сахарный диабет.* 2024. Т. 27, № 6. С. 580–588. <https://doi.org/10.14341/DM13195>.

14. Медицинская реабилитация после травм нижних конечностей у пациентов с сахарным диабетом: обзор литературы / В. А. Васильева, Л. А. Марченкова, Д. И. Отвечикова, Е. А. Рожкова, А. Д. Фесюн // *Вестник восстановительной медицины.* 2024. Т. 23, № 3. С. 61–68.

References

1. Tarabichi M., Shohat N., Kheir M.M., et al. Determining the Threshold for HbA1c as a Predictor for Adverse Outcomes After Total Joint Arthroplasty: A Multicenter, Retrospective Study. *The Journal of Arthroplasty.* 2017;32(9):S263-S267.e1. <https://doi.org/10.1016/j.arth.2017.04.065>.

2. Bondar I.A., Shabelnikova O. Yu. Features of the clinical course and frequency of complications in patients with type 2 diabetes mellitus of various clusters in the Novosibirsk region. *Problemy endokrinologii = Problems of Endocrinology.* 2023;69(5):84-92. (In Russ.) <https://doi.org/10.14341/probl13259>.

3. Yaara Berkovich, Ela Cohen Nissan, David Maman, Michael Tobias Hirschmann, Yaniv Yonai, Yaniv Steinfeld, Yaron Berkovich. Diabetes and total knee arthroplasty: A nationwide analysis of short-term complications, healthcare utilization and costs. *Knee Surgery, Sports Traumatology, Arthroscopy.* 2025;33(9):3250-3260. <https://doi.org/10.1002/ksa.12696>.

4. Groot O.Q., Ogink P.T., Lans A., et al. Machine learning prediction models in orthopedic surgery: A systematic review in transparent reporting. *Journal of Orthopaedic Research.* 2022;40(2): 475-483. <https://doi.org/10.1002/jor.25036>.

5. Gimm G., Shin D.-W., Lee J., et al. A development of machine learning models to preoperatively predict insufficient clinical improvement after total knee arthroplasty. *J. Orthop. Surg. Res.* 2025;(20):778. <https://doi.org/10.1186/s13018-025-06206-z>.

6. Lyubimova L.V., Mikishanina E.A., Nikolaev N.S., Lyubimov E.A., Preobrazhenskaya E.V. Indices of systemic inflammation for predicting early infections after arthroplasty of large joints. *Travmatologiya i ortopediya Rossii = Traumatology and Orthopedics of Russia.* 2025;31(4):41-52. (In Russ.) <https://doi.org/10.17816/2311-2905-17754>.

7. Kuo Ren Tan, Jun Jie Benjamin Seng, Yu Heng Kwan, Ying Jie Chen, Sueziani Binte Zainudin, Dionne Hui Fang Loh, Nan Liu, Lian Leng Low. Evaluation of Machine Learning Methods Developed for Prediction of Diabetes Complications: A Systematic Review. *Journal of Diabetes Science and Technology.* 2021;17(2):474-489. <https://doi.org/10.1177/19322968211056917>.

8. Vaishya R., Patralekh M.K., Misra A., Vaish A. Outcomes of total knee arthroplasty in people with diabetes: An overview of systematic reviews and meta-analysis. *Journal of Orthopaedics.* 2025;65:336-345. <https://doi.org/10.1016/j.jor.2025.06.023>.

9. Seok Ho Hong, Seung Cheol Kwon, Jong Hwa Lee, Shinje Moon, Joong Il Kim. Influence of Diabetes Mellitus on Postoperative Complications After Total Knee Arthroplasty: A Systematic Review and Meta-Analysis. *Medicina*. 2024;60(11):1757. <https://doi.org/10.3390/medicina60111757>.
10. Andrea Baldini, Damiano Ardiri, Lorenzo Benvenuti, Mattia Chirico, Enrico Fiorilli, Alessandro Singlitico, Filippo Leggieri. What Are the Game Changers in Total Knee Arthroplasty? A Narrative Review of Evidence-Based Interventions That Transform Patient Outcomes. *Journal of Personalized Medicine*. 2025;15(8):389. <https://doi.org/10.3390/jpm15080389>.
11. Groot O.Q., Ogink P.T., Lans A., et al. Machine learning prediction models in orthopedic surgery: A systematic review in transparent reporting. *Journal of Orthopaedic Research*. 2022;40(2):475-483. <https://doi.org/10.1002/jor.25036>.
12. Geunwu Gimm, Byoungjun Jeon, Sung Eun Kim, Byeong Soo Kim, Hyuk-Soo Han, Sungwan Kim. A development of machine learning models to preoperatively predict insufficient clinical improvement after total knee arthroplasty. *J. Orthop. Surg. Res.* 2025;20:778. <https://doi.org/10.1186/s13018-025-06206-z>.
13. Bondar I.A., Shabelnikova O. Yu. Risks of deaths in case of individual clinical phenotypes in patients with type 2 diabetes mellitus in the Novosi-Birsk region. *Sakharnyi diabet = Diabetes Mellitus*. 2024;27(6):580-588. (In Russ.) <https://doi.org/10.14341/DM13195>.
14. Vasiliev V.A., Marchenkova L.A., Osvetchikova D.I., Rozhkova E.A., Fesyun A.D. Medical rehabilitation after injuries of the lower extremities in patients with diabetes mellitus: a review of the literature. *Vestnik vosstanovitel'noi meditsiny = Bulletin of Restorative Medicine*. 2024;23(3):61-68. (In Russ.)

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, Scopus ID: 57195455825, WOS ID: Q-1060-2017

Sofia N. Rodionova, Cand. Sci. (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, Scopus ID: 57195455825, WOS ID: Q-1060-2017

Тишин Ярослав Николаевич, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: tisinaroslav5@gmail.com, ORCID: 0009-0008-7864-4566

Yaroslav N. Tishin, Postgraduate at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: tisinaroslav5@gmail.com, ORCID: 0009-0008-7864-4566

Бабкин Андрей Андреевич, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: babosboxing@gmail.com, ORCID: 0009-0008-5569-7390

Andrey A. Babkin, Postgraduate at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: babosboxing@gmail.com, ORCID: 0009-0008-5569-7390

<https://doi.org/10.21869/2223-1536-2026-16-2-218-234>

УДК 681.51

Система регулирования лучезапястного сустава с динамикой мышц представленной моделью Хилла

О. Ю. Щербак¹ ✉, А. Л. Масленников¹

¹ Московский государственный технический университет им. Н. Э. Баумана
ул. 2-я Бауманская, д. 5, г. Москва 105005, Российская Федерация

✉ e-mail: scherbak.olga.j@bmstu.ru

Резюме

Цель исследования – построение и исследование системы регулирования биотехнической системы на примере лучезапястного сустава с использованием модели Хилла для описания динамики мышц на базе новой математической модели, способной адекватно описывать динамику мышц и сустава при движении в трёх плоскостях, включая последовательное достижение нескольких заданных угловых положений, перекрёстные связи и физиологические ограничения суставного аппарата.

Методы. Для исследования рассматриваемой биотехнической системы предлагаемая математическая модель, включающая динамику сустава в плоскостях сгибания-разгибания, приведения-отведения и пронации-супинации, которая состоит из блока динамики сустава, блоков динамики мышц и блока перекрёстных связей, учитывающих взаимосвязь движений в разных плоскостях. Динамика мышц представлена тремя парами мышц «агонист-антагонист», реализованными на основе трёхкомпонентной модели Хилла. Управляющие воздействия формируются с использованием ПИ-регуляторов по углам и угловым скоростям в каждом канале регулирования (в каждой плоскости движения).

Результаты. Проведены вычислительные эксперименты, в которых сустав последовательно перемещался в три заданных угловых положения. Полученные переходные процессы по углам и угловым скоростям демонстрируют устойчивость системы и точное достижение всех целевых положений. Анализ длин мышц и сил натяжения сухожилий показал согласованную работу пар мышц: формирование управляющего момента осуществляется за счёт изменения соотношения сил мышц агониста и антагониста.

Заключение. Полученные результаты подтверждают адекватность разработанной математической модели для описания динамики биотехнической системы на примере лучезапястного сустава и мышечно-сухожильного комплекса и демонстрируют принципиальную возможность использования предложенного подхода для моделирования биотехнических систем.

Ключевые слова: лучезапястный сустав; биотехническая система; система регулирования; модель мышц; ПИ-регулятор.

Конфликт интересов: Авторы декларируют отсутствие конфликта интересов, связанных с публикацией данной статьи.

Для цитирования: Щербак О. Ю., Масленников А. Л. Система регулирования лучезапястного сустава с динамикой мышц представленной моделью Хилла // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 218–234. <https://doi.org/10.21869/2223-1536-2026-16-2-218-234>.

Поступила в редакцию 10.04.2026

Подписана в печать 08.05.2026

Опубликована 30.06.2026

Wrist joint control system with muscle dynamics represented by Hill's model

Olga Yu. Scherbak¹✉, Andrey L. Maslennikov¹

¹ Bauman Moscow State Technical University
2nd Baumanskaya Str. 5, Moscow 105005, Russian Federation

✉ e-mail: scherbak.olga.j@bmstu.ru

Abstract

The purpose of the research is to construct and research a biotechnical control system using the Hill model for describing muscle dynamics, using the wrist joint as an example. The model is based on a new mathematical model capable of adequately describing muscle and joint dynamics during motion in three planes, including the sequential achievement of several predetermined angular positions, cross-couplings, and the physiological limitations of the wrist joint.

Methods. To study the considered biotechnical system, a mathematical model is proposed that includes the dynamics of the joint in the planes of flexion, extension, abduction, and supination, which consists of a block of joint dynamics, blocks of muscle dynamics, and a block of criss-cross connections that take into account the relationship of movements in different planes. The dynamics of muscles is represented by three pairs of "agonist antagonist" muscles implemented on the basis of the three-component Hill model. Control actions are formed using PI regulators for angles and angular velocities in each control channel (in each plane of motion).

Results. Computational experiments were performed where the wrist joint was sequentially moved to three predetermined angular positions. The resulting transient responses for angles and angular velocities demonstrated the system's stability and the precise achievement of all target positions. Analysis of muscle lengths and tendon tension forces revealed the coordinated action of muscle pairs: the control torque is generated by changing the ratio of agonist and antagonist muscle forces.

Conclusion. The obtained results confirm the adequacy of the developed mathematical model for describing the dynamics of a biotechnical system using the wrist joint and muscle-tendon complex as an example and demonstrate the fundamental feasibility of using the proposed approach for modeling biotechnical systems.

Keywords: wrist joint; biotechnical system; control systems; muscle model; PI controller.

Conflict of interest: The authors declares no conflict of interest related to the publication of this article.

For citation: Scherbak O.Yu., Maslennikov A.L. Wrist joint control system with muscle dynamics represented by Hill's model. *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(2):218–234. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-218-234>.

Received 10.04.2026

Accepted 08.05.2026

Published 30.06.2026

Введение

Лучезапястный сустав, реализующий движения в нескольких плоскостях, представляет особый интерес как объект моделирования и инженерного

воспроизведения для разработки экзопротезов [1]. Его функциональная сложность, обусловленная сочетанием нескольких степеней свободы и взаимодействием костных, связочных и

мышечных структур, требует формализованного описания при создании технических систем различного назначения. Для проектирования биотехнических систем на примере лучезапястного сустава необходимо формирование адекватной математической модели и системы управления [2].

Существует несколько подходов к построению математических моделей лучезапястного сустава. В многотельных моделях сустав рассматривается как система твёрдых тел с шарнирами, контактами и связочными ограничениями [3]. Для анализа распределения напряжений и контактных давлений [4] используют трёхмерные модели костей, хрящей и связок, построенные с использованием метода конечных элементов [5]. Например, в [1] представлена высокоанатомичная модель лучезапястного сустава, учитывающая кости и мягкие ткани. Однако трёхмерные модели сложны, ресурсоёмки и неудобны для синтеза управления или анализа динамики системы. Вместо них применяют более простые в реализации кинематические модели, описывающие движение костей через геометрические связи и ограничения. Так, в работе [6] рассматривают кости запястья как сеть взаимодействующих сегментов и исследуют относительные движения костей запястья во время активных движений. Помимо этого, в качестве моделей лучезапястного сустава целесообразно рассмотреть различные модели экзопротезов руки: модель с пневматическими приводами [7] или модель на основе параллельных кинематических архитектур [8].

Мышцы являются исполнительным органом рассматриваемой биотехниче-

ской системы, формирующим усилия и движения в суставе, поэтому для их описания также необходимы адекватные математические модели. Для моделирования мышц используются различные подходы, отличающиеся степенью физиологической достоверности и сложностью реализации [9]. Высокой физиологической точностью обладают модели Хаксли [10], которые учитывают биофизику сокращения, однако они сложны для моделирования. Модели на основе метода конечных элементов [11] рассматривают мышцы как трёхмерное деформируемое тело с активной и пассивной механикой, учитывают неоднородность тканей и распределение сил и применяются преимущественно при моделировании травм или хирургических вмешательств [12]. Для описания мышечно-скелетных моделей конечностей, оценки суставных моментов и систем с большим числом мышц используют модели мышц Хилла [13], которые не учитывают биохимические процессы, однако стали стандартом в биомеханике благодаря достаточно адекватному описанию динамики мышечного сокращения [14]. Наиболее распространена трёхкомпонентная модель Хилла [15], которую для повышения точности можно модифицировать [16], введя учёт мышечного утомления, типов волокон, динамики активации мышц [17].

Комплексные модели лучезапястного сустава, включающие как динамику сустава, так и динамику мышц, представляют сегодня особый интерес в исследованиях. Например, в [18] предложена модель лучезапястного сустава с учётом динамики пяти основных мышц предплечья, что позволяет оценивать влияние отдельных мышц на формиро-

вание управляющих моментов и характер движения в суставе. В [19] представлена модель опорно-двигательного аппарата, объединяющая мышечную модель Хилла с кинематической моделью запястья, которая позволяет проводить анализ движений по принципам зеркального билатерального управления. Модель запястных костей, представленная в [20], интегрирована с мышечной моделью на основе модели Хилла, что обеспечивает анализ координации мышц и формирования управляющих моментов в суставе.

В [21] авторами была предложена система регулирования биотехнической системы на примере лучезапястного сустава с движением в плоскостях приведения-отведения и растяжения-сжатия, при этом динамика мышц аппроксимировалась дифференциальным уравнением первого порядка. Хотя такая модель позволяла воспроизводить базовые переходные процессы, она была ограничена по числу плоскостей движения и

упрощённо описывала мышечную динамику. В данной работе модель существенно расширена: добавлена динамика движения в плоскости пронации-супинации, а для описания динамики мышц предлагается модификация модели мышц на основе трёхкомпонентной модели Хилла, что позволяет более точно учитывать активную работу мышц и их взаимодействие с суставом. Предлагаемая модель объединяет кинематику сустава и динамику мышц в единую систему, обеспечивая реалистичное формирование управляющих моментов.

Материалы и методы

Математическая модель системы регулирования биотехнической системы на примере лучезапястного сустава состоит из трёх каналов, блоков динамики мышц, блока динамики сустава и блока перекрёстных связей. Рассмотрим функциональную схему модели (рис. 1).




Рис. 1. Функциональная схема системы регулирования биотехнической системы на примере лучезапястного сустава

Fig. 1. Functional diagram of the control system for the biotechnical systems based on the wrist joint

На рисунке 1 введены следующие обозначения: $\psi, \dot{\psi}, \varphi, \dot{\varphi}, \gamma, \dot{\gamma}$ – угол и угловая скорость в плоскостях приведения-отведения, растяжения-сжатия, пронации-супинации соответственно (далее ψ, φ, γ в индексах обозначают принадлежность к соответствующей плоскости), рад и рад/с; $\mathbf{r}_\psi, \mathbf{r}_\varphi, \mathbf{r}_\gamma$ – входные воздействия, рад и рад/с; $\mathbf{e}_\psi, \mathbf{e}_\varphi, \mathbf{e}_\gamma$ – ошибки и управляющие сигналы; $m_\psi, m_\varphi, m_\gamma$ – управляющие моменты; ПИ – блоки формирования управляющих сигналов.

В общем случае в качестве входных воздействий рассматриваются заданные углы $r_\psi, r_\varphi, r_\gamma$ и угловые скорости $r_{\dot{\psi}}, r_{\dot{\varphi}}, r_{\dot{\gamma}}$ поворота биотехнической системы на примере лучезапястного сустава. Следовательно, векторы входных воздействий $\mathbf{r}_\psi, \mathbf{r}_\varphi, \mathbf{r}_\gamma$ и ошибок $\mathbf{e}_\psi, \mathbf{e}_\varphi, \mathbf{e}_\gamma$ имеют следующий вид:

$$\mathbf{r}_\psi = \begin{bmatrix} r_\psi \\ r_{\dot{\psi}} \end{bmatrix}, \quad \mathbf{r}_\varphi = \begin{bmatrix} r_\varphi \\ r_{\dot{\varphi}} \end{bmatrix}, \quad \mathbf{r}_\gamma = \begin{bmatrix} r_\gamma \\ r_{\dot{\gamma}} \end{bmatrix},$$

$$\mathbf{e}_\psi = \begin{bmatrix} e_\psi \\ e_{\dot{\psi}} \end{bmatrix}, \quad \mathbf{e}_\varphi = \begin{bmatrix} e_\varphi \\ e_{\dot{\varphi}} \end{bmatrix}, \quad \mathbf{e}_\gamma = \begin{bmatrix} e_\gamma \\ e_{\dot{\gamma}} \end{bmatrix}. \quad (1)$$

Динамика сустава при движении в трёх плоскостях описывается следующей системой дифференциальных уравнений:

$$\begin{cases} \ddot{\psi} = \left(-G_\psi \cos \gamma + r_p F_{t_\psi} + \right. \\ \quad \left. + M_{p_\psi} + M_{d_\psi} + q_{\dot{\psi}} \dot{\psi} + q_{\dot{\gamma}} \dot{\gamma} \right) / J_\psi, \\ \ddot{\varphi} = \left(-G_\varphi \sin \gamma + r_p F_{t_\varphi} + \right. \\ \quad \left. + M_{p_\varphi} + M_{d_\varphi} + q_{\dot{\varphi}} \dot{\varphi} + q_{\dot{\psi}} \dot{\psi} \right) / J_\varphi, \\ \ddot{\gamma} = \left(r_p F_{t_\gamma} + M_{p_\gamma} + \right. \\ \quad \left. + M_{d_\gamma} + q_{\dot{\gamma}} \dot{\gamma} + q_{\dot{\varphi}} \dot{\varphi} \right) / J_\gamma, \end{cases} \quad (2)$$

где G_ψ, G_φ – моменты силы тяжести; r_p – радиус сустава; $F_{t_\psi}, F_{t_\varphi}, F_{t_\gamma}$ – результирующие силы натяжения сухожилий; $M_{p_\psi}, M_{p_\varphi}, M_{p_\gamma}$ – пассивные моменты сустава; $M_{d_\psi}, M_{d_\varphi}, M_{d_\gamma}$ – моменты демпфирования сустава; $J_\psi, J_\varphi, J_\gamma$ – моменты инерции; $q_{\dot{\psi}\dot{\varphi}}, q_{\dot{\psi}\dot{\gamma}}, q_{\dot{\varphi}\dot{\psi}}, q_{\dot{\varphi}\dot{\gamma}}, q_{\dot{\gamma}\dot{\psi}}, q_{\dot{\gamma}\dot{\varphi}}$ – коэффициенты перекрёстных связей по угловым скоростям.

Пассивные моменты сустава [22] описываются экспоненциальными зависимостями [23], отражающими сопротивление связочного аппарата при приближении к пределам диапазона движений:

$$\begin{aligned} M_{p_\psi} &= k_{1_\psi} \exp(-k_{2_\psi} (\psi - \psi_{\max})) - \\ &\quad - k_{4_\psi} \exp(-k_{5_\psi} (\psi_{\min} - \psi)), \\ M_{p_\varphi} &= k_{1_\varphi} \exp(-k_{2_\varphi} (\varphi - \varphi_{\max})) - \\ &\quad - k_{4_\varphi} \exp(-k_{5_\varphi} (\varphi_{\min} - \varphi)), \\ M_{p_\gamma} &= k_{1_\gamma} \exp(-k_{2_\gamma} (\gamma - \gamma_{\max})) - \\ &\quad - k_{4_\gamma} \exp(-k_{5_\gamma} (\gamma_{\min} - \gamma)), \end{aligned} \quad (3)$$

где k_1, k_2, k_4, k_5 – параметры кривой сопротивления сустава; $\psi_{\max}, \varphi_{\max}, \gamma_{\max}, \psi_{\min}, \varphi_{\min}, \gamma_{\min}$ – минимальные и максимальные физиологические углы поворота в соответствующей плоскости.

Моменты демпфирования сустава, обусловленные вязкостью синовиальной жидкости и мягких тканей, предполагаются линейно зависящими от угловой скорости [24]:

$$\begin{aligned} M_{d_\psi} &= -B_{d_\psi} \dot{\psi}, \\ M_{d_\varphi} &= -B_{d_\varphi} \dot{\varphi}, \end{aligned}$$

$$M_{d_{\dot{\gamma}}} = -B_{d_{\dot{\gamma}}} \dot{\gamma}, \quad (4)$$

где $B_{d_{\psi}}$, $B_{d_{\phi}}$, $B_{d_{\dot{\gamma}}}$ – коэффициенты демпфирования сустава.

Силы натяжения сухожилий $F_{t_{\psi}}$, $F_{t_{\phi}}$, $F_{t_{\dot{\gamma}}}$ определяются на основе модели мышечного аппарата. В работе предла-

гается модификация модели пары мышц (агонист-антагонист) [25] на основе трёхкомпонентной мышечно-сухожильной модели Хилла (рис. 2), которая учитывает инерционные, упругие и диссипативные свойства мышечно-сухожильного комплекса.




Рис. 2. Модель пары мышц на основе трёхкомпонентной мышечно-сухожильной модели Хилла

Fig. 2. A muscle model based on Hill's three-component musculoskeleton model

На рисунке 2 введены следующие обозначения: индекс $i=1$ соответствует мышце-агонисту, а $i=2$ – антагонисту; α – угол отклонения сустава; l_m – длина мышцы; l_t – длина сухожилия; l_p – длина мышечно-сухожильного комплекса, $l_p = l_t + l_m$; F_t – сила натяжения сухожилия; F_{act} – сила сократительного элемента; F_p – сила параллельного эластичного элемента; F_d – сила параллельного демпфирующего элемента;

M_m – масса мышцы; r_{cm} – расстояние от оси лучезапястного сустава до центра масс кисти руки; m – масса кисти руки.

В такой конфигурации результирующие силы сухожилий в каждой плоскости определяются как разность сил агониста и антагониста:

$$\begin{aligned} F_{t_{\psi}} &= F_{t_{\psi 1}} - F_{t_{\psi 2}}, \\ F_{t_{\phi}} &= F_{t_{\phi 1}} - F_{t_{\phi 2}}, \\ F_{t_{\dot{\gamma}}} &= F_{t_{\dot{\gamma} 1}} - F_{t_{\dot{\gamma} 2}}. \end{aligned} \quad (5)$$

Динамика пары мышц (агониста и антагониста) описывается системой дифференциальных уравнений:

$$\begin{cases} \dot{F}_{t_1} = K_{t_1}(-r_p \dot{\alpha} - \dot{l}_{m_1}), \\ \ddot{l}_{m_1} = \frac{F_{t_1} - F_{act_1} - F_{p_1} - F_{d_1}}{M_{m_1}}, \\ \dot{a}_1 = \frac{1}{\tau}(u_1 - a_1), \\ \dot{F}_{t_2} = K_{t_2}(r_p \dot{\alpha} - \dot{l}_{m_2}), \\ \ddot{l}_{m_2} = \frac{F_{t_2} - F_{act_2} - F_{p_2} - F_{d_2}}{M_{m_2}}, \\ \dot{a}_2 = \frac{1}{\tau}(u_2 - a_2), \end{cases} \quad (6)$$

где K_t – дифференциальная жесткость сухожилия; a – сигнал активации мышцы; u – управляющий сигнал; τ – постоянная времени задержки.

Дифференциальная жесткость сухожилия, зависит от текущего натяжения сухожилия [22]:

$$K_t = \begin{cases} k_{te} F_t + k_{tl}, & 0 \leq F_t \leq F_{tc}, \\ k_t, & F_t > F_{tc}, \\ k_c, & \text{в других случаях,} \end{cases} \quad (7)$$

где k_{te} , k_{tl} – параметры экспоненциальной жесткости сухожилия на начальном участке растяжения; k_t – линейная жесткость сухожилия при больших нагрузках; k_c – незначительная жесткость сухожилия на сжатие; F_{tc} – сила, при которой эластичность сухожилия изменяется от экспоненциальной до равномерной.

Сила сократительного элемента зависит от уровня активации и механических условий сокращения – длины и скорости мышцы [26]:

$$F_{act} = F_{\max} a F_l F_v, \quad (8)$$

где $F_{\max}$ – максимальное изометрическое усилие, которое может быть создано сократительным элементом; F_l – соотношение сила-длина; F_v – соотношение сила-скорость, которые имеют вид:

$$\begin{aligned} F_l &= 1 - \left(\frac{l_m / l_{\text{opt}} - 1}{\Omega} \right)^2, \\ F_v &= \sqrt[3]{\frac{\dot{l}_m}{V_{\max}}} + 1, \end{aligned} \quad (9)$$

где l_m – длина мышцы; l_{opt} – оптимальная длина мышцы; Ω – относительная ширина кривой соотношения сила-длина; $\dot{l}_m$ – скорость изменения длины мышцы; $V_{\max}$ – максимальная скорость мышечного сокращения.

Сила параллельного эластичного элемента описывается кусочно-заданной функцией с экспоненциальным и линейным участками [27]:

$$F_p = \begin{cases} \frac{k_{ml}}{k_{me}} (\exp(k_{me}(l_m - l_{ms})) - 1), & l_{ms} \leq l_m \leq l_{mc}, \\ k_m (l_m - l_{mc}) + F_{mc}, & l_m > l_{mc}, \\ 0, & \text{в других случаях,} \end{cases} \quad (10)$$

где k_{me} , k_{ml} – параметры экспоненциальной жесткости параллельного эластичного элемента при растяжении; k_m – линейная жесткость параллельного эластичного элемента при больших деформациях; l_{ms} – длина мышцы в ненапряженном состоянии; l_{mc} , F_{mc} – длина и усилие, при которых упругость параллельного эластичного элемента изменяется от экспоненциальной к линейной.

Сила параллельного демпфирующего элемента предполагается линейно-вязкой [28]:

$$F_d = B_m \dot{l}_m, \quad (11)$$

где B_m – коэффициент демпфирования мышцы.

Сигналы активации мышц a_{ψ_1} , a_{ψ_2} , a_{ϕ_1} , a_{ϕ_2} , a_{γ_1} , a_{γ_2} вычисляются на основе управляющих сигналов следующим образом:

$$a_1 = \min \left(\max \left(\frac{u}{u_{\max}}, 0 \right), 1 \right),$$

$$a_2 = \min \left(\max \left(\frac{-u}{u_{\max}}, 0 \right), 1 \right), \quad (12)$$

где $u_{\max}$ – максимальное значение управляющего сигнала.

Управляющие сигналы u_{ψ} , u_{ϕ} и u_{γ} предлагается формировать как ПИ-законы регулирования следующим образом:

$$u_{\psi} = K_{p_{\psi}} e_{\psi} + K_{i_{\psi}} \int_0^t e_{\psi}(\tau) d\tau +$$

$$+ K_{p_{\dot{\psi}}} e_{\dot{\psi}} + K_{i_{\dot{\psi}}} \int_0^t e_{\dot{\psi}}(\tau) d\tau,$$

$$u_{\phi} = K_{p_{\phi}} e_{\phi} + K_{i_{\phi}} \int_0^t e_{\phi}(\tau) d\tau +$$

$$+ K_{p_{\dot{\phi}}} e_{\dot{\phi}} + K_{i_{\dot{\phi}}} \int_0^t e_{\dot{\phi}}(\tau) d\tau,$$

$$u_{\gamma} = K_{p_{\gamma}} e_{\gamma} + K_{i_{\gamma}} \int_0^t e_{\gamma}(\tau) d\tau +$$

$$+ K_{p_{\dot{\gamma}}} e_{\dot{\gamma}} + K_{i_{\dot{\gamma}}} \int_0^t e_{\dot{\gamma}}(\tau) d\tau, \quad (13)$$

где $K_{p_{\psi}}$, $K_{i_{\psi}}$, $K_{p_{\dot{\psi}}}$, $K_{i_{\dot{\psi}}}$, $K_{p_{\phi}}$, $K_{i_{\phi}}$, $K_{p_{\dot{\phi}}}$, $K_{i_{\dot{\phi}}}$, $K_{p_{\gamma}}$, $K_{i_{\gamma}}$, $K_{p_{\dot{\gamma}}}$, $K_{i_{\dot{\gamma}}}$ – коэффици-

енты системы регулирования, настройка которых осуществляется согласно подходу, предложенному в работе [29].

Таким образом, полная математическая модель представляет собой систему из 21 дифференциального уравнения (3 уравнения динамики сустава, 18 уравнений мышечной динамики). Для численного моделирования система приводится к нормальной форме Коши (системе дифференциальных уравнений первого порядка) и может быть описана следующим вектором фазовых переменных:

$$\mathbf{x} = \begin{bmatrix} \psi & \dot{\psi} & F_{t1_{\psi}} & l_{m1_{\psi}} & \dot{l}_{m1_{\psi}} & a_{1_{\psi}} & F_{t2_{\psi}} & \\ & l_{m2_{\psi}} & \dot{l}_{m2_{\psi}} & a_{2_{\psi}} & \phi & \dot{\phi} & F_{t1_{\phi}} & l_{m1_{\phi}} \\ & & \dot{l}_{m1_{\phi}} & a_{1_{\phi}} & F_{t2_{\phi}} & l_{m2_{\phi}} & \dot{l}_{m2_{\phi}} & a_{2_{\phi}} & \gamma \\ & & & \dot{\gamma} & F_{t1_{\gamma}} & l_{m1_{\gamma}} & \dot{l}_{m1_{\gamma}} & a_{1_{\gamma}} & F_{t2_{\gamma}} & l_{m2_{\gamma}} \\ & & & & \dot{l}_{m2_{\gamma}} & a_{2_{\gamma}} \end{bmatrix}^T. \quad (14)$$

Учет перекрестных связей реализуется умножением вектора углов на каждом шаге моделирования на матрицу трансформации следующим образом:

$$\begin{bmatrix} \psi \\ \phi \\ \gamma \end{bmatrix} = \begin{bmatrix} 1 & q_{\phi\psi} & q_{\gamma\psi} \\ q_{\psi\phi} & 1 & q_{\gamma\phi} \\ q_{\psi\gamma} & q_{\phi\gamma} & 1 \end{bmatrix} \begin{bmatrix} \psi \\ \phi \\ \gamma \end{bmatrix}, \quad (15)$$

где $q_{\phi\psi}$, $q_{\gamma\psi}$, $q_{\psi\phi}$, $q_{\gamma\phi}$, $q_{\psi\gamma}$, $q_{\phi\gamma}$ – коэффициенты перекрёстных связей по углам.

Результаты и их обсуждение

Для проверки предложенной математической модели системы регулирования биотехнической системы на примере лучезапястного сустава были проведены вычислительные эксперименты. Основные параметры модели приведены в таблицах 1 и 2.

Таблица 1. Параметры модели [20]

Table 1. Model parameters [20]

Параметр	Значение	Параметр	Значение
$k_{1\psi}, k_{1\phi}, k_{1\gamma}, k_{4\psi}, k_{4\phi}, k_{4\gamma}, \text{Н}\cdot\text{м}$	1	$q_{\phi\psi}, \text{рад}$	0,0869
$k_{2\psi}, k_{2\phi}, k_{2\gamma}, k_{5\psi}, k_{5\phi}, k_{5\gamma}, \text{рад}^{-1}$	6,5	$q_{\gamma\psi}, q_{\psi\gamma}, \text{рад}$	0,0017
$\Psi_{\max}, \Phi_{\max}, \gamma_{\max}, \text{рад}$	1,6	$q_{\phi\dot{\psi}}, \text{рад/с}$	0,0869
$\Psi_{\min}, \Phi_{\min}, \gamma_{\min}, \text{рад}$	-1,6	$q_{\dot{\gamma}\psi}, q_{\dot{\psi}\gamma}, \text{рад/с}$	0,0017
$J_{\psi}, J_{\phi}, J_{\gamma}, \text{кг}\cdot\text{м}^2$	0,002	$q_{\psi\phi}, \text{рад}$	0,0203
$B_{d\psi}, B_{d\phi}, B_{d\gamma}, \text{Н}\cdot\text{с/м}$	0,9	$q_{\dot{\phi}\psi}, q_{\dot{\psi}\phi}, \text{рад/с}$	0,0040
$K_{p\psi}, K_{p\phi}, K_{p\gamma}$	150	$q_{\dot{\psi}\dot{\phi}}, \text{рад/с}$	0,0203
$K_{i\psi}, K_{i\phi}, K_{i\gamma}$	0,5	$q_{\dot{\phi}\dot{\psi}}, q_{\dot{\psi}\dot{\phi}}, \text{рад/с}$	0,0040
$K_{p\dot{\psi}}, K_{p\dot{\phi}}, K_{p\dot{\gamma}}$	15	$r_p, \text{м}$	0,015
$K_{i\dot{\psi}}, K_{i\dot{\phi}}, K_{i\dot{\gamma}}$	0,01	$r_{cm}, \text{м}$	0,08
$m, \text{кг}$	0,4		

Таблица 2. Параметры модели мышц**Table 2.** Muscle model parameters

Параметр	Мышца					
	отведение	приведение	разгибание	сгибание	супинация	пронация
$k_{te}, \text{м}^{-1}$	300	300	290	270	200	200
$k_{tl}, \text{Н/м}$	3000	3000	2900	2700	2000	2000
$k_t, \text{Н/м}$	30000	30000	29000	27000	20000	20000
$k_c, \text{Н/м}$	5	5	5	5	5	5
$F_{tc}, \text{Н}$	30	30	30	30	30	30
$F_{\max}, \text{Н}$	550	500	510	550	500	500
$l_{mort}, \text{м}$	0,07	0,061	0,062	0,065	0,065	0,065
ω	0,55	0,55	0,55	0,55	0,55	0,55
$V_{\max}, \text{м/с}$	0,5	0,5	0,5	0,5	0,5	0,5
$k_{me}, \text{м}^{-1}$	40	40	40	40	40	40
$k_{ml}, \text{Н/м}$	52,38	54,65	29,61	32,81	57,97	57,97
$k_m, \text{Н/м}$	261,90	273,22	296,13	328,10	289,86	289,86
$F_{mc}, \text{Н}$	11	10	9,18	10,45	10	10
$l_{mc}, \text{м}$	0,0910	0,0793	0,0837	0,0871	0,0845	0,0845
$B_m, \text{Н}\cdot\text{с/м}$	20	20	20	20	20	20
$M_m, \text{кг}$	0,4	0,4	0,35	0,4	0,3	0,3

В ходе моделирования осуществлялось последовательное перемещение биотехнической системы в заданные положения. В качестве целевых были заданы следующие значения углов поворота: первая точка: $\psi = 30^\circ$, $\varphi = 20^\circ$, $\gamma = 0^\circ$; вторая точка: $\psi = 10^\circ$, $\varphi = -5^\circ$,

$\gamma = 10^\circ$; третья точка: $\psi = -40^\circ$, $\varphi = 50^\circ$, $\gamma = -10^\circ$. Полученные переходные процессы по углам и угловым скоростям представлены ниже (рис. 3), видно, что задача регулирования решается, система плавно перемещается из начального положения в заданные.




Рис. 3. Переходные процессы системы регулирования биотехнической системы на примере лучезапястного сустава

Fig. 3. Transient responses of the control system for the biotechnical system based on the wrist joint

Рассмотрим изменения длин мышц и соответствующие силы натяжения сухожилий для каждой пары мышц (рис. 4). Из графиков видно, что при перемещении сустава в заданном направлении происходит сокращение мышцы-агониста и одновременное удлинение

мышцы-антагониста. При этом сила натяжения сухожилия агониста возрастает, тогда как сила антагониста уменьшается по сравнению с агонистом. Разность этих сил формирует результирующий момент в соответствующей плоскости движения.




Рис. 4. Длина мышц и сила натяжения сухожилий

Fig. 4. Muscle length and tendon force

Динамика изменения длин мышц и сил сухожилий носит непрерывный и физиологически правдоподобный характер: отсутствуют скачкообразные изменения и неестественные значения усилий. Это свидетельствует о корректной реализации трёхкомпонентной модели Хилла и согласованности динамики мышечно-сухожильного комплекса с контуром регулирования.

Выводы

В работе представлена математическая модель системы регулирования биотехнической системы на примере

лучезапястного сустава, включающая модель движения сустава в трёх плоскостях с учётом перекрёстных связей и мышечно-сухожильную модель на основе трёхкомпонентной модели Хилла. Формирование моментов реализовано с учётом антагонистического характера работы мышечных групп, что позволяет физиологически достоверно описать мышечно-суставные усилия.

Для проверки предложенной математической модели системы регулирования биотехнической системы на примере лучезапястного сустава были проведены вычислительные экспери-

менты, которые показали, что разработанная система регулирования обеспечивает устойчивое и точное перемещение сустава в заданные положения. Переходные процессы характеризуются отсутствием статической ошибки и перерегулирования, что подтверждает корректность настройки регуляторов и функционирования замкнутой системы.

Анализ полученных результатов изменений длин мышц и сил натяже-

ния сухожилий продемонстрировал согласованную работу пар мышц. Таким образом, предложенная модель адекватно описывает взаимосвязь управляющих воздействий, мышечной динамики и движения сустава и может быть использована для дальнейших исследований в области моделирования и управления биотехническими системами.

Список литературы

1. Finite Element Modeling of the Human Wrist: A Review / A. Mena, R. Wollstein, J. Baus, J. Yang // *Journal of Wrist Surgery*. 2023. Vol. 12, N 6. P. 478–487. <https://doi.org/10.1055/s-0043-1768930>.
2. Biomechanical models in the lower-limb exoskeletons development: a review / V. Firouzi, A. Seyfarth, S. Song, O. Stryk, M. A. Sharbafi // *Journal of NeuroEngineering and Rehabilitation*. 2025. Vol. 22, N 1. P. 1–20. <https://doi.org/10.1186/s12984-025-01556-5>.
3. Multibody Models of the Thoracolumbar Spine: A Review on Applications, Limitations, and Challenges / T. Lerchl, K. Nispel, T. Baum, J. Bodden, V. Senner, J. S. Kirschke // *Bioengineering*. 2023. Vol. 10, N 2. P. 202. <https://doi.org/10.3390/bioengineering10020202>.
4. Comparative study regarding the stability of a proximal ulnar stump with or without distal oblique bundle reconstruction during the Sauvé-Kapandji procedure: a finite-element analysis / S. Yin, C. Zhang, Y. Huang, J. Pan, X. Wang, X. Liu // *Frontiers in Bioengineering and Biotechnology*. 2025. Vol. 12, P. 1482747. <https://doi.org/10.3389/fbioe.2024.1482747>.
5. Mechanical Effects of Wrist Position at the Wrist Joint: A Finite Element Analysis / T. Nomoto, M. Yusuke, Y. Takahiro, T. Suzuki, S. Ohtori // *Journal of Hand Surgery Global Online*. 2025. Vol. 7, N 4. P. 100747. <https://doi.org/10.1016/j.jhsg.2025.100747>.
6. Investigating the biomechanical behaviour of tendon-loaded wrist joint using web-like kinematic network model / I. S. Mat Jais, Y. R. Wong, D. A. McGrouther, H-L. Leo // *Journal of Biomechanics*. 2024. Vol. 172. P. 112210. <https://doi.org/10.1016/j.jbiomech.2024.112210>.
7. Pneumatically Actuated Soft Robotic Hand and Wrist Exoskeleton for Motion Assistance in Rehabilitation / T. Ridremont, I. Singh, B. Bruzek, A. Jamieson, Y. Gu, R. Merzouki, M. B. J. Wijesundara // *Actuators*. 2024. Vol. 13, N 5. P. 180. <https://doi.org/10.3390/act13050180>.
8. Di Gregorio R. Design of Novel Human Wrist Prostheses Based on Parallel Architectures: Dimensional Synthesis and Kinetostatics // *Biomimetics*. 2025. Vol. 10, N 1. P. 44. <https://doi.org/10.3390/biomimetics10010044>.

9. Wakeling J. M., Febrer-Nafria M., De Groot F. A Review of the Efforts to Develop Muscle and Musculoskeletal Models for Biomechanics in the Last 50 Years // *Journal of Biomechanics*. 2023. Vol. 155. P. 111657. <https://doi.org/10.1016/j.jbiomech.2023.111657>.
10. Multi-scale modeling and simulation of skeletal muscles with different fatigue degrees based on microphysiology / M. Wang, D. Jin, H. Wang, X. Xu, S. Zheng // *Scientific Reports*. 2025. Vol. 15, N 1. P. 11020. <https://doi.org/10.1038/s41598-025-87443-4>.
11. Modeling of active skeletal muscles: a 3D continuum approach incorporating multiple muscle interactions / W. Zeng, D. R. Hume, Y. Lu, C. Fitzpatrick, C. Babcock, C. Myers, P. Rullkoetter, K. Shelburne // *Frontiers in Bioengineering and Biotechnology*. 2023. Vol. 11. P. 1153692. <https://doi.org/10.3389/fbioe.2023.1153692>.
12. Development, validation, and biomechanical evaluation of a high-fidelity finite element model of the forearm musculoskeletal system / Rg. Shang, Sy. Xie, Lq. Liao, Gz. Qin, X. Zhu, Z. Wang, J. Xei, Y. Li, H. Yang, R. Gu // *BMC Musculoskelet Disord*. 2026. Vol. 20, N 199. P. 223. <https://doi.org/10.1186/s12891-026-09672-6>.
13. Numerical instability of Hill-type muscle models / S. H. Yeo, J. Verheul, W. Herzog, X. Xu, S. Zheng // *Journal of The Royal Society Interface*. 2023. Vol. 27, N 199. P. 20220430. <https://doi.org/10.1098/rsif.2022.0430>.
14. Hill-Type Models of Skeletal Muscle and Neuromuscular Actuators: A Systematic Review / A. H. Caillet, A. T. M. Phillips, C. Carty, D. Farina, L. Modenese // *IEEE Reviews in Biomedical Engineering*. 2025. Vol. 19. P. 159–181. <https://doi.org/10.1109/RBME.2025.3593185>.
15. Optimal fibre length and maximum isometric force are the most influential parameters when modelling muscular adaptations to unloading using Hill-type muscle models / J. Cowburn, G. Serrancolí, S. Colyer, D. Cazzola // *Frontiers in Physiology*. 2024. Vol. 15. P. 1347089. <https://doi.org/10.3389/fphys.2024.1347089>.
16. Applying a muscle fatigue model when optimizing load-sharing between muscles for short-duration high-intensity exercise: A preliminary study / F. Michaud, L. A. Frey-Law, U. Lúgrís, L. Cuadrado, J. Figueroa-Rodríguez, J. Cuadrado // *Frontiers in Physiology*. 2023. Vol. 14. P. 1167748. <https://doi.org/10.3389/fphys.2023.1167748>.
17. A forward dynamics framework for parameter optimization of the EMG-driven musculoskeletal model / H. Xie, Y. Wang, T. Liu, S. Yan, Y. Zhang, K. Zhang, X. Song // *Journal of NeuroEngineering and Rehabilitation*. 2026. Vol. 23. P. 91. <https://doi.org/10.1186/s12984-025-01752-3>.
18. Musculoskeletal Modeling of the Wrist via a Multi Body Simulation / J. Eschweiler, M. Praster, V. Quack, R. Michalik, F. Hildebrand, B. Rath, F. Migliorini // *Life*. 2022. Vol. 12, N 4. P. 581. <https://doi.org/10.3390/life12040581>.
19. An EMG-Driven Musculoskeletal Model for Estimation of Wrist Kinematics Using Mirrored Bilateral Movement / Y. Zhao, L. Zhenhong, Z. Zhiqiang, K. Qian, S. Xie // *Biomedical Signal Processing and Control*. 2023. Vol. 81. P. 104480. <https://doi.org/10.1016/j.bspc.2022.104480>.

20. A Musculoskeletal Model of the Hand and Wrist Capable of Simulating Functional Tasks / D. C. McFarland, B. I. Binder-Markey, J. A. Nichols, S. J. Wohlman, M. de Bruin, W. M. Murray // *IEEE Transactions on Biomedical Engineering*. 2023. Vol. 70, N 5. P. 1424–1435. <https://doi.org/10.1109/TBME.2022.3217722>.
21. Scherbak O. Yu., Maslennikov A. L. Biotechnical system based on the wrist joint control system tuning via genetic algorithm // *Russian Journal of Biomechanics*. 2025. Vol. 29, N 2. P. 116–122. <https://doi.org/10.15593/RJBiomech/2025.2.11>.
22. The Simultaneous Model-Based Estimation of Joint, Muscle, and Tendon Stiffness is Highly Sensitive to the Tendon Force-Strain Relationship / C. P. Cop, K. L. Jakubowski, A. C. Schouten, B. Koopman, E. J. Perreault, M. Sartori // *IEEE Transactions on Biomedical Engineering*. 2024. Vol. 71, N 3. P. 987–997. <https://doi.org/10.1109/TBME.2023.3324485>.
23. Koussou A., Dumas R., Desailly E. A procedure and model for the identification of uni- and biarticular structures passive contribution to inter-segmental dynamics // *Scientific Reports*. 2023. Vol. 13. P. 10535. <https://doi.org/10.1038/s41598-023-37357-w>.
24. Mechanical Modeling of the Dynamic Response of the Knee Joint Angle in the Evaluation of Muscle Nerve Response and Energy Consumption / L. Hongyan, B. Zhao, Q. Wang, J. Lee, L. Liu, P. Xu, J. Park // *Journal of Biomechanics*. 2025. Vol. 182. P. 112565. <https://doi.org/10.1016/j.jbiomech.2025.112565>.
25. Elbow Joint Stiffness Functional Scales Based on Hill's Muscle Model and Genetic Optimization / M. Radmilović, D. Urukalo, M. M. Janković, S. D. Dujović, T. J. D. Tomić, M. Trumić, K. Jovanović // *Sensors*. 2023. Vol. 23. P. 1709. <https://doi.org/10.3390/s23031709>.
26. Zhao Y., Ding S., Todoh M. Validate the force-velocity relation of the Hill's muscle model from a molecular perspective // *Frontiers in Bioengineering and Biotechnology*. 2022. Vol. 10. P. 1006571. <https://doi.org/10.3389/fbioe.2022.1006571>.
27. Full Hill-type muscle model of the I1/I3 retractor muscle complex in *Aplysia californica* / R. Sukhmandan, Q. Chen, J. Shen, S. Pao, Y. Huan, G. P. Sutton, J. P. Gill, H. J. Chiel, V. A. Webster-Wood // *Biological Cybernetics*. 2024. Vol. 118. P. 165–185. <https://doi.org/10.1007/s00422-024-00990-3>.
28. Muscle-tendon mechanics resolve the trade-off between energy-efficient and robust locomotion / M. Araz, T. Siebert, A. Badri-Spröwitz, S. Schmitt, D. F. B. Haeufle // *Biology Letters*. 2025. Vol. 21, N 11. P. 20250200. <https://doi.org/10.1098/rsbl.2025.0200>.
29. Масленников А. Л., Щербак О. Ю. Настройка системы регулирования сферического маятника с использованием генетического алгоритма по желаемому переходному процессу // *Автоматизация. Современные технологии*. 2026. Т. 80, № 2. С. 51–58. <https://doi.org/10.36652/0869-4931-2026-80-2-51-58>.
30. Assessment of synergy-assisted EMG-driven NMSK model for upper limb muscle activation prediction in cross-country sit-skiing double poling / X. Chen, Z. Yuan, X. Gao, Y. Zhang, C. Liu, B. Huo // *Frontiers in Bioengineering and Biotechnology*. 2025. Vol. 13. P. 1585127. <https://doi.org/10.3389/fbioe.2025.1585127>.

References

1. Mena A., Wollstein R., Baus J., Yang J. Finite Element Modeling of the Human Wrist: A Review. *Journal of Wrist Surgery*. 2023;12(6):478-487. <https://doi.org/10.1055/s-0043-1768930>.
2. Firouzi V., Seyfarth A., Song S., Stryk O., Sharbafi M.A. Biomechanical models in the lower-limb exoskeletons development: a review. *Journal of NeuroEngineering and Rehabilitation*. 2025;22(1):1-20. <https://doi.org/10.1186/s12984-025-01556-5>.
3. Lerchl T., Nispel K., Baum T., Bodden J., Senner V., Kirschke J.S. Multibody Models of the Thoracolumbar Spine: A Review on Applications, Limitations, and Challenges. *Bioengineering*. 2023;10(2):202. <https://doi.org/10.3390/bioengineering10020202>.
4. Yin S., Zhang C., Huang Y., Pan J., Wang X., Liu X. Comparative study regarding the stability of a proximal ulnar stump with or without distal oblique bundle reconstruction during the Sauvé-Kapandji procedure: a finite-element analysis. *Frontiers in Bioengineering and Biotechnology*. 2025;12:1482747. <https://doi.org/10.3389/fbioe.2024.1482747>.
5. Nomoto T., Yusuke M., Takahiro Y., Suzuki T., Ohtori S. Mechanical Effects of Wrist Position at the Wrist Joint: A Finite Element Analysis. *Journal of Hand Surgery Global Online*. 2025;7(4):100747. <https://doi.org/10.1016/j.jhsg.2025.100747>.
6. Mat Jais I.S., Wong Y.R., McGrouther D.A., Leo H-L. Investigating the biomechanical behaviour of tendon-loaded wrist joint using web-like kinematic network model. *Journal of Biomechanics*. 2024;172:112210. doi: 10.1016/j.jbiomech.2024.112210.
7. Ridremont T., Singh I., Bruzek B., Jamieson A., Gu Y., Merzouki R., Wijesundara M.B.J. Pneumatically Actuated Soft Robotic Hand and Wrist Exoskeleton for Motion Assistance in Rehabilitation. *Actuators*. 2024;13(5):180. <https://doi.org/10.3390/act13050180>.
8. Di Gregorio R. Design of Novel Human Wrist Prostheses Based on Parallel Architectures: Dimensional Synthesis and Kinetostatics. *Biomimetics*. 2025;10(1):44. <https://doi.org/10.3390/biomimetics10010044>.
9. Wakeling J.M., Febrer-Nafria M., De Groote F. A Review of the Efforts to Develop Muscle and Musculoskeletal Models for Biomechanics in the Last 50 Years. *Journal of Biomechanics*. 2023;155:11657. <https://doi.org/10.1016/j.jbiomech.2023.111657>.
10. Wang M., Jin D., Wang H., Xu X., Zheng S. Multi-scale modeling and simulation of skeletal muscles with different fatigue degrees based on microphysiology. *Scientific Reports*. 2025;15:11020. <https://doi.org/10.1038/s41598-025-87443-4>.
11. Zeng W., Hume D.R., Lu Y., Fitzpatrick C., Babcock C., Myers C., Rullkoetter P., Shelburne K. Modeling of active skeletal muscles: a 3D continuum approach incorporating multiple muscle interactions. *Frontiers in Bioengineering and Biotechnology*. 2023;11:1153692. <https://doi.org/10.3389/fbioe.2023.1153692>.
12. Shang Rg., Xie Sy., Liao Lq., Qin Gz., Zhu X., Wang Z., Xei J., Li Y., Yang H., Gu R. Development, validation, and biomechanical evaluation of a high-fidelity finite element model of the forearm musculoskeletal system. *BMC Musculoskelet Disord*. 2026;27(1):223. <https://doi.org/10.1186/s12891-026-09672-6>.

13. Yeo S.H., Verheul J., Herzog W., Xu X., Zheng S. Numerical instability of Hill-type muscle models. *Journal of The Royal Society Interface*. 2023;27(199):20220430. <https://doi.org/10.1098/rsif.2022.0430>.
14. Caillet A.H., Phillips A.T.M., Carty C., Farina D., Modenese L. Hill-Type Models of Skeletal Muscle and Neuromuscular Actuators: A Systematic Review. *IEEE Reviews in Biomedical Engineering*. 2025;19:159-181. <https://doi.org/10.1109/RBME.2025.3593185>.
15. Cowburn J., Serrancolí G., Colyer S., Cazzola D. Optimal fibre length and maximum isometric force are the most influential parameters when modelling muscular adaptations to unloading using Hill-type muscle models. *Frontiers in Physiology*. 2024;15:1347089. <https://doi.org/10.3389/fphys.2024.1347089>.
16. Michaud F., Frey-Law L.A., Lúgrís U., Cuadrado L., Figueroa-Rodríguez J., Cuadrado J. Applying a muscle fatigue model when optimizing load-sharing between muscles for short-duration high-intensity exercise: A preliminary study. *Frontiers in Physiology*. 2023;14:1167748. <https://doi.org/10.3389/fphys.2023.1167748>.
17. Xie H., Wang Y., Liu T., Yan S., Zhang Y., Zhang K., Song X. A forward dynamics framework for parameter optimization of the EMG-driven musculoskeletal model. *Journal of NeuroEngineering and Rehabilitation*. 2026;23:91. <https://doi.org/10.1186/s12984-025-01752-3>.
18. Eschweiler J., Praster M., Quack V., Michalik R., Hildebrand F., Rath B., Migliorini F. Musculoskeletal Modeling of the Wrist via a Multi Body Simulation. *Life*. 2022;12(4):581. <https://doi.org/10.3390/life12040581>.
19. Zhao Y., Zhenhong L., Zhiqiang Z., Qian K., Xie S. An EMG-Driven Musculoskeletal Model for Estimation of Wrist Kinematics Using Mirrored Bilateral Movement. *Biomedical Signal Processing and Control*. 2023;81:104480. <https://doi.org/10.1016/j.bspc.2022.104480>.
20. McFarland D.C., Binder-Markey B.I., Nichols J.A., Wohlman S.J., de Bruin M., Murray W.M. A Musculoskeletal Model of the Hand and Wrist Capable of Simulating Functional Tasks. *IEEE Transactions on Biomedical Engineering*. 2023;70(5):1424-1435. <https://doi.org/10.1109/TBME.2022.3217722>.
21. Scherbak O.Yu., Maslennikov A.L. Biotechnical system based on the wrist joint control system tuning via genetic algorithm. *Russian Journal of Biomechanics*. 2025;29(2):116-122. <https://doi.org/10.15593/RJBiomech/2025.2.11>.
22. Cop C. P., Jakubowski K. L., Schouten A. C., Koopman B., Perreault E.J., Sartori M. The Simultaneous Model-Based Estimation of Joint, Muscle, and Tendon Stiffness is Highly Sensitive to the Tendon Force-Strain Relationship. *IEEE Transactions on Biomedical Engineering*. 2024;71(3):987-997. <https://doi.org/10.1109/TBME.2023.3324485>.
23. Koussou A., Dumas R., Desailly E. A procedure and model for the identification of uni- and biarticular structures passive contribution to inter-segmental dynamics. *Scientific Reports*. 2023;13:10535. <https://doi.org/10.1038/s41598-023-37357-w>.
24. Hongyan L., Zhao B., Wang Q., Lee J., Liu L., Xu P., Park J. Mechanical Modeling of the Dynamic Response of the Knee Joint Angle in the Evaluation of Muscle Nerve

Response and Energy Consumption. *Journal of Biomechanics*. 2025;182:112565. <https://doi.org/10.1016/j.jbiomech.2025.112565>.

25. Radmilović M., Urukalo D., Janković M.M.; Dujović S.D., Tomić T.J.D., Trumić M., Jovanović K. Elbow Joint Stiffness Functional Scales Based on Hill's Muscle Model and Genetic Optimization. *Sensors*. 2023;23:1709. <https://doi.org/10.3390/s23031709>.

26. Zhao Y., Ding S., Todoh M. Validate the force-velocity relation of the Hill's muscle model from a molecular perspective. *Frontiers in Bioengineering and Biotechnology*. 2022;10:1006571. <https://doi.org/10.3389/fbioe.2022.1006571>.

27. Sukhnandan R., Chen Q., Shen J., Pao S., Huan Y., Sutton G.P., Gill J.P., Chiel H.J., Webster-Wood V.A. Full Hill-type muscle model of the I1/I3 retractor muscle complex in *Aplysia californica*. *Biological Cybernetics*. 2024;118:165–185. <https://doi.org/10.1007/s00422-024-00990-3>.

28. Araz M., Siebert T., Badri-Spröwitz A., Schmitt S., Haeufle D.F.B. Muscle-tendon mechanics resolve the trade-off between energy-efficient and robust locomotion. *Biology Letters*. 2025;21(11):20250200. <https://doi.org/10.1098/rsbl.2025.0200>.

29. Maslennikov A.L., Shcherbak O.Yu. A control system adjustment of the spherical pendulum using a genetic algorithm based on a desired transient process. *Avtomatizatsiya. Sovremennye tekhnologii = Automation. Modern Technologies*. 2026;80(2):51–58. (In Russ.) <https://doi.org/10.36652/0869-4931-2026-80-2-51-58>.

30. Chen X., Yuan Z., Gao X., Zhang Y., Liu C., Huo B. Assessment of synergy-assisted EMG-driven NMSK model for upper limb muscle activation prediction in cross-country sit-skiing double poling. *Frontiers in Bioengineering and Biotechnology*. 2025;13:1585127. <https://doi.org/10.3389/fbioe.2025.1585127>.

Информация об авторах / Information about the Authors

Щербак Ольга Юрьевна, ассистент кафедры систем автоматического управления, Московский государственный технический университет им. Н. Э. Баумана, г. Москва, Российская Федерация, e-mail: scherbak.olga.j@bmstu.ru, ORCID: 0000-0002-1826-910X

Olga Y. Scherbak, Assistant at the Department of Automatic Control Systems, Bauman Moscow State Technical University, Moscow, Russian Federation, e-mail: scherbak.olga.j@bmstu.ru, ORCID: 0000-0002-1826-910X

Масленников Андрей Леонидович, старший преподаватель кафедры системы автоматического управления, Московский государственный технический университет им. Н. Э. Баумана, г. Москва, Российская Федерация, e-mail: amas@bmstu.ru, ORCID: 0000-0001-9061-4193

Andrey L. Maslennikov, Senior Lecturer at the Department of Automatic Control Systems, Bauman Moscow State Technical University, Moscow, Russian Federation, e-mail: amas@bmstu.ru, ORCID: 0000-0001-9061-4193

<https://doi.org/10.21869/2223-1536-2026-16-2-235-247>



УДК 617.3 617.3

Методика оптимизации выбора и хранения информации об электрокардиосигналах сверхвысокого разрешения

Д. О. Шевяков¹ ✉, Е. А. Денисова¹, А. А. Кордюкова¹,
А. С. Афанасенко¹, Б. С. Гуревич¹

¹ Институт аналитического приборостроения Российской академии наук
ул. Ивана Черных, д. 31–33, литера А, г. Санкт-Петербург 198095, Российская Федерация

✉ e-mail: sevakovdaniil@gmail.com

Резюме

Цель исследования. Разработка и апробация специализированной автоматизированной системы для записи, структурированного хранения и анализа данных электрокардиосигналов сверхвысокого разрешения, получаемых в ходе экспериментов по моделированию ишемии миокарда у подопытных животных на базе применения нового метода электрокардиографии сверхвысокого разрешения, – цель исследования.

Методы. Для решения задачи была реализована автоматизированная система, состоящая из модулей записи, хранения и анализа. Модуль записи был специально разработан для сохранения электрокардиосигналов сверхвысокого разрешения и включает возможность визуализации хода эксперимента для контроля состояния биологического объекта. Модуль хранения данных эксперимента представляет собой документоориентированную базу данных и специальное программное обеспечение, позволяющее систематизировать и извлекать по заданным критериям неоднородную информацию. Модуль автоматического анализа выполняет функцию последовательного исполнения программных модулей, специально разработанных для анализа электрокардиосигналов сверхвысокого разрешения.

Результаты. Внедрение разработанной системы хранения и анализа большого количества данных электрокардиосигналов сверхвысокого разрешения, полученных во время проведения экспериментов, позволило существенно оптимизировать исследовательские процессы. Используемый подход позволил ускорить выполнение рутинных операций за счет автоматизации цикла обработки данных от записи и систематизации до анализа. Отсутствие ручного присвоения метаданных, а также последующая валидация исключают неструктурированное хранение информации и ошибки, связанные с человеческим фактором, позволяя проводить недоступный ранее метаанализ.

Заключение. Система обеспечивает надежное хранение и безопасный доступ к большим объемам неоднородной информации, что повышает воспроизводимость, качество и эффективность исследований по ранней диагностике ишемии миокарда по методу электрокардиографии сверхвысокого разрешения.

Ключевые слова: хранение данных; анализ данных; базы данных; биомедицинские данные; электрокардиография сверхвысокого разрешения.

Благодарности: Хотим выразить благодарность Министерству образования и науки Российской Федерации за государственную тему № 1023032800366-6 «Теоретические и экспериментальные исследования по созданию приборов и интеллектуальных информационных систем ранней диагностики рака и других новообразований с использованием технологий радиофотоники, а также патологий сердца и головного мозга на базе инструментальной электрофизиологии сверхвысокого разрешения».

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

Для цитирования: Методика оптимизации выбора и хранения информации об электрокардиосигналах сверхвысокого разрешения / Д. О. Шевяков, Е. А. Денисова, А. А. Кордюкова, А. С. Афанасенко, Б. С. Гуревич // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 235–247. <https://doi.org/10.21869/2223-1536-2026-16-2-235-247>.

Поступила в редакцию 16.04.2026

Подписана в печать 14.05.2026

Опубликована 30.06.2026

A methodology for optimizing the selection and storage of ultra-high-resolution electrocardiogram information

Daniil O. Shevyakov¹ ✉, Elena A. Denisova¹, Anna A. Kordyukova¹,
Arseniy S. Afanasenko¹, Boris S. Gurevich¹

¹ Institute of Analytical Instrumentation of the Russian Academy of Sciences
31-33/A Ivan Chernykh Str., Saint Petersburg 198095, Russian Federation

✉ e-mail: sevakovdaniil@gmail.com

Abstract

Purpose of research. Development and testing of a specialized automated system for recording, structured storage, and analysis of ultra-high-resolution electrocardiogram data obtained during experiments modeling myocardial ischemia in laboratory animals using a new ultra-high-resolution electrocardiography method is the purpose of research.

Methods. To address this problem, an automated system consisting of recording, storage, and analysis modules was implemented. The recording module was specifically designed to store UHR ECS and includes the ability to visualize the experiment progress to monitor the condition of the biological sample. The experimental data storage module consists of a document-oriented database and specialized software that enables systematization and retrieval of heterogeneous information based on specified criteria. The automatic analysis module sequentially executes software modules specifically designed for analyzing UHR ECS.

Results. The introduction of a developed system for storing and analyzing a large amount of ultra-high resolution electro-cardio signal data obtained during experiments made it possible to significantly optimize research processes. The approach used made it possible to speed up the completion of routine operations by automating the data processing cycle from recording and system optimization to analysis. The absence of manual assignment of metadata, as well as subsequent validation, eliminates unstructured information storage and human errors, allowing previously unavailable meta-analysis.

Conclusion. The system ensures reliable storage and secure access to large volumes of heterogeneous data, improving the reproducibility, quality, and effectiveness of studies on the early diagnosis of myocardial ischemia using ultra-high-resolution electrocardiography.

Keywords: data storage; data analysis; databases; biomedical data; ultra-high-resolution electrocardiography

Acknowledgements: We would like to express our gratitude to the Ministry of Education and Science of the Russian Federation for state project No. 1023032800366-6 "Theoretical and experimental research on the creation of devices and intelligent information systems for the early diagnosis of cancer and other neoplasms using radiophotonics technologies, as well as pathologies of the heart and brain based on ultra-high-resolution instrumental electrophysiology."

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

For citation: Shevyakov D.O., Denisova E.A., Kordyukova A.A., Afanasenko A.S., Gurevich B.S. A methodology for optimizing the selection and storage of ultra-high-resolution electrocardiogram information. *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(2):235–247. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-235-247>.

Received 16.04.2026

Accepted 14.05.2026

Published 30.06.2026

Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026;16(2):235–247

Введение

Электрокардиография (ЭКГ) по-прежнему остается стандартом в диагностике ишемической болезни сердца (ИБС) и других кардиологических патологий [1]. В связи с этим совершенствование электрокардиографических методов является актуальной задачей для современного здравоохранения [2]. Тенденция к повышению диагностической чувствительности ЭКГ [3] и получению новой значимой информации о ранних стадиях развития ишемии миокарда позволила перейти к разработке нового метода электрокардиографии сверхвысокого разрешения (ЭКГ СВР) [4]. Данный метод предложен и развивается научным коллективом лаборатории «Радио и оптоэлектронных приборов ранней диагностики заболеваний человека» Института аналитического приборостроения РАН. Основной принцип метода ЭКГ СВР заключается в регистрации электрокардиосигналов сверхвысокого разрешения (ЭКС СВР) в более расширенных амплитудных и частотных диапазонах по сравнению с другими известными методами [4]. Такой подход позволяет выявить низкоамплитудные высокочастотные микропотенциалы, несущие важную диагностическую информацию о начальных стадиях патологических изменений в миокарде [5].

Для верификации диагностических возможностей метода ЭКГ СВР на базе Института экспериментальной медицины Центра Алмазова проводятся экспериментальные исследования на животных моделях с искусственно индуцированным коронарным синдромом [6]. В ходе экспериментов ведется многоканальная запись ЭКС СВР с трех отведений и двух каналов регистрации – низкочастотного (НЧ, аналог стандартной ЭКГ) и высокочастотного (в расширенных диапазонах). Полученные данные

составляют большой объем информации, а их рост, разновидность и сложность в обработке требуют внедрения передовых методов к их систематизации и комплексному анализу. Внедрение структурированной модульной системы для записи, хранения и обработки ЭКГ-данных становится критически важным. Такая система должна обеспечивать стандартизацию данных, автоматизацию обработки, воспроизводимость результатов и интеграцию с другими исследовательскими инструментами [7].

Известные платформы для хранения и анализа биомедицинских сигналов, такие как PhysioNet и MIMIC, являются стандартом для работы с клиническими и экспериментальными данными. Однако они заточены либо под относительно стандартизированные клинические форматы, либо под многопараметрические клинические записи. Форматы обмена, такие как OpenXDF, предлагают расширенные возможности для сложных метаданных, но их интеграция в замкнутые исследовательские циклы с уникальной аппаратурой требует дополнительной адаптации.

Научной проблемой, решаемой в данной работе, является отсутствие готовых решений, полностью учитывающих специфику протоколов экспериментов с ЭКГ СВР на животных, а именно: необходимость жесткой синхронизации «сырых» сигналов высокого и низкого разрешения, экспериментальных аннотаций в реальном времени, сложной иерархии метаданных и последующих результатов специализированной обработки. Разрабатываемая система позволит обеспечить не только хранение, но и автоматизированный анализ в рамках конкретной исследовательской методологии.

Использование структурированной системы записи, обработки и хранения

данных позволит значительно упростить процесс сохранения и дальнейшей обработки результатов экспериментов [7]. Автоматизация рутинных процессов, включая занесение экспериментальных данных в базу данных (БД), сохранение записей в стандартизированном формате, фильтрацию и обработку данных, генерацию и сравнение итоговых результатов, позволит минимизировать влияние человеческого фактора на этапах регистрации и систематизации информации [8]. Ключевым преимуществом такого подхода является единообразие обработки данных на всех этапах исследования, что обеспечивает сопоставимость и воспроизводимость результатов [9]. Кроме того, централизованное хранение информации позволит оперативно извлекать данные по заданным критериям, проводить комплексный анализ, корре-

лировать параметры ЭКС СВР с другими биомедицинскими показателями.

Материалы и методы

Разработанная методика оптимизации рабочего цикла с данными ЭКС СВР основана на трех ключевых принципах: автоматизация присвоения метаданных на этапе записи для исключения человеческого фактора; использование базы данных с гибкой схемой для аккомодации неоднородных и опциональных данных экспериментов; централизация хранения и обработки в единой программной среде для устранения асинхронности и обеспечения воспроизводимости.

Для решения поставленной задачи разработана структурная схема системы отображения, записи, обработки и хранения данных об ЭКС СВР (рис. 1).




Рис. 1. Структурная схема системы отображения, записи, хранения и обработки электрокардиосигналов сверхвысокого разрешения

Fig. 1. Structural diagram of the system for displaying, recording, storing and processing ultra-high-resolution electrocardiogram signals

Разработанная система состоит из трех модулей: отображения / записи, хранения и обработки. В модуле отображения / записи регистрируемые с об-

екта исследования сигналы с трех отведений и двух каналов транслируются на экране ПК, что позволяет контролировать правильность подключения всех

элементов электрофизиологического технического оснащения эксперимента, а также проверять корректность записи во всех отведениях. В дальнейшем потребность постоянного отображения ЭКС СВР на мониторе обусловлена необходимостью в контроле изменения их характеристик. Одновременно с отображением и записью самого сигнала в данном модуле предусмотрено внесение в специальное окно аннотаций данных об этапах эксперимента, его особенностях и внештатных ситуациях [10]. Запись сигнала с экспериментального блока и аннотации производится с использованием специально разработанного программного модуля. Отображение сигналов в реальном времени реализовано с помощью EDF-браузера – специализированного инструмента для просмотра и анализа медицинских сигналов в формате .edf. Выбор данного инструмента обоснован его ключевыми функциями: поддержкой различных операционных систем (Windows/macOS/Linux); возможностью одновременного просмотра до 64 сигнальных каналов; функциями настройки цветовых схем и масштабирования; встроенными фильмами разных типов и др. Записанные edf-файлы и соответствующие аннотации сохраняются в модуле хранения.

Модуль хранения состоит из файлового хранилища, а также взаимодействующей с ней базы данных экспериментов с метаданными и результатами последующей обработки. Специфическая неоднородность структуры метаданных экспериментов накладывает определенные ограничения при выборе системы управления базой данных (СУБД). Информация об экспериментах может содержать уникальные значения, например описание внештатных ситуа-

ций, произошедших во время проведения эксперимента. Некоторые записи могут, наоборот, не иметь типичной для набора данных информации, например, если животное погибло в процессе проведения эксперимента. Таким образом, необходимо использовать СУБД, которая поддерживает хранение неоднородных данных, при этом предоставляя возможность эффективно извлекать информацию по заданным параметрам [11]. Была выбрана документоориентированная NoSQL СУБД – MongoDB, обладающая гибкой схемой, возможностью работы с вложенными документами или массивам, а также масштабируемостью (возможностью хранения больших объемов данных от множества экспериментов) [12]. Файловое хранилище представляет собой несортированную систему хранения, взаимодействие с которой осуществляется через набор ссылок на файлы записей экспериментов. Эти ссылки сохраняются в коллекциях БД и привязываются к конкретным экспериментам [13].

Для обеспечения эффективного совместного доступа к данным различных медицинских и исследовательских команд было решено разместить файловое хранилище и базу данных на удаленном сервере. Такой подход позволит централизованно хранить данные, а также управлять ими. Резервное копирование данных для последующего хранения на защищенном сервере позволит избежать утери данных вследствие случайного удаления кем-то из пользователей. Также хранение данных на удаленном сервере позволит разграничить доступ к информации в зависимости от роли пользователя.

Как было отмечено ранее, сама база данных содержит две коллекции: экспе-

рименты и результаты обработки. Коллекция экспериментов включает в себя набор метаданных, описывающих условия, методы и параметры эксперимента. Они играют ключевую роль в воспроизводимости исследований, анализе данных и последующей экстраполяции результатов на человека. Все метаданные подразделяются на категории: общая информация об эксперименте (цель исследования – изучение острой ишемии, оценка реперфузионного повреждения, изучение субклинического атеросклероза и т. д.; авторы и учреждения; дата и место проведения; номер протокола комиссии по биоэтике), характеристики подопытных животных (вид и линия – например крысы Wistar, мыши C57BL/6, свиньи и т. д.; пол, вес и физиологическое состояние; условия содержания и рацион), архивные данные (сырые записи ЭКС СВР, фильтрованные записи ЭКС СВР, аннотации). Перечисленные метаданные являются обязательными для заполнения. К опциональной информации можно отнести данные об особенностях проведения эксперимента или описание непредвиденных случаев, произошедших в процессе проведения эксперимента, например выход из строя датчиков или включения дополнительного оборудования.

Коллекция результатов обработки представляет собой набор записей, каждая из которых содержит ссылки на различные результаты обработки экспериментов. Следует отметить, что фильтрация является частью последующей обработки, однако ее результаты хранятся в коллекции экспериментов для более удобного доступа к ЭКС СВР. Все дальнейшие процедуры проводятся как для сырых, так и для фильтрованных сигнала-

лов, а результаты сохраняются в соответствующие файлы.

Основным методом последующей обработки ЭКС СВР является проведение их спектрального анализа, включающего Фурье-преобразование, расчет гистограмм и вейвлет-преобразование. Результаты спектрального анализа хранятся в виде файла, содержащего рассчитанные оценки спектральной плотности мощности на различных этапах эксперимента. Снижение спектральной плотности мощности ЭКС СВР в ВЧ-канале при моделировании патологии является основным диагностическим маркером ее раннего развития. В связи с этим данные значения являются обязательными для хранения в БД. Помимо числовых значений результатами спектральной обработки также являются и наборы изображений, которые также заносятся в модуль хранения.

Результаты выделения характерных точек ЭКС СВР из НЧ-канала содержат файл с массивом временных отсчетов, соответствующих PQRS-пикам, полученными с помощью инструментов, описанных в работе [14]. Данная процедура в первую очередь необходима для выявления характерных изменений сегмента ST (элевацию или депрессию), которые служат общепризнанными маркерами ишемии, поэтому полученные значения также обязательно вносятся в БД.

Данные, содержащие результаты проведения синхронного анализа представляют собой файлы, содержащие набор кардиоциклов, которые разделены на кластеры и масштабированы [15]. Эти данные необходимы для дальнейшего анализа тонкой структуры высокочастотных составляющих ЭКС СВР и хранятся в виде файлов в формате .csv.

Результаты и их обсуждение

Внедрение автоматизированной системы хранения и обработки стало важным пунктом в процессе оптимизации работы с большими массивами биомедицинских данных ЭКС СВР, получаемых в процессе проведения экспериментальных исследований. Система позволила не только ускорить отдельные операции, но и в корне преобразить весь цикл записи, систематизации и анализа поступающих данных.

В процессе записи эксперимента происходит автоматическое присвоение метаданных, таких как дата, место проведения эксперимента и особые условия. По завершении процедуры эксперимента происходит валидация данных, проверка их на целостность и сохранение в структурированную базу данных. Такой подход исключает возможность неструктурированного сохранения информации, а также устраняет необходимость в трудоемких процессах ручной систематизации поступающих данных.

Одним из ключевых решений в разработке системы является переход от локального хранения информации на удаленное хранилище. Эта мера позволяет реализовывать принцип централизованного управления данными. За счет этого пропадет необходимость дублирования базы данных на каждом устройстве, участвующем в обработке. Такой подход позволяет не только экономить дисковое пространство, но и обеспечивает повышение уровня информационной безопасности, обеспечивая сохранение данных в одном централизованном, контролируемом и защищенном окружении.

Важным достижением является существенное уменьшение времени от

момента фиксации данных в ходе эксперимента до появления записи в удобном для дальнейшего анализа формате. Устранение процедуры физического переноса информации между рабочими устройствами позволяет исключить задержки, связанные с человеческим фактором и пропускной способностью каналов копирования. Также пропала необходимость вносить изменения в базу данных на каждом устройстве, где она хранится. Все это позволяет подготавливать данные к дальнейшей обработке в режиме, приближенном к реальному времени.

Реализация возможности удаленного доступа к базе данных позволяет существенно улучшить научное взаимодействие. Это позволяет обеспечить территориальную независимость научной деятельности, предоставляя возможность осуществлять анализ данных с любого устройства, имеющего подключение к интернету.

Применение системы ролевого доступа позволяет детально проработать полномочия взаимодействия с данными для каждой группы пользователей от младшего персонала, обладающего только возможностью просмотра информации до ведущих исследователей, обладающих возможностью модификации данных и изменения процедуры обработки. Такая точечная настройка прав доступа обеспечивает целостность и конфиденциальность данных, исключая возможность несанкционированного доступа, модификации или удаления данных, в т. ч. вследствие человеческой ошибки.

Рассмотрим пример использования системы разными группами исследователей (рис. 2).

№

Дата

Патология

Место

Животное

Серия

Пол

Найти

Номер протокола	Дата	Исследуемая патология	Место	Животное	Серия	Пол	Файлы
7_1	04.05.2023	Трансмуральная ишемия	Кабинет 405	Крыса	K-1226	М	Запись Анализ Протокол
9_2	25.09.2023	Трансмуральная ишемия	Кабинет 405	Крыса	K-1134	М	Запись Анализ Протокол
P_3	26.06.2023	Субэндокардиальная ишемия	Кабинет 412	Свинья	C-1522	М	Запись Анализ Протокол
K_5	26.06.2023	Контроль	Кабинет 405	Крыса	K-1226	М	Запись Анализ Протокол

а

№

Дата

Патология

Место

Животное

Серия

Пол

Найти

Номер протокола	Дата	Исследуемая патология	Место	Животное	Серия	Пол	Файлы	Управление
7_1	04.05.2023	Трансмуральная ишемия	Кабинет 405	Крыса	K-1226	М	Запись Анализ Протокол	Изменить параметры анализа Повторить анализ Изменить данные Удалить данные
9_2	25.09.2023	Трансмуральная ишемия	Кабинет 405	Крыса	K-1134	М	Запись Анализ Протокол	Изменить параметры анализа Повторить анализ Изменить данные Удалить данные
P_3	26.06.2023	Субэндокардиальная ишемия	Кабинет 412	Свинья	C-1522	М	Запись Анализ Протокол	Изменить параметры анализа Повторить анализ Изменить данные Удалить данные
K_5	26.06.2023	Контроль	Кабинет 405	Крыса	K-1226	М	Запись Анализ Протокол	Изменить параметры анализа Повторить анализ Изменить данные Удалить данные

б

Рис. 2. Интерфейс системы для (а) группы с правами администратора и (б) группы без прав администратора

Fig. 2. The system interface for (a) a group with administrator rights and (b) a group without administrator rights

Для количественной оценки эффективности системы были определены следующие метрики: скорость выполнения запросов к БД по ключевым метаданным (например, выборка всех экспериментов по виду животного), которая не превышает 150 мс; степень сокращения ручных операций при подготовке данных к анализу, оцененная как отношение времени, затрачиваемого вручную в старой схеме работы, к времени в новой схеме. Надежность хранения обеспечивается схемой репликации данных на удаленном сервере и ежедневным резервным копированием.

Внедрение автоматизированной процедуры анализа, включающей систематизацию и сохранение результатов в базу данных, позволило достичь существенного сокращения времени на цикл обработки данных – на 40% от момента

регистрации сигнала до момента получения интерпретируемых результатов, с 3,5 до 2 ч в среднем по результатам обработки 80 экспериментов. Подобное увеличение производительности обусловлено устранением ключевой причины задержки – асинхронности в модификации и использовании аналитических модулей.

Ранее необходимость ручного обмена данными между множеством рабочих станций и инструментов, которые разрабатывались в разное время разными научными коллективами, создавала существенные задержки в исследовательском процессе, особенно в многозадачных и взаимозависимых процедурах. Новая система, являющаяся унифицированной программной средой, объединяет эти разрозненные модули и обеспечивает их последовательное исполнение.

Критически важным является не только сохранение конечных результатов анализа, но и систематический сбор и сохранение метаданных процедур обработки, которые включают временные метки выполнения операций, возникающие исключения и ошибки, а также параметры конфигурации алгоритмов. Такой подход формирует не только базу

данных результатов анализа, но и позволяет создать полноценный каталог исследовательского процесса, включающий особенности обработки каждого эксперимента.

Запись из каталога, включающая в себя метаданные из каталога, представлена ниже (рис. 3).

Информация об эксперименте			
Номер протокола	Дата эксперимента	Исследуемая патология	Место
7_1	04.05.2023	Трансмуральная ишемия	Кабинет 405
Информация о животном			
Вид	Пол	Серия	Вес
Крыса	М	К-1226	316 гр.
Сведения об исполнителе		Дополнительные сведения о животном	
Должность	Организация	Подготовка	Диета
В.н.с.	НМИЦ Алмазово	Резекция желудка	Стандартная
Результаты анализа			
Падение СИМ		Точность выделения характерных точек	
В %	Абсолютное	98.9%	
32.6	3.1		
Коэффициент увеличения падения после синхронного анализа		Точность выделения кардиоциклов с использованием вейвлет-анализа	
1.98		97.9%	
Отношение сигнал/шум до и после фильтрации			
До		После	
9		31	

Рис. 3. Демонстрация данных эксперимента в интерфейсе пользователя

Fig. 3. Demonstration of experimental data in the user interface

Накопление такой полной информации позволяет проводить недоступный ранее метаанализ. Становится возможным выявлять статистически важные зависимости между особенностями проведения эксперимента и отклонением результатов анализа от ожидаемых. Также появляется возможность выявлять особенности работы алгоритмов для их дальнейшей модификации под

определённые условия. Все это позволяет не только определять систематические погрешности, но и проводить достаточно точную калибровку параметров процедур анализа, а также определять границы применимости различных алгоритмов. В конечном итоге становится проще формулировать точные выводы и углублять интерпретацию полученных результатов.

Выводы

Разработанная методика и ее программная реализация с использованием технологий облачного хранения и анализа данных решает задачи стандартизации результатов обработки, автоматизацию процессов работы с данными и централизацию хранения данных и результатов их

обработки. Разработанная система позволяет эффективно хранить и управлять большими объемами неоднородной информации, обеспечивает ее сохранность и безопасный доступ. Все это повышает воспроизводимость, качество и скорость научных исследований в области ранней диагностики ишемии миокарда.

Список литературы

1. 2019 ESC Guidelines for the diagnosis and management of chronic coronary syndromes / J. Knuuti, W. Wijns, S. Achenbach [et al.] // *European Heart Journal*. 2020. Vol. 41, N 3. P. 407–477. <https://doi.org/10.1093/eurheartj/ehz425>.
2. Revisiting the diagnostic and prognostic significance of high-frequency QRS analysis in cardiovascular diseases: a comprehensive review / S. Qiu, T. Liu, Z. Zhan, X. Li, X. Liu, X. Xin [et al.] // *Postgraduate Medical Journal*. 2024. Vol. 100, N 1189. P. 785–795. <https://doi.org/10.1093/postmj/qgae064>.
3. Berbari E. J. High-resolution electrocardiography // *Critical Reviews in Biomedical Engineering*. 1988. Vol. 16, N 1. P. 67–103. PMID: 3293914.
4. Accuracy of advanced versus strictly conventional 12-lead ECG for detection and screening of coronary artery disease, left ventricular hypertrophy and left ventricular systolic dysfunction / T. T. Schlegel, W. B. Kulecz, A. H. Feiveson [et al.] // *BMC Cardiovascular Disorders*. 2010. Vol. 10. P. 28. <https://doi.org/10.1186/1471-2261-10-28>.
5. Amit G., Granot Y., Abboud S. Quantifying QRS changes during myocardial ischemia: Insights from high frequency electrocardiography // *Journal of Electrocardiology*. 2014. Vol. 47, N 4. P. 505–511. <https://doi.org/10.1016/j.jelectrocard.2014.03.006>.
6. Ultra-High-Resolution Electrocardiography Enables Earlier Detection of Transmural and Subendocardial Myocardial Ischemia Compared to Conventional Electrocardiography / K. V. Zaichenko, A. A. Kordyukova, D. L. Sonin, M. M. Galagudza // *Diagnostics*. 2023. Vol. 13, N 17. P. 2795. <https://doi.org/10.3390/diagnostics13172795>.
7. The FAIR Guiding Principles for scientific data management and stewardship / M. D. Wilkinson, M. Dumontier, I. J. Aalbersberg, G. Appleton, M. Axton, A. Baak [et al.] // *Scientific Data*. 2016. Vol. 6, N 1. P. 1–9. <https://doi.org/10.1038/sdata.2016.18>.
8. The practical implementation of artificial intelligence technologies in medicine / J. He, S. L. Baxter, J. Xu, J. Xu, X. Zhou, K. Zhang // *Nature Medicine*. 2019. Vol. 25, N 1. P. 30–36. <https://doi.org/10.1038/s41591-018-0307-0>.
9. Ioannidis J. P. A., Khoury M. J. Evidence-based medicine and big genomic data // *Human Molecular Genetics*. 2018. Vol. 27, N R1. P. R2–R7. <https://doi.org/10.1093/hmg/ddy065>.
10. Cunha-Oliveira T., Ioannidis J. P. A., Oliveira P. J. Best practices for data management and sharing in experimental biomedical research // *Physiological Reviews*. 2024. Vol. 104, N 3. P. 1387–1408. <https://doi.org/10.1152/physrev.00043.2023>.

11. Kunda D., Phiri H. Comparative Study of NoSQL and Relational Database // *Zambia ICT Journal*. 2017. Vol. 1, N 1. P. 1–4. <https://doi.org/10.33260/zictjournal.v1i1.8>.
12. MongoDB in Action / K. Banker, P. Bakkum, S. Verch, D. Garrett, T. Hawkins. 2nd ed. Shelter Island; New York: Manning Publications, 2016. 480 p.
13. Thakker F., Patel R. Cloud-based Lead-I ECG Feature Extraction and One-Class SVM Classification with MongoDB Storage for Accurate Detection of Tachycardia, SR, and ST Depression // *International Journal of Computer Applications*. 2025. Vol. 187, N 63. P. 19–25. <https://doi.org/10.5120/ijca2025926038>.
14. Application of Modern Methods of Determining Characteristic Points of an Electrocardiogram for Ultra-high Resolution Electrocardiosignals / K. V. Zaichenko, A. A. Afanasenko, E. A. Denisova [et al.] // 2024 X International Conference on Information Technology and Nanotechnology (ITNT). IEEE, 2024. P. 1–4. <https://doi.org/10.1109/ITNT60778.2024.10582322>.
15. Zaichenko K. V., Afanasenko A. S., Shevyakov D. O. Application of synchronous capture for ultra-high resolution electrocardiography // *Biomedical Engineering*. 2024. Vol. 57. P. 350–352. <https://doi.org/10.1007/s10527-023-10332-5>.

References

1. Knuuti J., Wijns W., Achenbach S., et al. 2019 ESC Guidelines for the diagnosis and management of chronic coronary syndromes. *European Heart Journal*. 2020;41(3):407-477. <https://doi.org/10.1093/eurheartj/ehz425>.
2. Qiu S., Liu T., Zhan Z., Li X., Liu X., Xin X., et al. Revisiting the diagnostic and prognostic significance of high-frequency QRS analysis in cardiovascular diseases: a comprehensive review. *Postgraduate Medical Journal*. 2024;100(1189):785-795. <https://doi.org/10.1093/postmj/qgae064>.
3. Berbari E.J. High-resolution electrocardiography. *Critical Reviews in Biomedical Engineering*. 1988;16(1):67-103. PMID: 3293914.
4. Schlegel T.T., Kulecz W.B., Feiveson A.H., et al. Accuracy of advanced versus strictly conventional 12-lead ECG for detection and screening of coronary artery disease, left ventricular hypertrophy and left ventricular systolic dysfunction. *BMC Cardiovascular Disorders*. 2010;10:28. <https://doi.org/10.1186/1471-2261-10-28>.
5. Amit G., Granot Y., Abboud S. Quantifying QRS changes during myocardial ischemia: Insights from high frequency electrocardiography. *Journal of Electrocardiology*. 2014;47(4):505-511. <https://doi.org/10.1016/j.jelectrocard.2014.03.006>.
6. Zaichenko K.V., Kordyukova A.A., Sonin D.L., Galagudza M.M. Ultra-High-Resolution Electrocardiography Enables Earlier Detection of Transmural and Subendocardial Myocardial Ischemia Compared to Conventional Electrocardiography. *Diagnostics*. 2023;13(17):2795. <https://doi.org/10.3390/diagnostics13172795>.
7. Wilkinson M.D., Dumontier M., Aalbersberg I.J., et al. The FAIR Guiding Principles for scientific data management and stewardship. *Scientific Data*. 2016;6(1):1–9. <https://doi.org/10.1038/sdata.2016.18>.
8. He J., Baxter S.L., Xu J., Xu J., Zhou X., Zhang K. The practical implementation of artificial intelligence technologies in medicine. *Nature Medicine*. 2019;25(1):30-36. <https://doi.org/10.1038/s41591-018-0307-0>.

9. Ioannidis J.P.A, Khoury M.J. Evidence-based medicine and big genomic data. *Human Molecular Genetics*. 2018;27(R1):R2-R7. <https://doi.org/10.1093/hmg/ddy065>.
10. Cunha-Oliveira T., Ioannidis J.P.A, Oliveira P.J. Best practices for data management and sharing in experimental biomedical research. *Physiological Reviews*. 2024;104(3):1387-1408. <https://doi.org/10.1152/physrev.00043.2023>.
11. Kunda D., Phiri H. Comparative Study of NoSQL and Relational Database. *Zambia ICT Journal*. 2017;1(1):1-4. <https://doi.org/10.33260/zictjournal.v1i1.8>.
12. Banker K., Bakkum P., Verch S., Garrett D., Hawkins T. MongoDB in Action. 2nd ed. Shelter Island, New York: Manning Publications; 2016. 480 p.
13. Thakker F., Patel R. Cloud-based Lead-I ECG Feature Extraction and One-Class SVM Classification with MongoDB Storage for Accurate Detection of Tachycardia, SR, and ST Depression. *International Journal of Computer Applications*. 2025;187(63):19-25. <https://doi.org/10.5120/ijca2025926038>
14. Zaichenko K.V., Afanasenko A.A., Denisova E.A., Shevakov D.O., Logachev E.P. Application of Modern Methods of Determining Characteristic Points of an Electrocardiogram for Ultra-high Resolution Electrocardiosignals. In: *2024 X International Conference on Information Technology and Nanotechnology (ITNT)*. IEEE; 2024. P. 1–4. <https://doi.org/10.1109/ITNT60778.2024.10582322>.
15. Zaichenko K.V., Afanasenko A.S., Shevyakov D.O. Application of synchronous capture for ultra-high resolution electrocardiography. *Biomedical Engineering*. 2024;57:350-352. <https://doi.org/10.1007/s10527-023-10332-5>.

Информация об авторах / Information about the Authors

Шевяков Даниил Олегович, младший научный сотрудник лаборатории радио и оптоэлектронных приборов ранней диагностики заболеваний человека, Институт аналитического приборостроения Российской академии наук, г. Санкт-Петербург, Российская Федерация, e-mail: sevakovdaniil@gmail.com, ORCID: 0000-0001-5609-4091

Daniil O. Shevyakov, Research Assistant at the Laboratory of Radio and Optoelectronic Devices for Early Diagnosis of Human Diseases, Institute of Analytical Instrumentation of the Russian Academy of Sciences, Saint Petersburg, Russian Federation, e-mail: sevakovdaniil@gmail.com, ORCID: 0000-0001-5609-4091

Денисова Елена Артемовна, младший научный сотрудник лаборатории радио и оптоэлектронных приборов ранней диагностики заболеваний человека, Институт аналитического приборостроения Российской академии наук, г. Санкт-Петербург, Российская Федерация, e-mail: tiranderel@yandex.ru, ORCID: 0000-0003-0329-2881

Elena A. Denisova, Research Assistant at the Laboratory of Radio and Optoelectronic Devices for Early Diagnosis of Human Diseases, Institute of Analytical Instrumentation of the Russian Academy of Sciences, Saint Petersburg, Russian Federation, e-mail: tiranderel@yandex.ru, ORCID: 0000-0003-0329-2881

Кордюкова Анна Алексеевна, младший научный сотрудник лаборатории радио и оптоэлектронных приборов ранней диагностики заболеваний человека, Институт аналитического приборостроения Российской академии наук, г. Санкт-Петербург, Российская Федерация, e-mail: annygm00@mail.ru, ORCID: 0000-0002-6099-4276

Афанасенко Арсений Сергеевич, кандидат технических наук, доцент, старший научный сотрудник лаборатории радио и оптоэлектронных приборов ранней диагностики заболеваний человека, Институт аналитического приборостроения Российской академии наук, г. Санкт-Петербург, Российская Федерация, e-mail: ar.afanasenko@gmail.com, ORCID: 0009-0001-0859-9252

Гуревич Борис Симхович, доктор технических наук, главный научный сотрудник лаборатории радио и оптоэлектронных приборов ранней диагностики заболеваний человека, Институт аналитического приборостроения Российской академии наук, г. Санкт-Петербург, Российская Федерация, e-mail: bgurevich48@gmail.com, ORCID: 0000-0002-7520-7087

Anna A. Kordyukova, Research Assistant at the Laboratory of Radio and Optoelectronic Devices for Early Diagnosis of Human Diseases, Institute of Analytical Instrumentation of the Russian Academy of Sciences, Saint Petersburg, Russian Federation, e-mail: annygm00@mail.ru, ORCID: 0000-0002-6099-4276

Arseniy S. Afanasenko, Cand. Sci. (Engineering), Associate Professor, Senior Researcher at the Laboratory of Radio and Optoelectronic Devices for Early Diagnosis of Human Diseases, Institute of Analytical Instrumentation of the Russian Academy of Sciences, Saint Petersburg, Russian Federation, e-mail: ar.afanasenko@gmail.com, ORCID: 0009-0001-0859-9252

Boris S. Gurevich, Dr. Sci. (Engineering), Chief Researcher at the Laboratory of Radio and Optoelectronic Devices for Early Diagnosis of Human Diseases, Institute of Analytical Instrumentation of the Russian Academy of Sciences, Saint Petersburg, Russian Federation, e-mail: bgurevich48@gmail.com, ORCID: 0000-0002-7520-7087

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 ($\sin$, $\cos$, $\tg$ 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/>.