




ВРАЧ

И ИНФОРМАЦИОННЫЕ
ТЕХНОЛОГИИ

№1 2026

MEDICAL DOCTOR AND IT



ISSN 1811-0193
9 1771811019000 >



№1 2026

MEDICAL DOCTOR AND IT

Журнал включен в Перечень рецензируемых научных изданий ВАК по специальностям:

- 2.3.1. Системный анализ, управление и обработка информации (технические науки);
- 2.3.5. Математическое и программное обеспечение вычислительных систем, комплексов и компьютерных сетей (технические науки);
- 3.3.9. Медицинская информатика (биологические науки);
- 3.3.9. Медицинская информатика (медицинские науки).

The journal is included in the List of peer-reviewed scientific publications of the Higher Attestation Commission on specialties:

- 2.3.1. System analysis, management and information processing (technical sciences);
- 2.3.5. Mathematical and software support of computer systems, complexes and computer networks (technical sciences);
- 3.3.9. Medical Informatics (biological sciences);
- 3.3.9. Medical Informatics (medical sciences).

Журнал индексируется в базе данных Russian Science Citation Index (RSCI) на платформе Web of Science.

The journal is included in the Russian Science Citation Index (RSCI) database on the Web of Science platform.

ГЛАВНЫЙ РЕДАКТОР

Карпов О.Э., академик РАН, д.м.н., проф., генеральный директор ФГБУ «НМХЦ им. Н.И. Пирогова» Минздрава России, Москва, Россия

ПОЧЕТНЫЙ ГЛАВНЫЙ РЕДАКТОР

Стародубов В.И., академик РАН, д.м.н., проф., научный руководитель ФГБУ «ЦНИИОИЗ» Минздрава России, представитель России в Исполнительном Комитете ВОЗ, Москва, Россия

ЗАМЕСТИТЕЛИ ГЛАВНОГО РЕДАКТОРА

Зарубина Т.В., член-корреспондент РАН, д.м.н., проф., заведующая кафедрой медицинской кибернетики и информатики, ФГАОУ ВО РНИМУ им. Н.И. Пирогова Минздрава России, Москва, Россия

Гусев А.В., к.т.н., член экспертного совета Минздрава по вопросам использования ИКТ, старший научный сотрудник ФГБУ «ЦНИИОИЗ» Минздрава России, директор по развитию компании «К-Скай», Петрозаводск, Россия

ОТВЕТСТВЕННЫЙ СЕКРЕТАРЬ

Пулин А.А., к.м.н., заместитель генерального директора по научной и образовательной деятельности ФГБУ «НМХЦ им. Н.И. Пирогова» Минздрава России, Москва, Россия

РЕДАКЦИОННАЯ КОЛЛЕГИЯ

Андриков Д.А., к.т.н., доцент Инженерной Академии ФГАОУ ВО РУДН, директор компании «Иммерсмед», Москва, Россия

Владимирский А.В., д.м.н., заместитель директора по научной работе ГБУЗ «НПКЦ ДиТ ДЗМ», Москва, Россия

Грибова В.В., член-корреспондент РАН, д.т.н., заместитель директора по научной работе ФГБУ «Институт автоматизации и процессов управления» Дальневосточного отделения РАН, Владивосток, Россия

Гулиев Я.И., к.т.н., директор Исследовательского центра медицинской информатики ИПС РАН им. А.К. Айламазяна, Ярославль, Россия

Зингерман Б.В., руководитель направления цифровой медицины ИНВИТРО, Москва, Россия

Карась С.И., д.м.н., специалист отдела координации научной и образовательной деятельности НИИ кардиологии, Томский национальный исследовательский медицинский центр Российской академии наук, Томск, Россия

Лебедев Г.С., д.т.н., директор института цифровой медицины, заведующий кафедрой информационных и интернет технологий ФГАОУ ВО «Первый МГМУ им. И.М. Сеченова» Минздрава России, Москва, Россия

Неусыпин К.А., д.т.н., профессор, заведующий кафедрой системы автоматического управления МГТУ им. Н.Э. Баумана, Москва, Россия

Пролетарский А.В., д.т.н., профессор, декан факультета «Информатика и системы управления» МГТУ им. Н.Э. Баумана, Москва, Россия

Реброва О.Ю., д.м.н., профессор кафедры медицинской кибернетики и информатики, ФГАОУ ВО РНИМУ им. Н.И. Пирогова Минздрава России, Москва, Россия

Столбов А.П., д.т.н., профессор кафедры организации здравоохранения, медицинской статистики и информатики ФГАОУ ВО «Первый МГМУ им. И.М. Сеченова» Минздрава России, Москва, Россия

Храмов А.Е., член-корреспондент РАН, д.ф.м.н., профессор, руководитель Балтийского центра нейротехнологий и искусственного интеллекта Балтийского федерального университета им. И. Канта, Калининград, Россия

Шахгельдян К.И., д.т.н., директор Научно-образовательного центра «Искусственный интеллект» ФГБОУ ВО «Владивостокский государственный университет», Владивосток, Россия

Швырев С.Л., к.м.н. заместитель руководителя Регламентной службы федерального реестра НСИ ФГБУ ЦНИИОИЗ Минздрава России, Москва, Россия

ИНОСТРАННЫЕ ЧЛЕНЫ РЕДАКЦИОННОЙ КОЛЛЕГИИ:

Максименко В.А., д.ф.м.н., ведущий научный сотрудник Национального Университета Сингапура, Сингапур, Республика Сингапур

Писарчик А., к.б.н., проф., заведующий кафедрой вычислительной биологии, центр биомедицинских технологий, Мадридский технический университет, Мадрид, Испания

CHIEF EDITOR

Karpov O.E., Academician of the RAS, DSc, Prof., General Director of the Pirogov National Medical and Surgical Center, Moscow, Russia

HONORARY CHIEF EDITOR

Starodubov V.I., Academician of the RAS, DSc, Prof., Scientific Director of the FRIHOI of MoH of Russia, Representative of Russia in the WHO Executive Committee, Moscow, Russia

DEPUTY CHIEF EDITORS

Zarubina T.V., Corresponding Member of the RAS, DSc, Prof., Head of the Department of Medical Cybernetics and Informatics, Pirogov Russian National Research Medical University, Moscow, Russia

Gusev A.V., PhD, member of the expert council of the Ministry of Health on the use of ICT, Senior Researcher of the FRIHOI of MoH of Russia, development director of the K-Sky company, Petrozavodsk, Russia

MANAGING EDITOR

Pulin A.A., PhD, Deputy General Director for Science and Education Pirogov National Medical and Surgical Center, Moscow, Russia

EDITORIAL BOARD

Andrikov D.A., PhD, Associate Prof. of the Engineering Academy of the RUDN University, Director of Immersmed, Moscow, Russia

Vladimirsky A.V., DSc, Deputy Director for Research, Scientific and Practical Clinical Center for Diagnostics and Telemedicine Technologies Department of Health of the City of Moscow, Moscow, Russia

Gribova V.V., Corresponding Member of the RAS, DSc, Deputy Director for Research of the Federal State Budgetary Institution "Institute of Automation and Control Processes" of the Far Eastern Institute of the RAS Branch, Vladivostok, Russia

Guliev Ya.I., PhD, Director of the Research Center for Medical Informatics of the Institute of Applied Problems of the Russian Academy of Sciences named after A.K. Ailamazyan, Yaroslavl, Russia

Zingerman B.V., Head of Digital Medicine, INVITRO, Moscow, Russia

Karas S.I., Dr. Sci. (Med), Specialist at the Department for Research and Training Coordination, Cardiology Research Institute, Tomsk National Research Medical Centre of the Russian Academy of Sciences, Tomsk, Russia

Lebedev G.S. DSc, Director of The Digital Health Institute, Head of The Department of information and Internet technologies, I.M. Sechenov First Moscow State Medical University, Moscow, Russia

Neusypin K.A., DSc, Prof., Head of the Automatic Control Systems Dept., Bauman Moscow State Technical University, Moscow, Russia

Proletarsky A.V., DSc, Prof., Dean of the Informatics, and Control Systems Department, Bauman University, Moscow, Russia

Rebrova O.Yu., DSc, Prof. of the Department of Medical Cybernetics and Informatics, Pirogov Russian National Research Medical University, Moscow, Russia

Stolbov A.P., DSc, Prof. of the Department of Public Health Organization, Medical Statistics and Informatics of the Faculty of Professional Development of Doctors of the I.M. Sechenov First Moscow State Medical University, Moscow, Russia

Khramov A.E., Corresponding Member of the RAS, DSc, Prof., Head of Baltic Center for Neurotechnology and Artificial Intelligence, Immanuel Kant Baltic Federal University, Kaliningrad, Russia

Shakhgeldyan K.I., DSc, Director of the Scientific and Educational Center «Artificial Intelligence» Vladivostok State University, Vladivostok, Russia

Shvyrev S.L., PhD, Deputy Head of the Regulatory Service of the Federal Register of the FRIHOI of MoH of Russia, Moscow, Russia

FOREIGN MEMBERS OF THE EDITORIAL BOARD:

Maksimenko V.A., DSc, National University of Singapore, Singapore, Republic of Singapore

Pisarchik A., PhD, Prof., Head of Department of Computational Biology, Center of Biomedical Technologies, Technical University of Madrid, Spain

Издается с 2004 года.

Включен в перечень ВАК ведущих рецензируемых научных журналов и изданий, рекомендуемых для опубликования основных научных результатов диссертации на соискание ученой степени кандидата и доктора наук.

Читатели могут принять участие в обсуждении статей, опубликованных в журнале «Врач и информационные технологии», и направить актуальные вопросы в редакцию (vit-j@pirogov-center.ru).

Журнал зарегистрирован Министерством Российской Федерации по делам печати, телерадиовещания и средств массовых коммуникаций.

Товарный знак и название «Врач и информационные технологии» являются исключительной собственностью ФГБУ «НМХЦ им. Н.И. Пирогова» Минздрава России.

Авторы опубликованных материалов несут ответственность за подбор и точность приведенных фактов, цитат, статистических данных и прочих сведений, а также за то, что в материалах не содержится данных, не подлежащих открытой публикации.

Материалы рецензируются редакционной коллегией. Мнение редакции может не совпадать с мнением автора.

Перепечатка текстов без разрешения журнала «Врач и информационные технологии» запрещена. При цитировании материалов ссылка на журнал обязательна.

За содержание рекламы ответственность несет рекламодатель.

Учредитель — ФГБУ «НМХЦ им. Н.И. Пирогова» Минздрава России.
Издатель — ФГБУ «НМХЦ им. Н.И. Пирогова» Минздрава России.

Адрес редакции:

105203, г. Москва,
ул. Нижняя Первомайская, д. 70,
e-mail: vit-j@pirogov-center.ru.
Тел. +7 (499) 464-03-03.

Главный редактор:

Карпов О.Э., академик РАН,
д.м.н., проф.

Почетный главный редактор:

Стародубов В.И.,
академик РАН, д.м.н., проф.

Зам. главного редактора:

Зарубина Т.В., член-корреспондент РАН,
д.м.н., проф.

Гусев А.В., к.т.н.

Компьютерная верстка и дизайн:

Издательство Пироговского Центра.

Подписные индексы:

Каталог агентства «Роспечать» — 82615.

Отпечатано в типографии ООО «Вива-Стар»
г. Москва, ул. Электрозаводская, д. 20
www.vivastar.ru

Подписано в печать 16 марта 2026 г.

Общий тираж 1000 экз.

Распространяется бесплатно.

© Издательство Пироговского Центра

ОБЗОРЫ

Казаринова В.Е., Зинченко В.В., Ковальчук А.Ю., Ахмад Е.С., Памова А.П., Арзамасов К.М., Омелянская О.В., Владзимирский А.В.
**ПЕРСПЕКТИВЫ ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА
ДЛЯ ВЫЯВЛЕНИЯ SPINA BIFIDA У ПЛОДА, ДЕТЕЙ И ВЗРОСЛЫХ.....** **6**

Гаранин А.А., Рубаненко О.А., Трусов Ю.А., Сенюшкин Д.В., Колсанов А.В.
**АСПЕКТЫ ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА
ДЛЯ СКРИНИНГА И ДИАГНОСТИКИ ЗАБОЛЕВАНИЙ:
НАРРАТИВНЫЙ ОБЗОР** **22**

Кобякова О.С., Канев А.Ф., Куракова Н.Г., Кармина Р.Л.
**ВЛИЯНИЕ ЦИФРОВИЗАЦИИ НА ПРОФЕССИОНАЛЬНЫЙ
ЛАНДШАФТ МЕДИЦИНСКОЙ ОТРАСЛИ: ПОТРЕБНОСТИ
РЫНКА ТРУДА И ПЕРСПЕКТИВЫ РАЗВИТИЯ
(АНАЛИЗ ЗАРУБЕЖНОГО ОПЫТА)** **38**

ОРИГИНАЛЬНЫЕ ИССЛЕДОВАНИЯ

Васильев Ю.А., Галкин В.Н., Раводин Р.А., Нанова О.Г., Савин Н.А., Блохин И.А., Мынко О.И., Владзимирский А.В., Омелянская О.В.
**ИССЛЕДОВАНИЕ ТОЧНОСТИ МЕДИЦИНСКОГО ИЗДЕЛИЯ
«ПРОРОДИНКИ» ДЛЯ ДИАГНОСТИКИ БАЗАЛЬНОКЛЕТОЧНОЙ
КАРЦИНОМЫ** **52**

Каширина И.Л., Старичкова Ю.В., Ле Ч.К.
**ТОНКАЯ НАСТРОЙКА ЯЗЫКОВОЙ МОДЕЛИ RUBERT
ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ АНАЛИЗА
МЕДИЦИНСКИХ ЗАПРОСОВ** **64**

Кремнева Е.И., Семенов Д.С., Сморгочкова А.К., Хоружая А.Н., Кулиговский Д.В., Адамия Н.Д., Ерижкоков Р.А., Омелянская О.В., Владзимирский А.В., Васильев Ю.А.
**ОЦЕНКА ЭФФЕКТИВНОСТИ ПРИМЕНЕНИЯ ПРОГРАММНОГО
ОБЕСПЕЧЕНИЯ ДЛЯ СУБТРАКЦИИ MOSMEDREG
В ДИАГНОСТИКЕ РАССЕЯННОГО СКЛЕРОЗА ПО ДАННЫМ
МАГНИТНО-РЕЗОНАНСНОЙ ТОМОГРАФИИ** **74**

Зуков Р.А., Комиссарова В.А., Данилин Т.А., Сафонцев И.П.
**СРАВНИТЕЛЬНЫЙ АНАЛИЗ ИСПОЛЬЗОВАНИЯ СИСТЕМ
ПОДДЕРЖКИ ПРИНЯТИЯ ВРАЧЕБНЫХ РЕШЕНИЙ
ПРИ АНАЛИЗЕ МАММОГРАФИЧЕСКИХ ИССЛЕДОВАНИЙ
В КРАСНОЯРСКОМ КРАЕ.....** **90**

REVIEWS

Kazarinova V.E., Zinchenko V.V., Kovalchuk A.Y., Akhmad E.S., Pamova A.P., Arzamasov K.M., Omelyanskaya O.V., Vladzimirskyy A.V.
PROSPECTS FOR USING ARTIFICIAL INTELLIGENCE TO DETECT SPINA BIFIDA IN FETUSES, CHILDREN, AND ADULTS..... 6

Garanin A.A., Rubanenko O.A., Trusov Yu.A., Senyushkin D.V., Kolsanov A.V.
ASPECTS OF THE USE OF ARTIFICIAL INTELLIGENCE FOR DISEASE SCREENING AND DIAGNOSIS: A NARRATIVE REVIEW 22

Kobyakova O.S., Kanev A.F., Kurakova N.G. Karmina R.L.
THE IMPACT OF DIGITALIZATION ON THE PROFESSIONAL LANDSCAPE OF THE MEDICAL INDUSTRY: LABOR MARKET NEEDS AND DEVELOPMENT PROSPECTS (ANALYSIS OF FOREIGN EXPERIENCE)..... 38

ORIGINAL RESEARCH

Vasilev Yu.A., Galkin V.N., Ravodin R.A., Nanova O.G., Savin N.A., Blokhin I.A., Mynko O.I., Vladzimirskyy A.V., Omelyanskaya O.V.
DIAGNOSTIC ACCURACY OF THE PRORODINKI MEDICAL DEVICE FOR BASAL CELL CARCINOMA..... 52

Kashirina I.L., Starichkova Yu.V., Le T.K.
FINE-TUNING THE RUBERT LANGUAGE MODEL TO IMPROVE THE ACCURACY OF MEDICAL QUERY ANALYSIS..... 64

Kremneva E.I., Semenov D.S., Smorchkova A.K., Khoruzhaya A.N., Kuligovskiy D.V., Adamia N.D., Erizhokov R.A., Omelyanskaya O.V., Vladzimirskyy A.V., Vasilev Yu.A.
MOSMEDREG SUBTRACTION SOFTWARE EFFECTIVENESS IN MULTIPLE SCLEROSIS DIAGNOSIS USING MAGNETIC RESONANCE IMAGING DATA 74

Zukov R.A., Komissarova V.A., Danilin T.A., Safontsev I.P.
COMPARATIVE ANALYSIS OF THE USE OF MEDICAL DECISION SUPPORT SYSTEMS IN THE ANALYSIS OF MAMMOGRAPHIC STUDIES IN THE KRASNOYARSK REGION..... 90

MEDICAL DOCTOR AND INFORMATION TECHNOLOGIES

Registration certificate
 PI No. FS77-80906 dated April 09, 2021

Published since 2004.

This journal is included in the list of the Higher Attestation Commission, detailing leading peer-reviewed scientific journals and publications recommended for publishing the foremost scientific results of dissertations for the degree of candidate and doctor of sciences.

Readers may take part in the discussion of articles published in the journal «Medical Doctor and Information Technologies», and send topical questions to the editorial office (vit-j@pirogov-center.ru).

The journal is registered by the Ministry of the Russian Federation for Press, TV and Radio Broadcasting, and Mass Media. The trademark and name «Medical Doctor and Information Technologies» are the exclusive property of the Pirogov National Medical and Surgical Center.

The authors of the published materials are responsible for the selection and accuracy of the facts, quotes, statistical data and other information, as well as ensuring that the materials do not contain data that is not subject to open publication.

The materials are reviewed by the editorial board. Editorial opinion may not reflect the views of the author.

Reprinting of texts without the permission of the journal «Medical Doctor and Information Technologies» is prohibited. When citing materials, a reference to the journal is required.

The advertiser is responsible for the content of the advertisement.

Founder — Pirogov National Medical and Surgical Center.

Publisher — Pirogov National Medical and Surgical Center.

Editorial office address:

105203, Moscow, st. Nizhnaya Pervomayskaya, 70, e-mail: vit-j@pirogov-center.ru. +7(499) 464-03-03.

Chief Editor:

Karpov O.E., Academician of the Russian Academy of Sciences, Doctor of Medical Sciences, Prof.

Honorary chief editor:

Starodubov V.I., Academician of the Russian Academy of Sciences, Doctor of Medical Sciences, Prof.

Deputy chief editors:

Zarubina T.V., Corresponding Member of the Russian Academy of Sciences, Doctor of Medical Sciences, prof.

Gusev A.V., Ph.D.

DTP and design:

Pirogov Center Publishing House.

Subscription indexes:

Catalogue of the agency «Rospechat» — 82615.

Printed in the «Viva-Star» Moscow, st. Elektrozavodskaya, 20 www.vivastar.ru

Signed for printing on March 16, 2026.

Circulation 1000 copies.

Free distribution.

© Pirogov Center Publishing House

КАЗАРИНОВА В.Е.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: KazarinovaVE@zdrav.mos.ru;
ORCID ID: 0009-0001-3568-8138

ЗИНЧЕНКО В.В.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: ZinchenkoVV1@zdrav.mos.ru;
ORCID ID: 0000-0002-2307-725X

КОВАЛЬЧУК А.Ю.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: KovalchukAY2@zdrav.mos.ru;
ORCID ID: 0009-0006-7975-8974

АХМАД Е.С.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: AkhmadES@zdrav.mos.ru;
ORCID ID: 0000-0002-8235-9361

ПАМОВА А.П.,

к.м.н., ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: PamovaAP@zdrav.mos.ru;
ORCID ID: 0000-0002-0041-3281

АРЗАМАСОВ К.М.,

д.м.н., ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: ArzamasovKM@zdrav.mos.ru;
ORCID ID: 0000-0001-7786-0349

ОМЕЛЯНСКАЯ О.В.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: npcmr@zdrav.mos.ru;
ORCID ID: 0000-0002-0245-4431

ВЛАДИМИРСКИЙ А.В.,

д.м.н., ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: npcmr@zdrav.mos.ru;
ORCID ID: 0000-0002-2990-7736

ПЕРСПЕКТИВЫ ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ВЫЯВЛЕНИЯ SPINA BIFIDA У ПЛОДА, ДЕТЕЙ И ВЗРОСЛЫХ

DOI: 10.25881/18110193_2026_1_6

Аннотация. Актуальность и цель: Spina Bifida (SB) — это врожденный порок развития позвоночника, требующий своевременной диагностики. Цифровизация здравоохранения и стремительное развитие технологий искусственного интеллекта (ИИ) способствуют внедрению ИИ в различные области медицины, включая диагностику SB. Целью данного исследования является анализ потенциала применения ИИ для выявления признаков SB у плода, детей и взрослых, оценка существующих подходов, а также определение ключевых областей для дальнейших исследований и разработок.

Методы: в представленную обзорную работу включены оригинальные и обзорные публикации, материалы конференций с описанием применения алгоритмов ИИ к любым видам данных на любом из этапов исследования SB у плода, детей и взрослых. Поиск доступной литературы был произведен в базах данных: PubMed, Google Scholar и РИНЦ (eLibrary.ru).

Результаты: было отобрано 17 публикаций о применении ИИ в диагностике SB, удовлетворяющих критериям поиска. Выделены следующие виды данных, которые анализируются с использованием алгоритмов ИИ: данные медицинской визуализации (магнитно-резонансной томографии, ультразвукового исследования, рентгенографии, видеоуродинамики), данные лабораторной диагностики, генетическая информация.

Обсуждение: алгоритмы ИИ показали высокую эффективность в выявлении SB и ее осложнений на различных этапах диагностического процесса. Была продемонстрирована перспектива использования компьютерного зрения для выявления SB на изображениях различной модальности, алгоритмов машинного обучения в лабораторной диагностике и в генетических исследованиях.

Ключевые слова: Spina Bifida, диагностика, искусственный интеллект, машинное обучение.

Для цитирования: Казаринова В.Е., Зинченко В.В., Ковальчук А.Ю., Ахмад Е.С., Памова А.П., Арзамасов К.М., Омелянская О.В., Владимирский А.В. Перспективы применения искусственного интеллекта для выявления Spina Bifida у плода, детей и взрослых. Врач и информационные технологии. 2026; 1: 6-21. DOI: 10.25881/18110193_2026_1_6.

KAZARINOVA V.E.,

Moscow Center for Diagnostics & Telemedicine, Moscow, Russia; e-mail: KazarinovaVE@zdrav.mos.ru;
ORCID ID: 0009-0001-3568-8138

ZINCHENKO V.V.,

Moscow Center for Diagnostics & Telemedicine, Moscow, Russia; e-mail: ZinchenkoVV1@zdrav.mos.ru;
ORCID ID: 0000-0002-2307-725X

KOVALCHUK A.Y.,

Moscow Center for Diagnostics & Telemedicine, Moscow, Russia; e-mail: KovalchukAY2@zdrav.mos.ru;
ORCID ID: 0009-0006-7975-8974

AKHMAD E.S.,

Moscow Center for Diagnostics & Telemedicine, Moscow, Russia; e-mail: AkhmadES@zdrav.mos.ru;
ORCID ID: 0000-0002-8235-9361

PAMOVA A.P.,

PhD, Moscow Center for Diagnostics & Telemedicine, Moscow, Russia; e-mail: PamovaAP@zdrav.mos.ru;
ORCID ID: 0000-0002-0041-3281

ARZAMASOV K.M.,

DSc, Moscow Center for Diagnostics & Telemedicine, Moscow, Russia; e-mail: ArzamasovKM@zdrav.mos.ru;
ORCID ID: 0000-0001-7786-0349

OMELYANSKAYA O.V.,

Moscow Center for Diagnostics & Telemedicine, Moscow, Russia; e-mail: npcmr@zdrav.mos.ru;
ORCID ID: 0000-0002-0245-4431

VLADZYMYRSKYI A.V.,

DSc, Moscow Center for Diagnostics & Telemedicine, Moscow, Russia; e-mail: npcmr@zdrav.mos.ru;
ORCID ID: 0000-0002-2990-7736

PROSPECTS FOR USING ARTIFICIAL INTELLIGENCE TO DETECT SPINA BIFIDA IN FETUSES, CHILDREN, AND ADULTS

DOI: 10.25881/18110193_2026_1_6

Abstract. *Background and Objective:* Spina Bifida (SB) is a congenital spinal malformation requiring timely diagnosis. Digitalization of healthcare and rapid development of artificial intelligence technologies (AI) facilitate AI implementation in various fields of medicine, including SB diagnosis. The aim of this study is to analyze the potential of AI for detecting signs of Spina Bifida in fetuses, children, and adults, evaluate existing approaches, and identify key areas for further research and development.

Methods: this review includes original and review publications, conference materials describing the application of AI algorithms to any type of data at any stage of the diagnostic process of SB in fetuses, children, and adults. A search of available literature was conducted in the following databases: PubMed, Google Scholar, and the Russian Science Citation Index (eLibrary.ru).

Results: seventeen publications on the use of AI in the diagnosis of SB were selected, which met the search criteria. Using AI algorithms, the following types of data were identified and analyzed: medical imaging data (magnetic resonance imaging, ultrasound, X-ray, video urodynamics), laboratory diagnostics data, and genetic information.

Discussion: AI algorithms have shown high efficiency in detecting SB and its complications at various stages of the diagnostic process. The prospect of using computer vision to detect SB in images of various modalities as well as machine learning algorithms in laboratory diagnostics and genetic research was demonstrated.

Keywords: Spina Bifida; Diagnosis; Artificial Intelligence; Machine Learning.

For citation: Kazarinova V.E., Zinchenko V.V., Kovalchuk A.Y., Akhmad E.S., Pamova A.P., Arzamasov K.M., Omelyanskaya O.V., Vladzimirskyy A.V. Prospects for using artificial intelligence to detect Spina Bifida in fetuses, children, and adults. *Medical doctor and information technology.* 2026; 1: 6-21. DOI: 10.25881/18110193_2026_1_6.

ВВЕДЕНИЕ

Spina Bifida (SB) — это врожденный порок развития, относящийся к спинальному дизрафизму, при котором отмечается дефект развития позвоночника в результате нарушения закрытия эмбриональной нервной трубки [1]. Данный порок может проявляться в двух формах: Spina Bifida Occulta (SBO) — скрытая форма, представляет собой небольшие костные дефекты без формирования спинномозговой грыжи; и Spina Bifida Aperta (SBA) — открытая форма, представляет собой более серьезное состояние, при котором через имеющийся дефект позвоночника наблюдается пролабирование содержимого спинномозгового канала [2, 3].

Этиология возникновения SB в процессе эмбрионального развития до конца не известна. Несмотря на значительное снижение распространенности SB в странах с обязательным обогащением зерновых фолиевой кислотой до 0,2–0,4 случаев на 1000 рождений, в некоторых регионах мира заболеваемость остается высокой, достигая 4–8 случаев на 1000 рождений [4].

Врожденные аномалии позвоночника представляют собой серьезную проблему, требующую мультидисциплинарного подхода как в диагностике, так и в лечении [5]. Пренатальная диагностика SB играет ключевую роль в обеспечении своевременного и эффективного медицинского вмешательства [6] и включает два основных метода: пренатальное биохимическое обследование (анализ уровня альфа-фетопротеина и ацетилхолинэстеразы) и пренатальное ультразвуковое обследование (УЗИ). Точность УЗИ зависит от опыта врача и положения плода [7, 8]. С развитием нейронных сетей было предложено множество алгоритмов искусственного интеллекта (ИИ) для выделения признаков различных патологий плода на ультразвуковых изображениях, но в обработке ультразвуковых изображений плода с SB все еще существует пробел [9].

Диагностика SB у взрослых также является актуальной проблемой по причине того, что некоторые осложнения могут проявиться только во взрослом возрасте, и ранняя диагностика позволяет своевременно принять меры для их предотвращения [10]. В большей степени это касается SBO, основным методом первичной диагностики которой является рентгенография

(РГ) с последующим подтверждением диагноза с помощью магнитно-резонансной томографии (МРТ) или компьютерной томографии (КТ).

Пороки развития спинного мозга часто сочетаются с нарушениями формирования органов малого таза, деформациями конечностей, а также аномалиями развития центральной нервной системы [11]. Важный этап обследования пациентов со SB — это выявление сопутствующих патологий и осложнений.

Таким образом, целью данного исследования является анализ потенциала применения ИИ для диагностики SB у плода, детей и взрослых, обзор существующих подходов, а также определение ключевых областей для дальнейших исследований и разработок.

МАТЕРИАЛЫ И МЕТОДЫ

Критерии включения/исключения исследований

Критерии включения:

В исследование включались оригинальные и обзорные статьи, материалы конференций, опубликованные на английском или русском языках, которые описывают использование алгоритмов машинного обучения к любым видам данных на любом из этапов диагностики SB у плода, детей и взрослых. Были включены работы, опубликованные не более 5 лет назад и находящиеся в открытом доступе либо имеющие подробное описание технологии ИИ в резюме статьи.

Критерии исключения:

Из данного обзорного исследования были исключены публикации, не соответствующие теме применения технологий ИИ в диагностике SB у плода, детей и взрослых, а также находящиеся в закрытом доступе и не имеющие подробного описания технологии в аннотации.

Ключевые слова для поиска

Для поиска литературы согласно вопросу исследования были использованы ключевые слова, указанные в таблице 1.

Анализ литературы

Поиск литературы был произведен по базам данных PubMed, Google Scholar и РИНЦ (eLibrary.ru). Найденные публикации были

Таблица 1 – Ключевые слова для поиска литературы

№	База данных	Строка поиска
1	PubMed	((spina bifida[Title/Abstract] OR meningocele[Title/Abstract] OR lipomenigocele[Title/Abstract] OR myelomenigocele[Title/Abstract])) OR (Spina Bifida Occulta[MeSH Terms])
2		"Artificial Intelligence"[Title/Abstract] OR "Machine Learning"[Title/Abstract] OR "Deep Learning"[Title/Abstract] OR "Neural Network"[Title/Abstract] OR "Computer Assisted Diagnosis"[Title/Abstract] OR "Medical Informatics"[Title/Abstract] OR "RNN"[Title/Abstract] OR "CNN"[Title/Abstract] OR "Random Forest"[Title/Abstract] OR "SVM"[Title/Abstract] OR "Support vector machine"[Title/Abstract] OR AI[Title/Abstract] OR Algorithms[MeSH Terms]
3		#1 AND #2
4	Google Scholar	(spina bifida OR meningocele OR lipomenigocele OR myelomenigocele) AND («Artificial Intelligence» OR «Machine Learning» OR «Deep Learning» OR «Neural Network» OR «Computer Assisted Diagnosis» OR «Medical Informatics» OR «RNN» OR «Random Forest» OR «SVM» OR «Support vector machine» OR AI)
5	РИНЦ	spina bifida И («машинное обучение» ИЛИ «искусственный интеллект»)

объединены в одну базу, удалены дубликаты. Далее был проведен скрининг работ по информации из названия публикации и краткого абстракта на предмет решения о включении/исключении публикации из дальнейшего рассмотрения. Были выделены следующие группы научных работ: основные работы, содержащие оригинальное исследование применения любых алгоритмов машинного обучения в области диагностики СВ и сопутствующих патологий у плода, детей и взрослых; дополнительные — публикации, включающие описание данных, используемых в решении описываемой проблемы, однако напрямую не связанные с

применением ИИ. Основные включенные публикации были сгруппированы и проанализированы в виде таблицы со следующими столбцами: ссылка, вид данных, вид алгоритма, задача ИИ, метрики, направления дальнейшего исследования. Отдельно были проанализированы дополнительные материалы для выявления перспектив применения ИИ в области диагностики и лечения СВ у пациентов.

РЕЗУЛЬТАТЫ

В базе данных PubMed по ключевым словам было найдено 28 публикаций, в Google Scholar — 46, в РИНЦ — 0. На рисунке 1



Рисунок 1 – Схема сбора исследований.

представлена схема отбора исследований. После исключения нерелевантных литературных источников суммарно анализ был произведен по 34 публикациям, которые были разделены на 2 группы: 17 исследований из основной группы и 17 исследований из дополнительной группы.

Исследования из основной группы были проанализированы в таблице 2. Работы были сгруппированы по данным, которые используются в решении задач ИИ, а именно по данным медицинской визуализации (МРТ, УЗИ, РГ,

видеоуродинамика), данным лабораторной диагностики, генетической информации. Публикациям с одними и теми же авторами, Mufti N. и др. и Cengizler C. и др., было дано одно описание, т.к. предположительно опубликованные работы освещают одну группу исследований, и рассмотрение данных работ по отдельности не даст дополнительного вклада в достижение заявленной цели исследования.

Дополнительная группа исследований была проанализирована в таблице 3.

Таблица 2 – Анализ статей, включенных в основную группу исследований

Ссылка	Вид данных	Вид алгоритма	Задача ИИ	Метрики	Направления дальнейшего исследования
Mufti et al. [12, 13]	МРТ-изображения	Нейронная сеть	Сегментировать структуры головного мозга плода для анализа морфологических изменений, возникающих в результате пренатальной операции по закрытию SB	–	Тестирование моделей более высокого порядка, увеличение набора данных
Ebner et al. [14]	МРТ-изображения	Нейронная сеть	Выполнить реконструкцию головного мозга плода	Коэффициент Дайса 0,939	Исследование эффективности разработки на других МРТ-сканерах
Trigui et al. [15]	МРТ-изображения	Метод опорных векторов, алгоритм случайного леса	Сегментировать и классифицировать стенки мочевого пузыря	Коэффициент Дайса 0,826, точность 94,4%, чувствительность 94,74%, специфичность 94,12%, прогностическая ценность положительного результата (ПЦПР) 94,74%	Увеличение набора данных, исследование новых 3D-текстурных признаков
Cengizler et al. [16, 17]	УЗИ	Генетические алгоритмы	Локализовать позвоночный столб плода, объединить костные области в группы	F-мера до 1,000 на отдельных примерах	Увеличение набора данных, оптимизация параметров функции, усовершенствование этапа сегментации алгоритма
Asha et al. [18, 19]	УЗИ	Нейронная сеть	Выявить наличие или отсутствие SB у плода	Точность обнаружения 97,8%, точность сегментации 96% по пикселям, точность классификации 96,5%	Увеличение набора данных, внешняя валидация разработки
Henry O.A. et al. [20]	УЗИ	Нейронная сеть	Диагностировать SB плода	DBN: ПЦПР 97%, точность 97%, F1-мера 98%, чувствительность 99%. U-Net: ПЦПР 93%, точность 91%, F1-мера 95%, чувствительность 96%. ResNet: ПЦПР 96%, точность 94%, F1-мера 96%, чувствительность 96%.	Внешняя валидация разработки
Chen et al. [21]	УЗИ	Нейронная сеть	Диагностировать SB плода	Чувствительность 0,93, ПЦПР 0,96, точность по пикселям 0,949, среднее пересечение по объединению 0,917	Увеличение набора данных, внешняя валидация
Duran et al. [22]	РГ пояснично-крестцового отдела позвоночника	Нейронная сеть	Диагностировать SBO	Точность 85,5%, чувствительность 80,8%, специфичность 89,7%, ПЦПР 87,5%, F1-мера 84%, площадь под ROC-кривой (AUC ROC) 0,92.	Увеличение набора данных, внешняя валидация

**Таблица 2 – Анализ статей, включенных в основную группу исследований
(продолжение)**

Ссылка	Вид данных	Вид алгоритма	Задача ИИ	Метрики	Направления дальнейшего исследования
Weaver J.K. et al. [23]	Данные уродинамических и РГ исследований	Алгоритм случайного леса, нейронная сеть	Классифицировать степень тяжести дисфункции мочевого пузыря	Точность 70%, взвешенная каппа 0,54 (умеренное согласие)	Внешняя валидация алгоритма
Hobbs et al. [24]	Данные уродинамических исследований	Метод опорных векторов, метод k-ближайших соседей	Выявить признаки гиперактивности детрузора	Временная модель с тремя каналами: AUC ROC 91,9 ± 1,3%; чувствительность 84,2 ± 3,8%; специфичность 86,4 ± 1,3%. Трехканальная модель на основе частоты: AUC ROC 90,5 ± 1,9%; чувствительность 68,3 ± 5,3%; специфичность 92,9 ± 1,1%	Использование большего количества параметров в алгоритме, внешняя валидация
Fazelinia et al. [25]	Образцы мочи	Алгоритмы машинного обучения	Дифференцировать пациентов со SB с высоким риском развития почечных осложнений, связанных с нейрогенным мочевым пузырем	–	Увеличение набора данных, внешняя валидация
Karthik et al. [26]	Генетическая информация	Логистическая регрессия, дерево решений, метод опорных векторов, случайный лес, метод k-ближайших соседей	Выявить ключевые гены, связанные со SB	Логистическая регрессия: точность 0,8667, AUC ROC 0,90. Метод k-ближайших соседей: точность 0,80, AUC ROC 0,95.	Дальнейшие исследования генома человека
Takeda [27]	Генетическая информация	Алгоритм случайного леса	Прогнозировать патогенность несинонимичных однонуклеотидных вариантов (nsSNV)	AUC ROC 0,941, AUC PR (precision-recall curve) 0,957, чувствительность 0,942, специфичность 0,848	Увеличение количества исследуемых nsSNV
Wolujewicz et al. [28]	Генетическая информация	Нейронная сеть	Определить геномные регуляторные сигнатуры, лежащие в основе патофизиологии SB	–	Дальнейшие исследования генома человека

Таблица 3 – Анализ работ из дополнительной группы исследований

Ссылка	Перспективы возможного применения ИИ
McKernan et al. [29]	Выявление особенностей, которые влияют на вариативность базовых навыков передвижения в инвалидной коляске и изменения в навыках передвижения с течением времени у пациентов с SB
Punchak et al. [30]	Прогнозирование развития синдрома фиксированного спинного мозга после первичного хирургического вмешательства
Chao et al. [31]	Пренатальная дифференциальная диагностика патологий позвоночника по данным УЗИ, МРТ, КТ
Benjamin et al. [32]	Поиск взаимосвязи между врожденными дефектами по данным реестров
Pollenus et al. [33]	Предсказание влияния аномалий головного мозга на когнитивные способности пациентов с SB
Hebert et al. [34]	Генетический анализ и выявление паттернов для предсказания развития SB
Aguiar-Pulido et al. [35]	Анализ генома человека для поиска ключевых механизмов, повышающих риск возникновения SB
Beltran Ale et al. [36], Gunnnett et al. [37]	Предсказание развития нарушения дыхания во сне у пациентов с SB

Таблица 3 – Анализ работ из дополнительной группы исследований (продолжение)

Ссылка	Перспективы возможного применения ИИ
Rethlefsen et al. [38]	Предсказание ежедневной двигательной активности (ходьбы) пациентов с SB в зависимости от нейросегментарного и функционального уровней поражения
Pruthi et al. [39], Sanz Cortes et al. [40]	Предсказание исхода пренатальной операции при SB у плода
McLaughlin et al. [41]	Маршрутизация пациентов и отслеживание в медицинской информационной системе
Weaver et al. [42]	Прогнозирование ухудшения функции почек с помощью уродинамического исследования
Uy et al. [43]	Изучение генетической основы возникновения SB
Trigo et al. [44]	Прогнозирование изменений аномалий центральной нервной системы после пренатального хирургического вмешательства по закрытию SB на основе анализа МРТ-изображений
Zoghi et al. [45]	Прогнозирование исхода хирургического лечения SB

ПРИМЕНЕНИЕ ИИ В МЕДИЦИНСКОЙ ВИЗУАЛИЗАЦИИ SB

1. МРТ

МРТ играет ключевую роль в постановке диагноза SB как у плода, так и у взрослых и детей, а также позволяет выявить сопутствующие патологии головного мозга (ГМ) — мальформацию Киари II, гидроцефалию и другие. По этой причине МРТ-изображения широко используются в разработках программного обеспечения (ПО) на основе технологий ИИ для выявления SB и сопутствующих заболеваний.

В работах [12–13] авторы использовали МРТ-изображения ГМ плода до и после пренатальной операции по закрытию SBA. Определялись объем и площадь поверхности ГМ, мозжечка и желудочков, а также оценивалась гирификация (степень извилистости) коры. Для автоматической первичной сегментации структур ГМ был использован метод глубокого обучения на основе свёрточных нейронных сетей (Convolutional Neural Networks, CNN). Авторы подчеркивают, что улучшение понимания траектории развития ГМ после пренатальной операции по закрытию SBA является важным аспектом для составления плана лечения пациентов.

В исследовании [14] рассмотрена проблема движения плода во время проведения МРТ, что приводит к смещению на изображении анатомических структур между срезами и невозможности качественной диагностики SBA и

ее осложнений. Авторы предлагают решение — автоматическую систему реконструкции мозга плода и автоматическую коррекцию артефактов движения. В представленном алгоритме для реконструкции ГМ плода на МРТ-изображениях используется локализация и сегментация ГМ моделями на основе глубокого обучения (каскадные CNN с 3D U-Net, ResNet и т.д.). Результаты реконструкции, полученные с помощью использованных нейросетей, выгодно отличаются от результатов, полученных при ручной, трудоёмкой сегментации мозга. В дальнейшем авторы планируют исследовать применимость сочетания этих алгоритмов на еще более широком диапазоне параметров МРТ-изображений в зависимости от периода гестации.

В исследовании [15] внимание было сконцентрировано на одном из самых частых осложнений SB у взрослых пациентов — нейрогенной дисфункции мочевого пузыря. Была разработана автоматизированная система компьютерной диагностики: сегментация и классификация стенок мочевого пузыря у взрослых и детей с SB на T2-взвешенных МРТ-изображениях. В работе использовались метод опорных векторов (Support Vector Machine, SVM) и алгоритм случайного леса (Random Forest, RF). Обнаружено, что применительно к этой задаче SVM превосходит классификатор RF при использовании алгоритма оптимизации Grey Wolf Optimizer и ядра радиальной базисной функции. Точность классификации составила 94,4%, чувствительность

94,74%, специфичность 94,12%. Планируется тестирование разработки на большем наборе данных, а также доработка предложенной системы диагностики.

2. УЗИ

Следующей областью медицинской визуализации, где активно ведутся разработки для диагностики SBA с применением ИИ, является УЗИ.

Публикации [16-17] посвящены автоматизированному поиску костей позвоночника плода при УЗИ. В работах ультразвуковое изображение автоматически делится на столбцы и определяются области костей, относящиеся к позвоночнику. Авторы предполагают, что разработанный метод, способный отличать кости позвоночника от других даже при наличии серьезных морфологических дефектов, является первым шагом на пути к созданию диагностической модели.

Asha R., Subashka Ramesh S.S. в исследованиях [18-19] предлагают модели на основе глубокого обучения для сегментации и классификации SB плода на ультразвуковых изображениях. В работе [18] модифицированная сверточная нейронная сеть Faster Region (Modified FRCNN-CO) применялась для классификации изображений с наличием и отсутствием SB у плода. В качестве исходных данных использовались 242 ультразвуковых изображения позвоночника плода, полученных на 18-й неделе гестации. Точность обнаружения составила 97,8%. В работе [19] две модели глубокого обучения (DED и FMDDCN) были усовершенствованы для сегментации и классификации УЗ-изображений позвоночника плода на нормальные и патологические. Участницами этого исследования стали 300 женщин, которым на 23-31 неделе гестации было проведено 3D-УЗИ. Точность сегментации составила 96% по пикселям, а точность классификации 96,5%. Разработанный метод показал перспективность применения в медицинской практике для диагностики SB плода на трехмерных ультразвуковых изображениях. В дальнейших исследованиях авторы планируют тестирование модели на большем количестве пациентов.

В другом исследовании [20] для классификации УЗИ плода с наличием и с отсутствием SB применялись нейронные сети DBN, U-Net и ResNet. В работе для обучения и тестирования модели было получено около 6100

ультразвуковых изображений плода, из которых 80% имели патологию и 20% нет. Точность моделей составила 97%, 91% и 94% для DBN, U-Net и ResNet, соответственно.

Для того чтобы лучше идентифицировать изображения плода со SB в исследовании [21] была усовершенствована нейросеть U-Net — внедрена свертка Octave, в результате чего была получена новая нейросеть Oct-U-Net. Точность алгоритма составила 96%. В результате сравнительного анализа времени работы трех алгоритмов было установлено, что среднее время работы Oct-U-Net составило 12,15 секунды, что меньше, чем у FCN (fully convolutional network) и U-Net ($p < 0,05$). Таким образом, по мнению авторов Oct-U-Net может эффективно сократить время и повысить точность сегментации.

3. Рентгенограммы

В исследовании [22] представлена разработка, основанная на использовании рентгенологических исследований, которая поможет врачам в выявлении SBO. Для обнаружения объектов использовалась нейронная сеть YOLO, для классификации объектов применялся метод трансферного обучения с использованием предварительно обученных сетей VGG-19, ResNet-101, MobileNetV2 и GoogleNet. Исследование проводилось на РГ пояснично-крестцового отдела позвоночника в передне-задней проекции 160 пациентов с SBO (14 женщин, 146 мужчин) со средним возрастом 23,2 года и 206 здоровых людей (13 женщин, 193 мужчины) со средним возрастом 22,6 года. Предварительно обученная модель VGG-19 показала лучшие метрики: точность 85,5%, чувствительность 80,8%, специфичность 89,7%, ПЦПР 87,5%, F1-мера 84% и AUC ROC 0,92. Модель, пригодная для клинического использования, может быть разработана в дальнейших исследованиях с большим количеством рентгенограмм.

4. Видеоуродинамика

Как уже говорилось выше, одним из осложнений SB, с которым сталкиваются пациенты, является нейрогенная дисфункция мочевого пузыря. Поэтому в уродинамических исследованиях, являющихся золотым стандартом диагностики в функциональной урологии, также ведутся

разработки по применению ИИ. Цель изученной работы [23] состояла в разработке моделей глубокого обучения для категоризации тяжести дисфункции мочевого пузыря (отсутствующая/легкая, умеренная и тяжелая) по видеоуродинамическим и рентгенологическим исследованиям. Для обучения модели использовались данные пациентов в возрасте от 2 месяцев до 28 лет с SB. Были построены 4 модели для прогнозирования тяжести дисфункции мочевого пузыря. Точность и взвешенная каппа ансамблевой модели классификации дисфункции мочевого пузыря при достижении не менее 75% ожидаемой емкости мочевого пузыря составили 70% и 0,54 (умеренное согласие), соответственно.

В работе [24] авторы поставили целью оценить точность различных моделей машинного обучения при выявлении признаков гиперактивного мочевого пузыря. Данные были извлечены из 805 файлов видеоуродинамических исследований, полученных от 546 пациентов. Были изучены различные подходы к классификации, в том числе метод k-ближайших соседей и SVM с линейными, полиномиальными и радиально-базисными ядрами. Использование нескольких каналов и окон данных повысило производительность. Временная модель со всеми тремя каналами имела AUC ROC $91,9 \pm 1,3\%$; чувствительность $84,2 \pm 3,8\%$; специфичность $86,4 \pm 1,3\%$. Трехканальная модель на основе частоты имела AUC ROC $90,5 \pm 1,9\%$; чувствительность $68,3 \pm 5,3\%$; специфичность $92,9 \pm 1,1\%$.

ВОЗМОЖНОСТИ ПО НА ОСНОВЕ ТЕХНОЛОГИЙ ИИ В ЛАБОРАТОРНОЙ ДИАГНОСТИКЕ ДЛЯ ПАЦИЕНТОВ С SB

Изучение такого осложнения, как нейрогенный мочевой пузырь, привело к идее применения ИИ в лабораторной диагностике для пациентов с SB. В небольшом пилотном исследовании [25] использовались современные протеомные подходы на основе масс-спектрометрии для выявления пептидов или белков в моче (связанных с фиброзом, воспалением и дисфункцией детрузора), которые могут дифференцировать пациентов с SB с высоким риском развития почечных осложнений, связанных с нейрогенным мочевым пузырем. С помощью методов машинного обучения были отобраны пять пептидов, которые продемонстрировали наибольшие различия между

двумя клиническими категориями (норма и патология), и на их основе был создан классификатор. Классификатор был успешно протестирован путем слепого исследования еще шести образцов мочи. Эти результаты свидетельствуют о том, что скрининг-тест мочи на основе пептидов может проводиться на регулярной основе для стратификации низкого и высокого риска развития почечных осложнений у пациентов с SB.

РОЛЬ ИИ В ГЕНЕТИЧЕСКИХ ИССЛЕДОВАНИЯХ У ПАЦИЕНТОВ С SB

Технологиям ИИ нашлось применение не только в клинической практике для диагностики SB у пациентов, но и в генетических исследованиях по поиску причин возникновения и патофизиологии данного порока.

В исследовании [26] представлен анализ дифференциальной экспрессии генов с рекурсивным исключением признаков — подходом машинного обучения, который позволил выявить ключевые гены, связанные с SB.

В работе [27] представлена модель Individual Meta Random Forest (InMeRF) на основе алгоритма «случайный лес» для прогнозирования патогенности несинонимичных однонуклеотидных вариантов по всему геному человека. Авторы применили InMeRF к nsSNV в генах, вызывающих врожденные миастенические синдромы, а также в гене VANG1, который связан с возникновением SB. Чувствительность и специфичность InMeRF имели значения, равные 0,942 и 0,848, соответственно.

Целью работы [28] было определить геномные регуляторные сигнатуры, лежащие в основе патофизиологии SB. Данные состояли из 298 образцов ДНК пациентов (149 здоровых и 149 с SB). Для решения задачи исследования авторы применяли алгоритмы на основе глубокого обучения. В результате были выявлены редкие однонуклеотидные полиморфизмы в специфических сайтах связывания транскрипционных факторов, которые отличают случаи SB от контрольной группы, а также были проанализированы функциональные пути задействованных генов. Авторы исследования считают, что объединение вычислительных и функциональных анализов повысит точность персонализированного подхода к генетическому консультированию в отношении риска развития SB.

ОБСУЖДЕНИЕ

Наблюдается растущий интерес исследователей к применению алгоритмов ИИ в диагностике СВ (рисунок 2). Приведенный обзор литературы продемонстрировал многообразие направлений для разработок и достижения существующих решений.

Диагностика СВ представляет важную клиническую задачу, поскольку пренатальное выявление SBA дает возможность раннему началу лечения, в том числе оперативному вмешательству [5]. Но не стоит упускать из внимания и взрослых пациентов, которые сталкиваются с впервые выявленной SBO [46] или с осложнениями этой патологии [47]. Правильный и своевременный поставленный диагноз позволяет сформировать группы диспансерного наблюдения и этапы маршрутизации пациентов.

Проанализированные публикации освещают разработки, использующие различные типы данных для обнаружения СВ и сопутствующих патологий на разных этапах диагностического процесса. Приведенные результаты исследований подтверждают перспективность внедрения компьютерных технологий для повышения точности диагностики. Тем не менее прежде чем начать внедрение ИИ в практику нужно решить ряд критических вопросов. Большинство существующих исследований ограничены по масштабам, охватывают небольшое количество случаев и проводятся в отдельных научных или медицинских центрах без внешней валидации. Чтобы тщательно изучить безопасность и эффективность применения ПО на основе технологий ИИ в диагностике СВ, необходимы

многоцентровые исследования с большим количеством участников, а также с соблюдением методологии проведения и репортирования результатов исследований [48–51].

Следует обратить внимание, что большинство разработок ПО на основе технологий ИИ посвящено диагностике SBA. Это объясняется несколькими факторами: во-первых, SBA особенно требует своевременной диагностики, так как именно эта форма заболевания несет риск тяжелых неврологических нарушений и требует хирургического вмешательства [5]. Во-вторых, данная форма патологии характеризуется наиболее выраженными морфологическими изменениями, что упрощает разработку алгоритмов машинного обучения для их выявления. В-третьих, открытая форма расщепления позвоночника чаще всего диагностируется на ранних сроках беременности при ультразвуковом обследовании, что предоставляет исследователям достаточно данных для обучения и тестирования нейронных сетей.

Также стоит отметить, что в современной диагностике СВ особое внимание уделяется МРТ и УЗИ, что обусловлено их высокой информативностью для постановки диагноза. Однако РГ, несмотря на более низкую разрешающую способность по сравнению с МРТ и УЗИ, сохраняет свою диагностическую ценность как метод первичной оценки состояния позвоночника. Рентгенограммы могут послужить основанием для подозрения на наличие скрытой патологии, SBO, например, у ребенка с урологическими жалобами или взрослого человека с болями в спине, что позволит своевременно направить




Рисунок 2 – Количество публикаций по теме в базе данных PubMed.

пациента на более детальное обследование [52]. Поэтому исключать РГ из арсенала диагностических инструментов при выявлении SB не стоит. Учитывая, что эта патология редкая и морфологические изменения при SBO менее выраженные по сравнению с SBA, технологии компьютерного зрения могут оказать поддержку принятия врачебного решения.

Из осложнений SB особое внимание в разработке алгоритмов ИИ уделяется проблеме нейрогенного мочевого пузыря. Проанализированные исследования демонстрируют многогранность подходов к решению этой проблемы. С одной стороны, алгоритмы машинного обучения успешно применяются для анализа данных уродинамических исследований и МРТ-изображений мочевого пузыря, что позволяет выявлять ранние признаки нейрогенных изменений. С другой стороны, разработки в области лабораторной диагностики направлены на создание ИИ-систем для анализа биохимических маркеров и клинических показателей функции мочевого пузыря. Такой комплексный подход к диагностике обусловлен необходимостью своевременного выявления нарушений функции мочевого пузыря у пациентов с SB, что позволит предотвратить развитие тяжелых урологических осложнений и сохранить качество жизни пациентов.

Также продолжают активные исследования генетических факторов, оказывающих влияние на возникновение SB. Хотя профилактическая эффективность фолиевой кислоты подтверждена исследованиями и нашла практическое применение в виде обязательного обогащения пищевых продуктов [53], генетические

исследования раскрывают новые аспекты механизмов развития этого порока.

Таким образом, перспективными направлениями, выявленными в ходе анализа публикаций, являются: проведение масштабных многоцентровых исследований для оценки эффективности и безопасности применения существующих решений, улучшение алгоритмов ИИ в МРТ и УЗИ для ранней диагностики SB, а также разработка ПО на основе ИИ для выявления SBO по данным РГ, создание прогностических моделей развития осложнений SB и исхода операций, расширение базы данных геномных исследований для более точного прогнозирования рисков развития SB.

ЗАКЛЮЧЕНИЕ

В настоящей работе были рассмотрены оригинальные и обзорные работы, посвященные текущему состоянию применения ИИ для пациентов с SB, а также перспективам развития данной области. Были выявлены области развития ИИ для целей разработки персонализированных подходов диагностики и поддержки пациентов с данным заболеванием, которые позволят повысить качество их жизни.

Источник финансирования. Данная статья подготовлена авторским коллективом в рамках НИР «Программные решения на основе технологий искусственного интеллекта для практического здравоохранения».

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

ЛИТЕРАТУРА/REFERENCES

1. Морозов С.Л., Полякова О.В., Яновская Н.В. и др. Spina Bifida. Современные подходы и возможности к диагностике, лечению и реабилитации // Практическая медицина. — 2020. — Т.18. — №3. — С.32-37. [Morozov SL, Polyakova OV, Yanovskaya NV, et al. Spina Bifida. Sovremennye podhody i vozmozhnosti k diagnostike, lecheniyu i reabilitacii. Prakticheskaya medicina. 2020; 18(3): 32-37. (In Russ.)]
2. Sahmat A, Gunasekaran R, Mohd-Zin SW, et al. The Prevalence and Distribution of Spina Bifida in a Single Major Referral Center in Malaysia. *Front Pediatr.* 2017; 5: 237. doi: 10.3389/fped.2017.00237.
3. Schindelmann KH, Paschereit F, Steege A, Stoltenburg-Didinger G, Kaindl AM. Systematic Classification of Spina Bifida. *J Neuropathol Exp Neurol.* 2021; 80(4): 294-305. doi: 10.1093/jnen/nlab007.
4. Pattisapu JV, Veerappan VR, White C, et al. Spina bifida management in low- and middle-income countries – a comprehensive policy approach. *Childs Nerv Syst.* 2023; 39(7): 1821-1829. doi: 10.1007/s00381-023-05988-z.

5. Иванов С.В., Кенис В.М., Щедрина А.Ю. и др. Spina bifida: мультидисциплинарная проблема (обзор литературы) // Российский вестник детской хирургии, анестезиологии и реаниматологии. — 2021. — Т.11. — №2. — С.201-213. [Ivanov SV, Kenis VM, SHCHedrina AYU, et al. Spina bifida: mult'itisciplinarnaya problema. Rossijskij vestnik detskoj hirurgii, anesteziologii i reanimatologii. 2021; 11(2): 201-213. (In Russ.)]
6. Prodan N, Hoopmann M, Sonek J, et al. Fetal profile in fetuses with open spina bifida. Arch Gynecol Obstet. 2020; 301(5): 1167-1171. doi: 10.1007/s00404-020-05503-8.
7. Grivell RM, Andersen C, Dodd JM. Prenatal versus postnatal repair procedures for spina bifida for improving infant and maternal outcomes. Cochrane Database Syst Rev. 2014; 2014(10): cd008825. doi:10.1002/14651858.cd008825.pub2.
8. Di Mascio D, Greco F, Rizzo G, et al. Diagnostic accuracy of prenatal ultrasound in identifying the level of the lesion in fetuses with open spina bifida: A systematic review and meta-analysis. Acta Obstet Gynecol Scand. 2021; 100(2): 210-219. doi: 10.1111/aogs.14001.
9. Lei C, Yingying T, Yujie D. Neural Network Algorithm-Based Three-Dimensional Ultrasound Evaluation In The Diagnosis Of Fetal Spina Bifida. Scientific Programming. 2021; 2021(4): 1-9. doi: 10.1155/2021/3605739.
10. Gebretsadik T, Cooper WO, Ouyang L, et al. Rates of hospitalization for urinary tract infections among medicaid-insured individuals by spina bifida status, Tennessee 2005-2013. Disabil Health J. 2020; 13(4): 100920. doi: 10.1016/j.dhjo.2020.100920.
11. Basaloglu HK, Celik S, Kille KD, et al. Spina Bifida: Morphological Features, Molecularegulations and Signal Pathways. J Spine. 2017; 6(1): 2-7. doi: 10.4172/2165-7939.1000352.
12. Mufti N, Aertsen M, Ebner M, et al. Cortical spectral matching and shape and volume analysis of the fetal brain pre- and post-fetal surgery for spina bifida: a retrospective study. Neuroradiology. 2021; 63(10): 1721-1734. doi: 10.1007/s00234-021-02725-8.
13. Mufti N, Chappell J, Aertsen M, et al. Assessment of longitudinal brain development using super-resolution magnetic resonance imaging following fetal surgery for open spina bifida. Ultrasound Obstet Gynecol. 2023; 62(5): 707-720. doi: 10.1002/uog.26244.
14. Ebner M, Wang G, Li W, et al. An automated framework for localization, segmentation and super-resolution reconstruction of fetal brain MRI. Neuroimage. 2020; 206: 116324. doi: 10.1016/j.neuroimage.2019.116324.
15. Trigui R, Adel M, Di Bisceglie M, et al. Bladder Wall Segmentation and Characterization on MR Images: Computer-Aided Spina Bifida Diagnosis. J Imaging. 2022; 8(6): 151. doi: 10.3390/jimaging8060151.
16. Cengizler C, Kerem Ün M, Buyukkurt S. A novel evolutionary method for spine detection in ultrasound samples of spina bifida cases. Comput Methods Programs Biomed. 2021; 198: 105787. doi: 10.1016/j.cmpb.2020.105787.
17. Cengizler Ç, Ün MK, Büyükkurt S. A Nature-Inspired Search Space Reduction Technique for Spine Identification on Ultrasound Samples of Spina Bifida Cases. Sci Rep. 2020; 10(1): 9280. doi: 10.1038/s41598-020-66468-x.
18. Asha R, Subashka Ramesh SS. An optimized modified faster region convolutional neural network for spina bifida identification from ultrasound images. Biomed Signal Process Control. 2023; 86: 105253.
19. Asha R, Subashka Ramesh SS. Segmentation and classification of fetal spina bifida using DED with FM2DCN. Multimed Tools Appl. 2024; 83(25): 66981-66999.
20. Henry OA, David AO, Adeyemi OA. Machine Learning Algorithm for Classification of Infant Congenital Anomaly. In: Nagar A, Jat DS, Mishra D, Joshi A. (eds) Intelligent Sustainable Systems. Worlds4 2024. Lecture Notes in Networks and Systems, vol 1178. Springer, Singapore. doi: 10.1007/978-981-97-9559-8_23.
21. Chen L, Tian Y, Deng Y. Neural Network Algorithm-Based Three-Dimensional Ultrasound Evaluation in the Diagnosis of Fetal Spina Bifida. Sci Program. 2021; 1: 3605739.
22. Duran S, Üreten K, Maraş Y, et al. Automatic detection of spina bifida occulta with deep learning methods from plain pelvic radiographs. Res Biomed Eng. 2023; 39(3): 655-661.
23. Weaver JK, Martin-Olenski M, Logan J, et al. Deep Learning of Videourodynamics to Classify Bladder Dysfunction Severity in Patients With Spina Bifida. J Urol. 2023; 209(5): 994-1003. doi: 10.1097/JU.0000000000003267.

24. Hobbs KT, Choe N, Aksenov LI, et al. Machine Learning for Urodynamic Detection of Detrusor Overactivity. *Urology*. 2022; 159: 247-254. doi: 10.1016/j.urology.2021.09.027.
25. Fazelinia H, Ding H, Taylor D, et al. Stratification of neurogenic bladder risk in spina bifida using the urinary peptidome. *Am J Physiol Renal Physiol*. 2024; 326(2): F241-F248. doi: 10.1152/ajprenal.00267.2023.
26. Karthik KV, Rajalingam A, Shivashankar M, Ganjiwale A. Recursive Feature Elimination-based Biomarker Identification for Open Neural Tube Defects. *Curr Genomics*. 2022; 23(3): 195-206. doi: 10.2174/1389202923666220511162038.
27. Takeda JI, Nanatsue K, Yamagishi R, et al. InMeRF: prediction of pathogenicity of missense variants by individual modeling for each amino acid substitution. *NAR Genom Bioinform*. 2020; 2(2): lqaa038. doi: 10.1093/nargab/lqaa038.
28. Wolujewicz P, Aguiar-Pulido V, Thareja G, et al. Integrative computational analyses implicate regulatory genomic elements contributing to spina bifida. *Genet Med Open*. 2024; 2: 101894. doi: 10.1016/j.gimo.2024.101894.
29. McKernan G, Izzo S, Crytzer TM, et al. Relationship Between Motor Level and Wheelchair Transfer Ability in Spina Bifida: A Study From the National Spina Bifida Patient Registry. *Arch Phys Med Rehabil*. 2020; 101(11): 1953-1960. doi: 10.1016/j.apmr.2020.06.016.
30. Punchak MA, Bond KM, Wathen CA, et al. Use of a machine learning algorithm with a focus on spinopelvic parameters to predict development of symptomatic tethered cord after initial untethering surgery. *J Neurosurg Pediatr*. 2024; 33(5): 405-410. doi: 10.3171/2023.11.PEDS23278.
31. Chao AS, Jhang LS, Hsieh PC. Prenatal Diagnosis and Outcomes of Cervical Meningocele and Myelomeningocele. *J Med Ultrasound*. 2024; 32(1): 21-24. doi: 10.4103/jmu.jmu_51_23.
32. Benjamin RH, Yu X, Navarro Sanchez ML, et al. Co-occurring defect analysis: A platform for analyzing birth defect co-occurrence in registries. *Birth Defects Res*. 2019; 111(18): 1356-1364. doi: 10.1002/bdr2.1549.
33. Pollenus J, Lagae L, Aertsen M, Jansen K. The impact of cerebral anomalies on cognitive outcome in patients with spina bifida: A systematic review. *Eur J Paediatr Neurol*. 2020; 28: 16-28. doi: 10.1016/j.ejpn.2020.07.005.
34. Hebert L, Hillman P, Baker C, et al. Burden of rare deleterious variants in WNT signaling genes among 511 myelomeningocele patients. *PLoS One*. 2020; 15(9): e0239083. doi: 10.1371/journal.pone.0239083.
35. Aguiar-Pulido V, Wolujewicz P, Martinez-Fundichely A, et al. Systems biology analysis of human genomes points to key pathways conferring spina bifida risk. *Proc Natl Acad Sci U S A*. 2021; 118(51): e2106844118. doi: 10.1073/pnas.2106844118.
36. Beltran Ale G, Pascoe J, George A, et al. Validation of pediatric sleep questionnaire in children with Chiari malformation and/or spina bifida with or without myelomeningocele. *Sleep Med*. 2021; 84: 93-97. doi: 10.1016/j.sleep.2021.05.030.
37. Gunnnett M, Rocque BG, Nourani A, Beltran-Ale G. Impact of Spina Bifida on Sleep Quality: Current Insights. *Nat Sci Sleep*. 2023; 15: 967-978. doi: 10.2147/NSS.S401269.
38. Rethlefsen SA, Bent MA, Mueske NM, Wren TAL. Relationships among classifications of impairment and measures of ambulatory function for children with spina bifida. *Disabil Rehabil*. 2021; 43(25): 3696-3700. doi: 10.1080/09638288.2020.1746845.
39. Pruthi V, Abbasi N, Ryan G, et al. Fetal Surgery for Open Spina Bifida in Canada: Initial Results. *J Obstet Gynaecol Can*. 2021; 43(6): 733-739.e1. doi: 10.1016/j.jogc.2020.10.014.
40. Sanz Cortes M, Chmait RH, Lapa DA, et al. Experience of 300 cases of prenatal fetoscopic open spina bifida repair: report of the International Fetoscopic Neural Tube Defect Repair Consortium. *Am J Obstet Gynecol*. 2021; 225(6): 678. e1-678. e11. doi: 10.1016/j.ajog.2021.05.044.
41. McLaughlin MJ, Modrcin AC, Hickman TP, Hoffman M. Determining the impact of a clinic coordinator on patient access and clinic efficiency in a pediatric multidisciplinary spina bifida clinic using medical informatics. *J Pediatr Rehabil Med*. 2021; 14(4): 661-666. doi: 10.3233/PRM-200790.

42. Weaver JK, Weiss DA, Aghababian A, et al. Why are pediatric urologists unable to predict renal deterioration using urodynamics? A focused narrative review of the shortcomings of the literature. *J Pediatr Urol.* 2022; 18(4): 493-498. doi: 10.1016/j.jpuro.2022.05.015.
43. Uy MNAR, Tantengco OAG. Investigating the landscape and trajectory of spina bifida research in Asia: a bibliometric analysis. *Childs Nerv Syst.* 2022; 38(8): 1581-1591. doi: 10.1007/s00381-022-05527-2.
44. Trigo L, Eixarch E, Faig-Leite F, et al. Longitudinal evolution of central nervous system anomalies in fetuses with open spina bifida fetoscopic repair and correlation with neurologic outcome. *Am J Obstet Gynecol MFM.* 2023; 5(6): 100932. doi: 10.1016/j.ajogmf.2023.100932.
45. Zoghi S, Feili M, Mosayebi MA, et al. Surgical outcomes of myelomeningocele repair: A 20-year experience from a single center in a middle-income country. *Clin Neurol Neurosurg.* 2024; 239: 108214. doi: 10.1016/j.clineuro.2024.108214.
46. Sakti YM, Lanodiyu ZA, Sakadewa GP, et al. Spina bifida occulta at the lumbar spine level manifested as chronic low back pain and unpredictable neurologic deficit: A case report. *Int J Surg Case Rep.* 2024; 116: 109320. doi: 10.1016/j.ijscr.2024.109320.
47. Muranaka I, Kyoda Y, Nofuji S, et al. A Case of Neuropathic Lower Urinary Tract Dysfunction Due to Spina Bifida Occulta Discovered at the Age of 19 Years and Successfully Treated with Multidisciplinary Therapy //Hinyokika kyo. *Acta Urologica Japonica.* 2024; 70(2): 55-59. doi: 10.14989/ActaUroJap_70_2_55.
48. Клинические испытания систем искусственного интеллекта (лучевая диагностика) / сост. Ю.А. Васильев, А.В. Владзимирский, Д.Е. Шарова и др. // Серия «Лучшие практики лучевой и инструментальной диагностики». — Вып. 113. — 2-е изд., перераб. и доп. — М.: ГБУЗ «НПКЦ ДиТ ДЗМ», 2023. — 40 с. [Klinicheskie ispytaniya sistem iskusstvennogo intellekta (luhevaya diagnostika). Sost. YU.A. Vasil'ev, A.V. Vladzimirskij, D.E. SHarova, et al. Seriya «Luchshie praktiki luchevoj i instrumental'noj diagnostiki». Вып. 113. 2-е изд., pererab. i dop. М.: GBUZ «NPKC DiT DZM», 2023. 40 s. (In Russ.)]
49. Васильев Ю.А., Памова А.П., Арзамасов К.М. и др. Представление метрик диагностической точности в зависимости от классификации программного обеспечения на основе искусственного интеллекта в области лучевой диагностики // Врач и информационные технологии. — 2025. — №1. — С.58-69. [Vasil'ev YUA, PamoVA AP, Arzamasov KM, et al. Predstavlenie metrik diagnosticheskoy tochnosti v zavisimosti ot klassifikacii programmnoho obespecheniya na osnove iskusstvennogo intellekta v oblasti luchevoj diagnostiki. Vrach i informacionnye tekhnologii. 2025; 1: 58-69. (In Russ.)]
50. Заюнчковский С.Ю., Коновалов С.А., Зинченко В.В. и др. Система менеджмента качества: инструмент развития организации или дополнительная нагрузка? // Digital Diagnostics. — 2023. — Т.4. — №3. — С.439-447. [Zayunchkovskij SYU, Konovalov SA, Zinchenko VV, et al. Sistema menedzhmenta kachestva: instrument razvitiya organizacii ili dopolnitel'naya nagruzka? Digital Diagnostics. 2023; 4(3): 439-447. (In Russ.)]
51. Искусственный интеллект в лучевой диагностике: Per Aspera Ad Astra / Под ред. Ю.А. Васильева и А.В. Владзимирского. М.: Издательские решения, 2025. — 491 с. [Iskusstvennyj intellekt v luchevoj diagnostike: Per Aspera Ad Astra. Pod red. YU.A. Vasil'eva i A.V. Vladzimirskogo. М.: Izdatel'skie resheniya, 2025. 491 s. (In Russ.)]
52. Mirzaei S, Khoshkholghsima M, Sabaghzadeh A, Kurdkandi HZ. Cervicothoracic (C6, C7 & T1) spina bifida occulta - A case report. *Int J Surg Case Rep.* 2024; 117: 109477. doi: 10.1016/j.ijscr.2024.109477.
53. Mai CT, Evans J, Alverson CJ, et al. Changes in Spina Bifida Lesion Level after Folic Acid Fortification in the US. *J Pediatr.* 2022; 249: 59-66.e1. doi: 10.1016/j.jpeds.2022.06.023.

ГАРАНИН А.А.,

к.м.н., ФГБОУ ВО «СамГМУ» Минздрава России, г. Самара, Россия;
e-mail: sameagle@yandex.ru

РУБАНЕНКО О.А.,

д.м.н., ФГБОУ ВО «СамГМУ» Минздрава России, г. Самара, Россия;
e-mail: olesya.rubanenko@gmail.com

ТРУСОВ Ю.А.,

ФГБОУ ВО «СамГМУ» Минздрава России, г. Самара, Россия;
e-mail: yu.a.trusov@samsmu.ru

СЕНЮШКИН Д.В.,

ФГБОУ ВО «СамГМУ» Минздрава России, г. Самара, Россия;
e-mail: d.v.senushkin@samsmu.ru

КОЛСАНОВ А.В.,

д.м.н., профессор, член-корреспондент РАН, ФГБОУ ВО «СамГМУ» Минздрава России,
г. Самара, Россия; e-mail: a.v.kolsanov@samsmu.ru

АСПЕКТЫ ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ СКРИНИНГА И ДИАГНОСТИКИ ЗАБОЛЕВАНИЙ: НАРРАТИВНЫЙ ОБЗОР

DOI: 10.25881/18110193_2026_1_22

Аннотация. Актуальность. Активное внедрение искусственного интеллекта (ИИ) в сферу здравоохранения существенно повышает эффективность ранней диагностики различных заболеваний. Среди перспективных направлений внедрения ИИ выделяются методы диагностики, основанные на анализе голоса, дистанционном мониторинге кровообращения методом фотоплетизмографии, отслеживании особенностей движения глаз, а также использование умных устройств для непрерывного мониторинга здоровья. Важнейшей задачей является разработка интегрированных систем комплексного медицинского скрининга.

Цель. Оценка литературных данных и анализ результатов применения искусственного интеллекта для раннего выявления заболеваний.

Материал и методы. Проведен поиск в базах данных PubMed (Medline), Google Scholar, eLibrary, Web of Science, Scopus, CyberLeninka работ на английском и русском языках, в которых осуществлялся скрининг заболеваний, по ключевым терминам «screening», «diagnostics», «artificial intelligence», «machine learning», «disease», «скрининг», «диагностика», «искусственный интеллект», «заболевание», «машинное обучение», «глубокое обучение». Включение исследований (2015–2025 гг.) основано на независимой оценке тремя исследователями, которые пришли к единому мнению.

Результаты. Для данного обзора в процессе отбора соответствующих исследований включена 31 работа, отвечающая критериям поиска, из 1141 публикаций.

Заключение. Скрининг и диагностика заболеваний с применением ИИ предоставляет существенную информацию о состоянии пациента, снижая риск человеческого фактора и пропуска ранних признаков заболевания.

Ключевые слова: скрининг, заболевание, искусственный интеллект, машинное обучение.

Для цитирования: Гаранин А.А., Рубаненко О.А., Трусов Ю.А., Сенюшкин Д.В., Колсанов А.В. Аспекты применения искусственного интеллекта для скрининга и диагностики заболеваний: нарративный обзор. Врач и информационные технологии. 2026; 1: 22-37. DOI: 10.25881/18110193_2026_1_22.

GARANIN A.A.,

PhD, Federal State Budgetary Educational Institution of Higher Medical Education "SamSMU" of the Ministry of Health of the Russian Federation, Samara, Russia; e-mail: sameagle@yandex.ru

RUBANENKO O.A.,

DSc, Federal State Budgetary Educational Institution of Higher Medical Education "SamSMU" of the Ministry of Health of the Russian Federation, Samara, Russia; e-mail: olesya.rubanenko@gmail.com

TRUSOV YU.A.,

Federal State Budgetary Educational Institution of Higher Medical Education "SamSMU" of the Ministry of Health of the Russian Federation, Samara, Russia; e-mail: yu.a.trusov@samsmu.ru

SENYUSHKIN D.V.,

Federal State Budgetary Educational Institution of Higher Medical Education "SamSMU" of the Ministry of Health of the Russian Federation, Samara, Russia; e-mail: d.v.senushkin@samsmu.ru

KOLSANOV A.V.,

DSc, Professor, Corresponding Member of the Russian Academy of Sciences, Federal State Budgetary Educational Institution of Higher Medical Education "SamSMU" of the Ministry of Health of the Russian Federation, Samara, Russia; e-mail: a.v.kolsanov@samsmu.ru

ASPECTS OF THE USE OF ARTIFICIAL INTELLIGENCE FOR DISEASE SCREENING AND DIAGNOSIS: A NARRATIVE REVIEW

DOI: 10.25881/18110193_2026_1_22

Abstract. *Background.* The active implementation of artificial intelligence (AI) in healthcare significantly improves the effectiveness of early diagnosis of various diseases. Promising areas for AI implementation include diagnostic methods based on voice analysis, remote blood flow monitoring using photoplethysmography, eye movement tracking, and the use of smart devices for continuous health monitoring. A key objective is the development of integrated systems for comprehensive medical screening.

Aim. To evaluate the literature and analyze the results of artificial intelligence implementation for the early detection of diseases.

Materials and methods. A search was conducted in the databases PubMed (Medline), Google Scholar, eLibrary, Web of Science, Scopus, CyberLeninka for English- and Russian-language publications. We used the keywords "screening," "diagnostics," "artificial intelligence," "machine learning," "disease," "screening," "diagnostics," "artificial intelligence," "disease," "machine learning," and "deep learning." Studies from 2015 to 2025 were included based on independent review by three researchers who reached a consensus.

Results. Thirty-one papers from 1,141 publications that met the search criteria were included for this review.

Conclusions. AI-based disease screening and diagnosis provides valuable information about a patient's condition, reducing the risk of human error and missing early signs of disease.

Keywords: screening, disease, artificial intelligence, machine learning.

For citation: Garanin A.A., Rubanenko O.A., Trusov Yu.A., Senyushkin D.V., Kolsanov A.V. Aspects of the use of artificial intelligence for disease screening and diagnosis: a narrative review. Medical doctor and information technology. 2026; 1: 22-37. DOI: 10.25881/18110193_2026_1_22.

ВВЕДЕНИЕ

Искусственный интеллект (ИИ) активно внедряется в медицинскую практику, помогая выявлять заболевания на ранних стадиях. Основные направления применения включают онкологический скрининг (анализ маммограмм с точностью выше специалиста-рентгенолога, диагностика рака кожи по фотографиям, выявление онкологических заболеваний на снимках магнитно-резонансной томографии (МРТ), компьютерной томографии (КТ)), кардиологическую диагностику (оценка рисков сердечно-сосудистых заболеваний (ССЗ) по ЭКГ, прогнозирование инсультов, анализ состояния сосудов по снимкам сетчатки), офтальмологический скрининг (выявление диабетической ретинопатии, диагностика заболеваний сетчатки, оценка состояния глазного дна) [1–5]. Практические решения для своевременного выявления заболеваний основаны на широко известных приложениях и платформах, обученных с использованием методов машинного обучения: ПроРодинки (случаи скрининга новообразований кожи) [6], SkinVision (система диагностики рака кожи по фотографиям с телефона) [7], IDx-DR (программа для анализа сетчатки глаза) [8], Ezra (ИИ-система для анализа МРТ-снимков) [9, 10], KardiaMobile (решение для анализа ЭКГ) [11]. Современные стоматологические клиники используют ИИ в клинической практике. К примеру, применение интраоральных камер, интегрированных с ИИ, даёт возможность мгновенно оценить состояние слизистой оболочки ротовой полости. Алгоритмы на базе ИИ способны самостоятельно классифицировать пациентов по степени риска, направляя их на углублённую диагностику. Совместное применение цифровых стоматологических изображений и КТ совместно с технологиями ИИ позволяет обнаруживать не только злокачественные новообразования, но также и ранние признаки онкологии [12–14]. Следовательно, внедрение ИИ способствует высокой точности и скорости анализа (ИИ может обрабатывать изображения за доли секунды, выявляя изменения, которые могут быть незаметны глазу опытного специалиста), снижению числа пропущенных диагнозов (за счёт автоматического скрининга снижается риск человеческого фактора и пропуска ранних признаков заболевания), экономии времени врача и пациента (быстрый анализ позволяет быстрее

принять решение о дальнейшем обследовании или лечении), доступности в удалённых регионах (ИИ можно интегрировать в телемедицинские платформы, что особенно важно для жителей отдалённых населённых пунктов, где нет возможности получения консультации специалистами узкого профиля) [15–16]. Преимущества использования ИИ обусловлены повышением точности диагностики, ускорением процесса анализа медицинских изображений, снижением нагрузки на врачей, возможностью раннего выявления заболеваний, персонализацией скрининговых программ. Перспективные направления для применения ИИ в практике врача — это диагностика состояния по голосу, дистанционной фотоплетизмографии, анализ движений глаз, мониторинг состояния через носимые устройства, создание комплексных систем скрининга [17–19].

Однако применение ИИ характеризуется рядом ограничений (зависимость от качества обучающих данных, вопросы интерпретируемости алгоритмов, правовые и этические аспекты) [48, 50]. Ошибочные исходные данные приводят к неправильному диагнозу. Например, при распознавании изображений некоторые детали (например, опухоль) могут быть пропущены или, наоборот, добавлены. Нейросети не дают ответ на вопрос, почему был получен тот или иной результат. Логика, лежащая в основе сделанных выводов, непонятна, и это приводит к неуверенности в корректности достигнутого результата. Кроме того, неясно, кто несёт ответственность за ошибки алгоритма — врач или разработчик.

Использование ИИ в скрининге позволяет значительно повысить эффективность ранней диагностики заболеваний и снизить риски развития серьезных осложнений. Однако для достижения максимального эффекта требуется комплексный подход с участием квалифицированных медицинских специалистов.

Цель исследования — обзор источников литературы по вопросам скрининга и диагностики различных заболеваний в практической деятельности врача с применением ИИ.

МЕТОДОЛОГИЯ ИССЛЕДОВАНИЯ

Авторами был произведен поиск публикаций в базах данных PubMed, Web of Science, Scopus, CyberLeninka, eLibrary и Google Scholar. Поиск осуществлялся по ключевым терминам:

«screening», «diagnostics», «artificial intelligence», «machine learning», «disease», «скрининг», «диагностика», «искусственный интеллект», «заболевание», «машинное обучение», «глубокое обучение». Три автора отдельно друг от друга выполняли отбор подходящих исследований. В обзор включались оригинальные работы, опубликованные на русском и английском языках с 2015 по 2025 годы. В настоящий обзор было включено 31 исследование (рисунок 1). Авторы проанализировали аннотации статей, полный текст, далее извлекали данные для формирования резюме. Во время проведения работы обсуждались разные мнения, в случае несогласия включения исследования в анализ приглашался четвертый коллега, по результатам консилиума принималось общее решение.

Из выборки удалялись публикации, которые по содержащимся в них данным, относились к нерелевантным областям. Чтобы определить принадлежность публикации к предметной области, находились определяющие термины в заглавии, аннотации и ключевых словах. С помощью анализа ключевых слов предшествующей выборки искали термины, не относящиеся к тематике исследования. Публикации, содержащие эти термины, исключались из рассмотрения. За несоответствие

тематике исследования из выборки удалялись публикации или группы публикаций, сформированные в результате, когда две работы ссылаются на общую третью в списках литературы.

В поиск не включались тезисы, опубликованные в материалах научных конференций, и диссертационные исследования, поскольку такая информация крайне редко включает приоритетные аспекты для извлечения данных. Из рассмотрения исключены следующие категории публикаций: эмпирические и методологические изыскания, а также нарративные обзоры и методические руководства, обзоры систематического характера, не содержащие данных о методах моделирования с применением ИИ, либо такие, из которых невозможно выделить результаты работы. Так как число найденных источников оказалось существенным, проводилось автоматическое удаление повторяющихся записей.

Оценка качества статей не проводилась ввиду отсутствия в большинстве случаев классической схемы со сравнением разных групп, которая не соблюдалась в отобранных нами статьях.

Синтез (обобщение) данных. В каждой статье выделялись следующие данные:

– характеристики выборки, если они приводились (возраст, пол, размер выборки);




Рисунок 1 – Алгоритм отбора публикаций для написания систематического обзора.

– характеристики прогностической модели ИИ (название способа, вид, характеристика модели, сравнение с контрольной группой).

РЕЗУЛЬТАТЫ

Блок-схема включенных исследований представлена на рисунке 1.

Основные характеристики статей, отвечающих критериям включения, представлены в таблице 1.

Как видно из представленных работ, применение методов ИИ позволяет решить разные задачи в области инфекционных заболеваний (предсказание развития сепсиса [20], оценка тяжести заболевания, определенной с помощью КТ, и временем от начала заболевания до КТ у пациентов при пневмонии, вызванной COVID-19 [33]), хирургических заболеваний (предупреждение о надвигающейся гипотензии в интраоперационном периоде [22]), нейрохирургии (для повышения точности компьютерной диагностики стеноза межпозвоночного отверстия [29]), соматической патологии (выделение фенотипов псориатического артрита [36], клиническая диагностика IgA-нефропатии [40], диагностика и классификация атрофии желудка и кишечной метаплазии [43], скрининг заболеваний органов грудной клетки (ателектаз, фиброз, кальцификация, уплотнения, узловые образования в легких, кардиомегалия, расширение средостения, плевральный выпот, пневмоторакс и пневмоперитонеум) [44], верификация инсульта с применением портативного устройства для отслеживания движения глаз [39]), риск развития сердечной недостаточности у пациентов с сахарным диабетом 2 типа [5]), в гинекологии (предсказание спонтанных аборт [40]), в том числе при использовании методов нетрадиционной медицины [41].

В кардиологической практике моделирование направлено на решение следующих вопросов: феногруппирование пациентов с сердечной недостаточностью и выявление больных с положительным ответом на сердечную ресинхронизирующую терапию [21], кардиоренальные осложнения при сахарном диабете с установленной клинической оценкой нефропатии [23], предсказание подходящей терапии имплантируемого кардиовертера-дефибриллятора при желудочковой тахикардии или фибрилляции

желудочков [25], выявление недиагностированной фибрилляции предсердий (ФП) в первичной медицинской помощи [32], эхокардиографические фенотипы предсказания сердечной недостаточности [35].

Конечно, в области онкологических состояний отдается предпочтение использованию ИИ для: прогнозирования патологических изменений у сложной группы пациентов с ВПЧ-ассоциированной карциномой ротоглотки [24], 5-летней выживаемости пациентов с раком молочной железы [26], риска остеосаркомы в популяционной когорте и оценки факторов, влияющих на возникновение легочных метастазов [29], метастазов на ранних стадиях инвазивного рака молочной железы [30], немелкоклеточного рака легких [25], прогрессирования опухоли при глиобластоме [34], патологической классификации менингиом [37], выявление рака легких на ранней стадии с помощью автоматизированной проточной цитометрии мокроты [39], рака предстательной железы на основе диагностических характеристик моделей позитронно-эмиссионной томографии/магнитно-резонансной томографии (ПЭТ/МРТ) с [68Ga]Ga-PSMA-11 in vivo для прогнозирования низкого и высокого риска поражения, а также биохимического рецидива и общего риска [41], определения скорости роста рака молочной железы (PMЖ) in vivo [42], нахождения очагов поражения при раке легкого на низкодозовых КТ [39].

В педиатрии использование ИИ необходимо для определения прогностического фенотипа детей с детским центральным параличом, которым требуются инъекции нейротоксинов [27], определение постинфекционной детской гидроцефалии [38].

Методы машинного и глубокого обучения включали разнообразные методы, в частности, случайный лес (random forest), в том числе по тесту Делонга, многоядерное обучение и классификация с использованием К-средних, классификация ENE, нейросетевое моделирование, модель XGBoost модель CatBoost, модели логистической регрессии (LR) и метод опорных векторов (SVM) (по тесту Делонга), анализ кривой принятия решения (DCA) и кривой клинического воздействия (CIC), модель BTX-PredictMed. дерево принятия решений, классификация градиентного бустинга, алгоритм ИИ Lunit INSIGHT CXR, регрессия Кокса.

Таблица 1 – Характеристика исследований

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
1	Морозов С.П. (2020) [1]	От 55 до 80 лет (средний возраст мужчин 64,8±9,4 года, женщин 65,9±8,3 года)	80 мужчин и 20 женщин	100	Алгоритм ИИ S. Trajanovski et al. (2019). Алгоритм на основе двухэтапного метода: 1 этап – детектор для идентификации очагов КТ; 2 этап – нейронная сеть (архитектура ResNet), регуляризованная с помощью случайного отключения нейронов (dropout)	Машинное обучение	Чувствительность – 0,817, специфичность – 0,925, точность – 0,860, площадь под характеристической кривой – 0,930 (95% ДИ 0,880–0,979)	Сопоставление полученных значений с итогами собственного тестирования свидетельствует о хорошей воспроизводимости результатов работы ИИ на независимых данных
2	Бородулина Е.А. (2025) [4]	Не указан	Не указан	2345 исследований	Основой работы интеллектуального блока ИИ-сервиса является сверточная нейронная сеть, обученная для детекции и локализации легочных патологий. Дополнительным элементом является многослойный нейросетевой классификатор, который выполнял функции распознавания классов патологий, детектированных и локализованных на изображениях.	Нейросетевые алгоритмы	Максимизация прогностической ценности отрицательного результата: чувствительность 96%, специфичность 61%, точность 81%, площадь под кривой рабочих характеристик ROC 0,91–0,93	ROC ИИ соответствует аналогичным показателям квалифицированных рентгенологов (0,78–0,91)

Таблица 1 – Характеристика исследований (продолжение)

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
3	Segar MW et al. (2024) [5]	Средний возраст: 62,7 (6,6) лет	Женщины 3370 (38,5%)	8756	Методы случайного леса для прогнозирования выживаемости (RSF), непараметрический подход на основе дерева принятия решений,	Машинное обучение	Применение RSF, и моделирование взаимосвязи с RSF - С-индекса 0,77 (95% ДИ 0,75–0,80, $p < 0,001$). Калибровка модели, основанной на RSF, оказалась приемлемой (статистика Хосмера-Лемешоу $\chi^2 = 9,63$, $p = 0,29$)	Применение RSF – общий С-индекс 0,74 (95% ДИ 0,71–0,74), по сравнению с методами поэтапного прямого отбора, равными 0,71 (95% ДИ 0,67–0,74) и обратного отбора, равными 0,73 (95% ДИ 0,70–0,76), при использовании моделирования зависимости РН Кокса ($p < 0,01$ и $p = 0,01$, соответственно)
4	Mertens S. et al. (2021) [14]	Не указан	Не указан		Кластерное рандомизированное перекрестное контролируемое исследование с применением программы – нейронная сеть для обнаружения кариеса (dentalXrai Pro, dentalXrai Ltd.)	Сверточная нейронная сеть	Чувствительность 0,81, 95% ДИ 0,74–0,87 ROC 0,89, 95% ДИ 0,87–0,90	Без применения ИИ метрики ниже: ROC 0,85; 95% ДИ 0,83–0,86; $p < 0,05$, чувствительность 0,72; 95% ДИ 0,64–0,79 ($p < 0,05$) без изменения специфичности ($p > 0,05$)
5	Wang D. et al. (2021) [20]	Не указан	Не указан	4449	Случайный лес	Машинное обучение	Площадь AUC составила 0,91, чувствительность – 87%, специфичность – 89%	Не указано
6	Cikes M. et al. (2018) [21]	Не указан	Не указан	1106	Множественное ядерное обучение и кластеризация методом k-средних	Машинное обучение	Не указана	Отношение рисков (ОР) 0,35; 95% доверительный интервал (ДИ) 0,19–0,64; $p = 0,0005$ и ОР 0,36; 95% ДИ 0,19–0,68; $p = 0,001$

Таблица 1 – Характеристика исследований (продолжение)

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
7	Wijnberge M. et al. (2020) [22]	Средний возраст — 64 года	43% женщин	68	Система раннего оповещения на основе машинного обучения	Машинное обучение	Не указана	Среднее время с момента возникновения гипотензии у одного пациента составило 8,0 минут в группе вмешательства по сравнению с 32,7 минутами в контрольной группе
8	Januzzi JJ, et al. (2025) [23]	Не указан	Не указан	Не указана	Многопараметрическая модель машинного обучения	Машинное обучение	Не указана	Точность модели оценки риска была подтверждена в отдельных когортах исследования CREDENCE и в исследовании Canagliflozin Cardiovascular Assessment Study
9	Kann B.H. et al. (2023) [24]	Не указан	Не указан	178 сканирований	Алгоритм глубокого обучения на основе компьютерной томографии	Глубокое обучение	AUC алгоритма глубокого обучения для классификации ENE составил 0,86 (95% ДИ 0,82–0,90)	Алгоритм показал лучшую производительность по сравнению с рентгенологами для ENE размером более 1 мм и в узлах с диаметром короткой оси 1 см или больше
10	Ginder C. et al. (2023) [25]	Средний возраст — 64 года	26% женщин	2718	Многофакторная логистическая регрессия и нейронные сети	Машинное обучение	Логистическая регрессия: AUC 0,72; нейронные сети: AUC 0,90	Логистическая регрессия (чувствительность 39%, специфичность 91%, AUC 0,72). Нейросетевое моделирование ($p < 0,01$ для сравнения) (чувствительность 54%, специфичность 96%, AUC 0,90)

Таблица 1 – Характеристика исследований (продолжение)

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
11	Yu W. et al. (2023) [26]	Не указан	Не указан	13 802	LASSO, логистическая регрессия, случайный лес, SVM, XGBoost	Машинное обучение	XGBoost: AUC = 0,8400 в обучающей группе; AUC = 0,8365 в проверочной группе	Не указана
12	Bertoncelli C.M. et al. (2022) [27]	Средний возраст 16,5±1,2	Не указан	165	Модель машинного обучения ВТХ-PredictMed	Машинное обучение	Средняя точность, чувствительность и специфичность составили 75%	Эффективность 75%
13	Su Z. et al. (2023) [28]	Не указан	Не указан	612	Логистическая регрессия, LASSO, многофакторная логистическая регрессия		AUC = 0,701 в обучающей когорте; AUC = 0,786 в проверочной когорте	Не указана
14	Wang H. et al. (2022) [29]	Не указан	Не указан	86	Алгоритм автоматической оценки изображений межпозвоночных отверстий с помощью глубокого обучения	Машинное обучение	Традиционный классификатор 1-NN (точность от 51,8±2,5 до 61,3±0,7, F1 от 0,517 до 0,768) ELM (точность от 51,3±2,1 до 65,4±3,8, F1 от 0,697 до 0,786)	Не указана
15	Yu Y. и др. (2021) [30]	Не указан	Не указан	1088	Радиомика МРТ, машинное обучение, метод опорных векторов	Машинное обучение	AUC радиомики: 0,88; AUC мультиомической сигнатуры: 0,90	Мультиомная сигнатура показала более высокую прогностическую ценность
16	Chen Y. et al. (2022) [31]	Не указан	Не указан	104	Система чтения изображений на основе ИИ и глубокого обучения	Глубокое обучение	Чувствительность рентгенологов: 72,94% Чувствительность системы ИИ: 94,12%	Система ИИ показала более высокую чувствительность (p<0,05)
	Hill N.R. et al. (2022) [32]	≥30 лет	Не указан	Не указан	Алгоритм прогнозирования риска ФП на основе машинного обучения	Машинное обучение	Стратегия скрининга экономически эффективна при определённых условиях	Стратегия скрининга экономически эффективна для выявления ФП
17	Ohno Y. et al. [33]	Не указан	Не указан	32	Алгоритм ИИ для диагностики пневмонии, вызванной COVID-19, количественный анализ текстуры КТ	Машинное обучение	Оценка тяжести заболевания по КТ: 62,5%. Точность комбинированного количественного метода: 87,5%	Комбинированный количественный метод показал более высокую точность

Таблица 1 – Характеристика исследований (продолжение)

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
18	George E. et al. (2022) [34]	Средний возраст 55,2 года	69% мужчины	113	Машинное обучение на основе радиомики для прогнозирования результатов иммунотерапии при глиобластоме	Машинное обучение	Характеристики МРТ до лечения имели низкую прогностическую ценность. Прогностическая ценность первых результатов МРТ во время лечения: индекс согласованности = 0,692–0,750	Модель МО на основе радиомики позволяет прогнозировать выживаемость пациентов
19	Kobayashi M. et al. (2022) [35]	Средний возраст: 60±5 лет (STANISLAS); 67±6 лет (Malmö)	Мужчины: 48% (STANISLAS); 70% (Malmö)	827 (STANISLAS); 1394 (Malmö)	Эхокардиографические фенотипы, выявленные с помощью машинного обучения	Машинное обучение	Фенотипы ДИ и ДИ/СР связаны с более высоким риском развития цереброваскулярной болезни и гипертрофии левого желудочка	Классификация на основе эхокардиографических данных выявила профили с различным долгосрочным риском развития сердечной недостаточности
20	Richette P. et al. (2023) [36]	Не указан	Мужчины и женщины	661	Неотрицательная матричная факторизация для выявления кластеров фенотипов ПсА	Машинное обучение без учителя	Ответ на лечение гуселькумабом различался в зависимости от кластера	Выявлено восемь кластеров фенотипов ПсА со значительными различиями в демографических характеристиках, клинических проявлениях и реакции на лечение
21	Wang X. et al. (2022) [37]	Не указан	Не указан	120	Модель на основе неконтролируемой кластеризации Multihabitat для прогнозирования патологической классификации менингиом	Машинное обучение без учителя	Площадь под кривой: 0,838 в обучающей группе; 0,73 в тестовой группе Обучающая группа: 67,65%; тестовая группа: 69,05%	Модель продемонстрировала большой потенциал для практического применения

Таблица 1 – Характеристика исследований (продолжение)

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
22	Harper J.R. et al. (2021) [38]	Не указан	Не указан	Не указан	Оценка эффективности визуализации головного мозга с низким разрешением: лечение гидроцефалии у младенцев	Глубокое обучение	Не указана	Изображения низкого качества могут быть полезны для планирования лечения гидроцефалии, но могут содержать вводящую в заблуждение информацию при улучшении с помощью глубокого обучения
23	Lemieux M.E. et al. (2023) [39]	Не указан	Не указан	182	CyPath Lung: анализ мокроты с помощью автоматизированной проточной цитометрии и машинного обучения	Машинное обучение	AUC: 0,89 (95% ДИ 0,83–0,89) в первой группе; AUC: 0,85 (95% ДИ 0,71–0,98) во второй группе	Тест показал высокую чувствительность и специфичность для классификации образцов как раковых или нераковых, в том числе у участников с разными стадиями заболевания и узелками диаметром менее 20 мм
24	Qin X. et al. (2023) [40]	Не указан	Не указан	120	Разработка новой комбинированной номограммы, объединяющей радиомику на основе глубокого обучения, для клинической диагностики IgA-нефропатии	Глубокое обучение	ROC-кривая модели радиомики: 0,816; ROC-кривая модели глубокого обучения: 0,844; ROC комбинированной номограммы: 0,884	Комбинированная номограмма в сочетании с независимыми клиническими факторами риска показала сильную дискриминацию и клиническую применимость
25	Papp L. et al. (2025) [41]	Не указан	Мужчины	52	Машинное обучение с учителем для определения характера поражения при первичном раке предстательной железы с помощью ПЭТ/МРТ [68Ga] Ga-PSMA-11	Машинное обучение с учителем	Точность стандартного анализа на основе ПСА, индекса Глисона и стадии TNM: 69% и 70% для прогнозирования BCR и OPR соответственно Точность моделей MBCR и MOPR: 89% и 91% соответственно	Модели на основе радиомики ПЭТ/МРТ и машинного обучения показали более высокую точность по сравнению со стандартным анализом

Таблица 1 – Характеристика исследований (продолжение)

№	Автор исследования (год)	Возраст (лет)	Пол (М/Ж)	Размер выборки	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
26	Bhattarai S. et al. (2019) [42]	Не указан	Женщины	Не указан	Прогнозирование скорости роста рака молочной железы in vivo на основе машинного обучения	Машинное обучение	Surr-INVIGOR стратифицировала опухоли и совпала с SM-INVIGOR в когорте исследования; в когорте валидации выявила значительные различия в выживаемости между пациентами с быстрорастущими и медленно растущими опухолями	Surr-INVIGOR прогнозирует скорость роста рака молочной железы in vivo и предлагает несколько полезных вариантов применения
27	Fang S. et al. (2024) [43]	Не указан	Не указан	545	Диагностика и оценка степени атрофии желудка и кишечной метаплазии с помощью полуконтролируемого глубокого обучения на патологических изображениях	Чувствительность и специфичность патологоанатомов не указаны	AUC для диагностики атрофии: 0,877; чувствительность: 80%; специфичность: 85%	GasMIL превзошёл результаты всех десяти патологоанатомов в диагностике атрофии и показал улучшение показателей AUC, чувствительности и специфичности при диагностике интрамуральной опухоли
28	van Beek EJR. (2023) [44]	Диапазон возраста: 13–102 года	Мужчины: 49% Женщины: 51%	1960	Lunit INSIGHT CXR (версия 3.1.2.0)	Полуконтролируемое глубокое обучение	AUC: 0,881–0,999 (ED)	AUROC алгоритма сопоставима с экспертами, за исключением выпота ($p < 0,001$)
29	Lu Q. et al. (2023) [45]	Средний возраст: 62,1 года	Мужчины: 23; Женщины: 17	40	Анализ движений глаз под 5-цветными стимулами + RF	Машинное обучение (SVM)	AUC: 88,45 (красный стимул); F1: 85,47	RF и CatBoost показали наилучшие результаты
30	Huang Z. et al. (2022) [46]	Не указан	Не указан	393	Классификация свойств «холод-жар» по молекулярным данным	Машинное обучение (RF, CatBoost и др.)	AUC: 0,82	Модель выявляет структурные различия молекул
31	Liu Y. et al. (2022) [47]	22–45	Женщины	663	GBDT на основе конституции ТКМ и клинических данных	RF + GNB	AUC для диагностики атрофии: 0,877; чувствительность: 80%; специфичность: 85%	GBDT показал наилучший результат среди 8 моделей

Исходя из данных таблицы 1, можно сделать вывод, что метрики разработанных моделей указывают на удовлетворительное или хорошее качество, что определяется чувствительностью, специфичностью, диагностической точностью, площадью под кривой AUC. Созданные алгоритмы продемонстрировали улучшенную производительность по сравнению с результатами работы врача, который традиционными методами, в том числе визуально, определял вероятность наличия патологического состояния. Важным аспектом является то, что разработанные модели проходят проверку на тестовой выборке и валидационной выборке, что позволяет судить об эффективности применения ИИ для задач практического здравоохранения.

Таким образом, такие методы ИИ, как машинное обучение, нейронные сети, применялись наиболее часто; случайный лес и нейронные сети продемонстрировали наибольшую точность; основные параметры в проанализированных публикациях — чувствительность, специфичность, ROC-анализ, AUC. Исследователями отмечены следующие недостатки и ограничения: если система обучена на недостаточно репрезентативных данных, она может демонстрировать предвзятость к определённым группам пациентов; многие современные алгоритмы, особенно основанные на глубоком обучении, не могут объяснить логику своих решений. Наиболее перспективные направления для будущих исследований включают анализ данных с носимых устройств, когда нейросеть сможет корректировать дозу препаратов и предупреждать врача о риске обострения, анализ генетических мутаций опухоли и предложение оптимальной комбинации препаратов, внедрение круглосуточных консультантов, отслеживающих режим приёма лекарств и динамику состояния.

ОБСУЖДЕНИЕ

Существует два основных метода выявления заболеваний, в том числе онкологических, ССЗ, инфекционных (туберкулез) на ранней стадии: скрининг и диагностика. Скрининг — это диспансеризация большого количества потенциально здоровых пациентов с целью выявления больных людей, требующих последующего индивидуального обследования, диагностика — персонализированное обследование пациентов с определенным набором жалоб. Указанные методы обладают

своей спецификой. Скрининг позволяет обнаружить бессимптомное течение заболевания в ходе проведения массового обследования большой выборки, диагностика способствует детальному обследованию пациентов с жалобами для исключения или подтверждения наличия патологии.

Несмотря на кажущееся преимущество, для метода скрининга характерен ряд сложностей, препятствующих повышению ранней диагностики заболевания. Из-за большого объема исследований затягивается процесс постановки диагноза. С целью уменьшения влияния данного фактора разработаны технологии ИИ, которые активно развиваются и используются в разных областях общественной жизни. Многие авторы подчеркивают существенную экономию времени, потраченного на подготовку заключений. Оптимальная точка отсечения для скрининговых исследований должна определяться исходя из показателя максимальной предсказательной способности отрицательных результатов [1, 4]. Технология «компьютерное зрение» (Computer Vision) для автоматической интерпретации исследований МРТ, КТ, флюорографии и маммографии является современным ИИ-решением, применяемым в лучевой диагностике.

Особенности использования ИИ в выявлении заболеваний продиктованы основными принципами работы. Здесь можно подчеркнуть роль ИИ как помощника врача, а не его замены. Основные положения включают двойную проверку результатов, сопоставление выводов ИИ с мнением специалиста, защиту медицинских данных, необходимость дополнительного обучения систем. Несмотря на очевидные преимущества использования ИИ для задач практикующего врача, существует ряд ограничений. Это необходимость в качественных обучающих базах данных, правовые и этические вопросы, включая защиту персональных данных, потребность в верификации и сертификации ИИ-решений [48–50]. Применение ИИ требует формирование набора данных. Размерность и полнота заполнения набора данных будет определять результат работы.

В ближайшие годы ожидается более широкое внедрение ИИ в медицинскую деятельность, что предоставит возможность значительно улучшить уровень профилактики и ранней диагностики различных заболеваний, в первую очередь, жизнеугрожающих и смертельных состояний.

ЗАКЛЮЧЕНИЕ

Наибольший прогресс в применении ИИ отмечен в расшифровке рентгеновских снимков, МРТ и КТ. ИИ зарекомендовал себя ещё в период пандемии COVID-19 при анализе снимков оптической когерентной томографии. Перспективы включают персонализированное лечение, что обеспечивается комплексной оценкой генетических данных, анамнеза, биомаркеров, результатов анализов с помощью ИИ; системы прогнозирования осложнений хронических заболеваний на основе постоянного мониторинга, технологию анализа микробиома для

диагностики широкого спектра патологий. При этом выделяются определенные ограничивающие аспекты: необходимы структурированные и размеченные данные для проведения качественных исследований в области медицинской диагностики; скептицизм медицинского сообщества и пациентов (как медицинский персонал, так и пациенты с осторожностью относятся к прогнозам и прогнозам ИИ); правовые стандарты (в российском законодательстве до сих пор не существует определённых стандартов, которые регламентируют работу медицинских ИИ-сервисов).

ЛИТЕРАТУРА/REFERENCES

1. Морозов С.П., Владимирский А.В., Гомболевский В.А., Кляшторный В.Г., Федулова И.А., Власенков Л.А. Искусственный интеллект в скрининге рака легкого: оценка диагностической точности алгоритма для анализа низкодозовых компьютерных томографий // Туберкулёз и болезни лёгких. — 2020. — Т.98. — №8. — С.24-31. [Morozov SP, Vladimirovskiy AV, Gombolevskiy VA, Klyashtorniy VG, Fedulova IA, Vlasenkov LA. Artificial intelligence in lung cancer screening: assessment of the diagnostic accuracy of the algorithm analyzing low-dose computed tomography. Tuberculosis and Lung Diseases. 2020; 98(8): 24-31. (In Russ.)] doi: 10.21292/2075-1230-2020-98-8-24-31.
2. Pei Q, Luo Y, Chen Y, Li J, Xie D, Ye T. Artificial intelligence in clinical applications for lung cancer: diagnosis, treatment and prognosis. Clin Chem Lab Med. 2022; 60(12): 1974-1983. doi: 10.1515/cclm-2022-0291.
3. Качаева Г.И., Мустафаев А.Г. Использование нейросетевых методов для автоматического анализа электрокардиограмм при диагностике заболеваний сердечно-сосудистой системы. Вестник Дагестанского государственного технического университета // Технические науки. — 2018. — №45(2). — С.114-124. [Kachaeva GI, Mustafayev AG. The use of neural networks for the automatic analysis of electrocardiograms in diagnosis of cardiovascular diseases. Herald of Dagestan State Technical University. Technical Sciences. 2018; 45(2): 114-124. (In Russ.)] doi: 10.21822/2073-6185-2018-45-2-114-124.
4. Бородулина Е.А., Гогоберидзе Ю.Т., Просвиркин И.А. и др. Оценка эффективности использования технологий искусственного интеллекта для скрининга заболеваний легких в муниципальной больнице // Сибирский журнал клинической и экспериментальной медицины. — 2025. — №40(1). — С.209-217. [Borodulina EA, Gogoberidze YT, Prosvirkin IA, et al. Effectiveness of artificial intelligence for lung disease screening in a municipal hospital. Siberian Journal of Clinical and Experimental Medicine. 2025; 40(1): 209-217. (In Russ.)] doi: 10.29001/2073-8552-2025-40-1-209-217.
5. Segar MW, Vaduganathan M, Patel KV, et al. Machine Learning to Predict the Risk of Incident Heart Failure Hospitalization Among Patients With Diabetes: The WATCH-DM Risk Score Diabetes Care 2019; 42: 2298-2306. doi: 10.2337/dc19-0587.
6. Сервис поддержки принятия врачебных решений для диагностики новообразований кожи ПроРодинки по ТУ 58.29.32-001-43490523-2022. Регистрационное удостоверение медицинского изделия. № РЗН 2023/21776, Приказ от 27.12.23 №9743. [Servis podderzhki prinyatiya vrachebnyh reshenij dlya diagnostiki novoobrazovanij kozhi ProRodinki po TU 58.29.32-001-43490523-2022. Registracionnoe udostoverenie medicinskogo izdeliya. № RZN 2023/21776, Prikaz ot 27.12.23 №9743. (In Russ.)]
7. Freeman K, Dinnes J, Chuchu N, et al. Algorithm based smartphone apps to assess risk of skin cancer in adults: systematic review of diagnostic accuracy studies. BMJ. 2020; 368: m127. doi: 10.1136/bmj.m127.
8. Владимирова Ю.В., Тюриков М.И., Лоскутов И.А., Каталевская Е.А. Программа скрининга диабетической ретинопатии на основе алгоритмов искусственного интеллекта // Эффективная фармакотерапия. — 2024. — №20(15): 60-63. [Vladimirova YUV, Tyurikov MI, Loskutov IA, Kataljevskaya EA. Programma skrininga diabeticheskoj retinopatii na osnove algoritmov iskusstvennogo intellekta. Effektivnaya farmakoterapiya. 2024; 20(15): 60-63. (In Russ.)] doi: 10.33978/2307-3586-2024-20-15-60-63.
9. Ezra Receives 510(k) FDA Clearance for AI that enhances MRI, enabling fast, low-cost scans.

10. Perelomova PA. Automatic recognition of pathologies on X-ray, CT and MRI images. *International scientific journal Bulletin of Science*. 2025; 1(3)(84): 520-525.
11. Varma N, Cygankiewicz I, Turakhia M. 2021 ISHNE/HRS/EHRA/APHRs Collaborative Statement on mHealth in Arrhythmia Management: Digital Medical Tools for Heart Rhythm Professionals. *Russian Journal of Cardiology*. 2021; 26(15): 4420.
12. Ilhan B, Lin K, Guneri P, Wilder-Smith P. Improving Oral Cancer Outcomes with Imaging and Artificial Intelligence. *J Dent Res*. 2020; 99(3): 241-248. doi: 10.1177/0022034520902128.
13. Pitchika V, Büttner M, Schwendicke F. Artificial intelligence and personalized diagnostics in periodontology: A narrative review. *Periodontol 2000*. 2024; 95(1): 220-231. doi: 10.1111/prd.12586.
14. Mertens S, Krois J, Cantu AG, Arsiwala LT, Schwendicke F. Artificial intelligence for caries detection: Randomized trial. *J Dent*. 2021; 115: 103849. doi: 10.1016/j.jdent.2021.103849.
15. Shmatko A, Ghaffari Laleh N, Gerstung M, Kather JN. Artificial intelligence in histopathology: enhancing cancer research and clinical oncology. *Nat Cancer*. 2022; 3(9): 1026-1038. doi: 10.1038/s43018-022-00436-4.
16. Koski E, Murphy J. AI in Healthcare. *Stud Health Technol Inform*. 2021; 284: 295-299. doi: 10.3233/SHTI210726. PMID: 34920529.
17. Li JO, Liu H, Ting DSJ, et al. Digital technology, tele-medicine and artificial intelligence in ophthalmology: A global perspective. *Prog Retin Eye Res*. 2021; 82: 100900. doi: 10.1016/j.preteyeres.2020.100900.
18. Sung J. Artificial intelligence in medicine: Ethical, social and legal perspectives. *Ann Acad Med Singap*. 2023; 52(12): 695-699. doi: 10.47102/annals-acadmedsg.2023103.
19. Lorkowski J, Kolaszyńska O, Pokorski M. Artificial Intelligence and Precision Medicine: A Perspective. *Adv Exp Med Biol*. 2022; 1375: 1-11. doi: 10.1007/5584_2021_652.
20. Wang D, Li J, Sun Y, et al. A Machine Learning Model for Accurate Prediction of Sepsis in ICU Patients. *Front Public Health*. 2021; 9: 754348. doi: 10.3389/fpubh.2021.754348.
21. Cikes M, Sanchez-Martinez S, Claggett B, et al. Machine learning-based phenotyping in heart failure to identify responders to cardiac resynchronization therapy. *Eur J Heart Fail*. 2019; 21(1): 74-85. doi: 10.1002/ejhf.1333.
22. Wijnberge M, Geerts BF, Hol L, et al. Effect of a Machine Learning-Derived Early Warning System for Intraoperative Hypotension vs Standard Care on Depth and Duration of Intraoperative Hypotension During Elective Noncardiac Surgery: The HYPE Randomized Clinical Trial. *JAMA*. 2020; 323(11): 1052-1060. doi: 10.1001/jama.2020.0592.
23. Januzzi JL, Sattar N, Vaduganathan M, Magaret CA, et al. A validated multivariable machine learning model to predict cardio-kidney risk in diabetic kidney disease. *Cardiovasc Diabetol*. 2025; 24(1): 213. doi: 10.1186/s12933-025-02779-5.
24. Kann BH, Likitlersuang J, Bontempi D, et al. Screening for extranodal extension in HPV-associated oropharyngeal carcinoma: evaluation of a CT-based deep learning algorithm in patient data from a multicentre, randomised de-escalation trial. *Lancet Digit Health*. 2023; 5(6): e360-e369. doi: 10.1016/S2589-7500(23)00046-8.
25. Ginder C, Li J, Halperin JL, et al. Predicting Malignant Ventricular Arrhythmias Using Real-Time Remote Monitoring. *J Am Coll Cardiol*. 2023; 81(10): 949-961. doi: 10.1016/j.jacc.2022.12.024.
26. Yu W, Lu Y, Shou H, et al. A 5-year survival status prognosis of nonmetastatic cervical cancer patients through machine learning algorithms. *Cancer Med*. 2023; 12(6): 6867-6876. doi: 10.1002/cam4.5477.
27. Bertocelli CM, Latalski M, Bertocelli D, et al. Prediction Model for Identifying Computational Phenotypes of Children with Cerebral Palsy Needing Neurotoxin Treatments. *Toxins (Basel)*. 2022; 15(1): 20. doi: 10.3390/toxins15010020.
28. Su Z, Huang F, Yin C, Yu Y, Yu C. Clinical model of pulmonary metastasis in patients with osteosarcoma: A new multiple machine learning-based risk prediction. *J Orthop Surg (Hong Kong)*. 2023; 31(2): 10225536231177102. doi: 10.1177/10225536231177102.
29. Wang H, Liu Y, Li Y. Study on Automatic Multi-Classification of Spine Based on Deep Learning and Postoperative Infection Screening. *J Healthc Eng*. 2022; 2022: 2779686. doi: 10.1155/2022/2779686.
30. Yu Y, He Z, Ouyang J, et al. Magnetic resonance imaging radiomics predicts preoperative axillary lymph node metastasis to support surgical decisions and is associated with tumor microenvironment in invasive breast cancer: A machine learning, multicenter study. *EBioMedicine*. 2021; 69: 103460. doi: 10.1016/j.ebiom.2021.103460.
31. Chen Y, Tian X, Fan K, Zheng Y, Tian N, Fan K. The Value of Artificial Intelligence Film Reading System Based on Deep Learning in the Diagnosis of Non-Small-Cell Lung Cancer and the Significance of Efficacy Monitoring: A Retrospective, Clinical, Nonrandomized, Controlled Study. *Comput Math Methods Med*.

- 2022; 2022: 2864170. doi: 10.1155/2022/2864170. Retraction in: *Comput Math Methods Med.* 2023 Oct 4; 2023: 9823173. doi: 10.1155/2023/9823173.
32. Hill NR, Groves L, Dickerson C, et al. Identification of undiagnosed atrial fibrillation using a machine learning risk prediction algorithm and diagnostic testing (PULsE-AI) in primary care: cost-effectiveness of a screening strategy evaluated in a randomized controlled trial in England. *J Med Econ.* 2022; 25(1): 974-983. doi: 10.1080/13696998.2022.2102355.
 33. Ohno Y, Aoyagi K, Arakita K, Doi Y, et al. Newly developed artificial intelligence algorithm for COVID-19 pneumonia: utility of quantitative CT texture analysis for prediction of favipiravir treatment effect. *Jpn J Radiol.* 2022; 40(8): 800-813. doi: 10.1007/s11604-022-01270-5.
 34. George E, Flagg E, Chang K, et al. Radiomics-Based Machine Learning for Outcome Prediction in a Multicenter Phase II Study of Programmed Death-Ligand 1 Inhibition Immunotherapy for Glioblastoma. *AJNR Am J Neuroradiol.* 2022; 43(5): 675-681. doi: 10.3174/ajnr.A7488.
 35. Kobayashi M, Huttin O, Magnusson M, et al. STANISLAS Study Investigators. Machine Learning-Derived Echocardiographic Phenotypes Predict Heart Failure Incidence in Asymptomatic Individuals. *JACC Cardiovasc Imaging.* 2022; 15(2): 193-208. doi: 10.1016/j.jcmg.2021.07.004.
 36. Richette P, Vis M, Ohrndorf S, et al. Identification of PsA phenotypes with machine learning analytics using data from two phase III clinical trials of guselkumab in a bio-naïve population of patients with PsA. *RMD Open.* 2023; 9(1): e002934. doi: 10.1136/rmdopen-2022-002934.
 37. Wang X, Li J, Sun J, et al. A Machine Learning Model Based on Unsupervised Clustering Multihabitat to Predict the Pathological Grading of Meningiomas. *Biomed Res Int.* 2022; 2022: 8955227. doi: 10.1155/2022/8955227.
 38. Harper JR, Cherukuri V, O'Reilly T, Yu M, et al. Assessing the utility of low resolution brain imaging: treatment of infant hydrocephalus. *Neuroimage Clin.* 2021; 32: 102896. doi: 10.1016/j.nicl.2021.102896.
 39. Lemieux ME, Reveles XT, Rebeles J, et al. Detection of early-stage lung cancer in sputum using automated flow cytometry and machine learning. *Respir Res.* 2023; 24(1): 23. doi: 10.1186/s12931-023-02327-3.
 40. Qin X, Xia L, Ma Q, Cheng D, Zhang C. Development of a novel combined nomogram model integrating deep learning radiomics to diagnose IgA nephropathy clinically. *Ren Fail.* 2023; 45(2): 2271104. doi: 10.1080/0886022X.2023.2271104.
 41. Papp L, Spielvogel CP, Grubmüller B, et al. Supervised machine learning enables non-invasive lesion characterization in primary prostate cancer with [68Ga] Ga-PSMA-11 PET/MRI. *Eur J Nucl Med Mol Imaging.* 2021; 48(6): 1795-1805. doi: 10.1007/s00259-020-05140-y.
 42. Bhattarai S, Klimov S, Aleskandarany MA, et al. Machine learning-based prediction of breast cancer growth rate in vivo. *Br J Cancer.* 2019; 121(6): 497-504. doi: 10.1038/s41416-019-0539-x.
 43. Fang S, Liu Z, Qiu Q, et al. Diagnosing and grading gastric atrophy and intestinal metaplasia using semi-supervised deep learning on pathological images: development and validation study. *Gastric Cancer.* 2024; 27(2): 343-354. doi: 10.1007/s10120-023-01451-9.
 44. van Beek EJR, Ahn JS, Kim MJ, Murchison JT. Validation study of machine-learning chest radiograph software in primary and emergency medicine. *Clin Radiol.* 2023; 78(1): 1-7. doi: 10.1016/j.crad.2022.08.129.
 45. Lu Q. et al. Machine learning models for stroke detection by observing the eye-movement features under five-color visual stimuli in traditional Chinese medicine. *Journal of Traditional Chinese Medical Sciences.* 2023; 10(3): 321-330. doi: 10.1016/j.jtcm.2023.06.003.
 46. Zhongquan H, Yuqing L, Hongyan C, Geng L, Zhiwei L. Definition of the molecular bases of cold and hot properties of traditional Chinese medicine through machine learning. *Pharmacological Research - Modern Chinese Medicine.* 2022; 4: 100124. doi: 10.1016/j.prmcm.2022.100124.
 47. Yan L, Yangyang G, Liuqing Y, et al. Traditional Chinese Medicine Constitution and Clinical Data Association with Machine Learning for Prediction of Spontaneous Abortion. *Clinical Complementary Medicine and Pharmacology.* 2022; 2(2): 100016. doi: 10.1016/j.ccmp.2021.100016.
 48. Kolla L, Parikh RB. Uses and limitations of artificial intelligence for oncology. *Cancer.* 2024; 130(12): 2101-2107. doi: 10.1002/cncr.35307.
 49. Abdullah YI, Schuman JS, Shabsigh R, Caplan A, Al-Aswad LA. Ethics of Artificial Intelligence in Medicine and Ophthalmology. *Asia Pac J Ophthalmol (Phila).* 2021; 10(3): 289-298. doi: 10.1097/APO.0000000000000397.
 50. Pantanowitz L, Hanna M, Pantanowitz J, et al. Regulatory Aspects of Artificial Intelligence and Machine Learning. *Mod Pathol.* 2024; 37(12): 100609. doi: 10.1016/j.modpat.2024.100609.

КОБЯКОВА О.С.,

чл.-корр. РАН, д.м.н., ФГБУ «Центральный научно-исследовательский институт организации и информатизации здравоохранения» Министерства здравоохранения Российской Федерации, г. Москва, Россия; e-mail: kobyakovaos@mednet.ru; ORCID: 0000-0003-0098-1403

КАНЕВ А.Ф.,

к.м.н., ФГБУ «Центральный научно-исследовательский институт организации и информатизации здравоохранения» Министерства здравоохранения Российской Федерации, г. Москва, Россия; e-mail: alexkanev92@gmail.com; ORCID: 0000-0001-9612-8815

КУРАКОВА Н.Г.,

д.б.н., ФГБУ «Центральный научно-исследовательский институт организации и информатизации здравоохранения» Министерства здравоохранения Российской Федерации, г. Москва, Россия; e-mail: idmz@mednet.ru; ORCID: 0000-0003-1896-6420

КАРМИНА Р.Л.,

ФГБУ «Центральный научно-исследовательский институт организации и информатизации здравоохранения» Министерства здравоохранения Российской Федерации, г. Москва, Россия; e-mail: r.karmina@yandex.ru; ORCID: 0009-0006-6567-4235

ВЛИЯНИЕ ЦИФРОВИЗАЦИИ НА ПРОФЕССИОНАЛЬНЫЙ ЛАНДШАФТ МЕДИЦИНСКОЙ ОТРАСЛИ: ПОТРЕБНОСТИ РЫНКА ТРУДА И ПЕРСПЕКТИВЫ РАЗВИТИЯ (АНАЛИЗ ЗАРУБЕЖНОГО ОПЫТА)

DOI: 10.25881/18110193_2026_1_38

Аннотация. Актуальность. Внедрение цифровых технологий в систему здравоохранения оказывает глубокое и многовекторное влияние на самую ценную и уязвимую ее составляющую – человеческие ресурсы. Цифровая трансформация меняет ландшафт профессиональной деятельности, инициируя появление принципиально новых специальностей и требований к компетенциям и навыкам медицинских работников.

Цель исследования: систематизировать актуальные данные о влиянии цифровизации на потребность в медицинских кадрах, на изменение профессионального ландшафта и на требования к компетенциям медицинских работников.

Материалы и методы. Систематически проанализированы зарубежные публикации, извлеченные из баз данных Scopus, PubMed, Google Scholar с использованием поискового образа: «digital technologies» OR «artificial intelligence» or «telemedicine» and «workforce» and «healthcare». Включались все типы исследований, оценивающих влияние цифровых технологий (искусственный интеллект, телемедицина, роботизация, интернет медицинских вещей и анализ больших данных) на уровень нагрузки на медперсонал.

Результаты. В обзор вошла 61 зарубежная публикация, позволяющая отметить, что по состоянию на конец 2025 г. цифровые технологии не предлагают глобальной системе здравоохранения решения проблемы кадрового дефицита, но предоставляют комплекс инструментов, позволяющих ей функционировать более эффективно, устойчиво и качественно даже в условиях объективного глобального дефицита человеческих ресурсов. Поэтому цифровизация в большинстве публикаций, вошедших в обзор, рассматривается в качестве ключевого инструмента смягчения последствий глобального кадрового дефицита.

Заключение. Выполненный обзор обозначил перспективу глубинной трансформации ландшафта медицинских профессий. Роли врачей и медсестер эволюционируют в сторону управления данными, их критической интерпретации и усиленного взаимодействия с пациентом. Возникает устойчивый спрос на принципиально новые гибридные профессии на стыке медицины, информационных технологий и наук о данных (биоинформатики, разработчики медицинского программного обеспечения, специалисты по кибербезопасности). Для реализации потенциала цифровизации необходимы преодоление нормативных барьеров и значительная трансформация системы медицинского образования.

Ключевые слова: цифровая трансформация, система здравоохранения, кадровое обеспечение, искусственный интеллект, телемедицина, роботизация, интернет медицинских вещей, экономическая эффективность, межлицензионная практика, модели оплаты, ответственность за решения, интероперабельность.

Для цитирования: Кобякова О.С., Канев А.Ф., Куракова Н.Г., Кармина Р.Л. Влияние цифровизации на профессиональный ландшафт медицинской отрасли: потребности рынка труда и перспективы развития (анализ зарубежного опыта). *Врач и информационные технологии.* 2026; 1: 38-51. DOI: 10.25881/18110193_2026_1_38.

KOBYAKOVA O.S.,

Corresponding Member of the RAS, DSc, Russian Research Institute of Health, Moscow, Russia;
e-mail: kobyakovaos@mednet.ru; ORCID: 0000-0003-0098-1403

KANEV A.F.,

PhD, Russian Research Institute of Health, Moscow, Russia; e-mail: alexkanev92@gmail.com;
ORCID: 0000-0001-9612-8815

KURAKOVA N.G.,

DSc, Russian Research Institute of Health, Moscow, Russia; e-mail: idmz@mednet.ru;
ORCID: 0000-0003-1896-6420

KARMINA R.L.,

Russian Research Institute of Health, Russia; e-mail: r.karmina@yandex.ru;
ORCID: 0009-0006-6567-4235

THE IMPACT OF DIGITALIZATION ON THE PROFESSIONAL LANDSCAPE OF THE MEDICAL INDUSTRY: LABOR MARKET NEEDS AND DEVELOPMENT PROSPECTS (ANALYSIS OF FOREIGN EXPERIENCE)

DOI: 10.25881/18110193_2026_1_38

Abstract. *Significance.* The introduction of digital technologies into the healthcare system has a profound and multidimensional impact on its most valuable and vulnerable component - human resources. Digital transformation is changing the landscape of professional activity, leading to the emergence of fundamentally new specialties and requirements for competencies and skills of medical professionals.

Aim: to systematize current data on the impact of digitalization on the demand for medical personnel, the changing professional landscape, and the requirements for the competencies of medical professionals.

Materials and methods. We systematically analyzed international publications retrieved from Scopus, PubMed, and Google Scholar using the search terms "digital technologies," "artificial intelligence," or "telemedicine," "workforce," and "healthcare.". All types of studies assessing the impact of digital technologies (artificial intelligence, telemedicine, robotics, the Internet of Medical Things, and big data analysis) on the workload of medical staff were included.

Results. The review includes 61 international publications, which indicate that, as of the end of 2025, digital technologies do not offer the global healthcare system a solution to the workforce shortage. Instead, they provide a set of tools enabling it to function more efficiently, sustainably, and efficiently, even in the face of an objective global human resource shortage. Therefore, digitalization is considered a key tool in mitigating the consequences of the global workforce shortage in the majority of publications included in the review.

Conclusion. The review highlights the potential for a profound transformation of the medical profession landscape. physicians and nurses are evolving toward data management, critical interpretation, and enhanced patient engagement. There is a strong demand for fundamentally new hybrid professions at the intersection of medicine, information technology, and data science (bioinformaticians, medical software developers, cybersecurity specialists). Realizing the potential of digitalization requires overcoming regulatory barriers and significantly transforming the medical education system.

Keywords: digital transformation, healthcare system, human resources, artificial intelligence, telemedicine, robotics, Internet of medical things, economic efficiency, inter-license practices, payment models, responsibility for decisions, interoperability.

For citation: Kobyakova O.S., Kanev A.F., Kurakova N.G., Karmina R.L. The impact of digitalization on the professional landscape of the medical industry: labor market needs and development prospects (analysis of foreign experience). *Medical doctor and information technology.* 2026; 1: 38-51. DOI: 10.25881/18110193_2026_1_38.

ВВЕДЕНИЕ

Современная система глобального здравоохранения находится в состоянии перманентного кризиса, обусловленного демографическими сдвигами, эпидемиологическим переходом и растущими финансовыми ограничениями [1]. Старение населения, повсеместный рост распространенности хронических неинфекционных заболеваний и повышенные ожидания пациентов в отношении качества и доступности медицинской помощи создают беспрецедентную нагрузку на отработанные десятилетиями модели оказания услуг. Важным элементом этого кризиса является существенная нехватка человеческих ресурсов. Согласно прогнозам Всемирной организации здравоохранения (ВОЗ), к 2030 г. мировой дефицит медицинских работников может достичь отметки в 18 млн человек [2], что более чем вдвое превышает текущие показатели. Данный кризис усугубляется такими факторами, как профессиональное выгорание, непривлекательность условий труда в отдельных регионах и дисбаланс в распределении кадров между мегаполисами и отдаленными сельскими районами [3].

В этих условиях цифровые технологии, включая искусственный интеллект (ИИ), телемедицину, роботизацию, интернет медицинских вещей (IoMT) и анализ больших данных, повсеместно рассматриваются как ключевой инструмент для повышения операционной эффективности, качества медицинской помощи и экономической устойчивости систем здравоохранения. Правительства многих стран и международные организации возлагают на цифровизацию большие надежды в контексте преодоления вышеозначенных вызовов [4].

Хотя внедрение цифровых технологий и нельзя считать окончательным ответом на проблему кадрового дефицита, оно безусловно оказывает глубокое и многовекторное влияние на самую ценную и уязвимую составляющую любой системы здравоохранения — человеческие ресурсы [5]. Цифровая трансформация значительным образом меняет ландшафт профессиональной деятельности, модифицируя суть существующих профессий, инициируя появление принципиально новых специальностей и предъявляя экстраординарные требования к компетенциям и навыкам медицинских работников [6]. Как отмечается в отчете OECD, врачам сегодня уже недостаточно обладать лишь глубокими клиническими

знаниями — на ведущие роли выходят цифровые компетенции и способность работать в симбиозе с интеллектуальными системами [1].

Цель: систематизировать актуальные данные о влиянии цифровизации на потребность в медицинских кадрах, на изменение профессионального ландшафта и на требования к компетенциям медицинских работников.

МАТЕРИАЛЫ И МЕТОДЫ

Систематически проанализированы зарубежные публикации, извлеченные из баз данных Scopus, PubMed, Google Scholar с использованием поискового образа: «digital technologies» OR «artificial intelligence» or «telemedicine» and «workforce» and «healthcare».

Включались все типы исследований, оценивающих влияние цифровых технологий (ИИ, телемедицина, роботизация, интернет медицинских вещей и анализ больших данных) на уровень нагрузки на медперсонал. Двое авторов независимо отбирали публикации иностранных авторских коллективов и извлекали данные, объединенные в качественный синтез.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Всего в обзор была включена 61 публикация, размер выборок и контексты вошедших в обзор публикаций существенно различались. Ниже представлены ключевые результаты по пяти главным аспектам анализа, подкрепленные конкретными примерами из литературы.

Влияние цифровизации на кадровый дефицит в здравоохранении

Анализ массива литературных данных однозначно указывает на то, что цифровые технологии, вопреки некоторым опасениям и (или) надеждам, не ведут к прямому и масштабному сокращению общей численности медицинских кадров. Вместо простого замещения человеческого труда машинным они действуют как мощный мультипликатор эффективности и инструмент оптимизации, позволяя существующему кадровому составу обслуживать больше пациентов без потери, а зачастую и с повышением качества оказываемой медицинской помощи [7].

Автоматизация рутинных задач. Ключевым механизмом данного процесса является автоматизация рутинных, ресурсоемких и

поддающихся алгоритмизации задач. Это высвобождает значительные временные ресурсы высококвалифицированных специалистов, которые могут быть перенаправлены на прямое взаимодействие с пациентом и решение сложных диагностических и терапевтических задач, требующих применения клинического мышления [8]. Ярче всего этот эффект проявляется в диагностических специальностях, работающих с большими массивами стандартизированных данных. Важно подчеркнуть, что речь не идет о замене врача, а о перераспределении его рабочего времени от рутинного скрининга к сложным случаям, верификации и интерпретации данных.

Так, в исследовании, проведенном в больнице Яньтай Юйхуандин, центре рака Фуданского университета и Гуандунской больнице охраны здоровья матери и ребенка, применение технологии ИИ для анализа изображений, полученных во время маммографии, увеличивало точность выявления новообразований молочной железы на 12,4%, при этом скорость анализа составляла в среднем всего 3 секунды против шести минут, необходимых врачу-диагносту [9]. Подобное исследование было проведено и на базе Университетской больницы Королевы Софии в Испании: применение ИИ для скрининга рака молочной железы увеличивало чувствительность метода на 25%, одновременно уменьшая нагрузку на врачей на 29,7% [10].

В госпитале медицинского университета Южной Каролины ИИ сократил время интерпретации КТ-снимков грудной клетки на 93 секунды [11]. В центральной больнице Фушуня провинции Ляонин в Китае, стратегия скрининга переломов ребер, основанная на применении ИИ, оказалась точнее и быстрее, чем стандартный анализ рентгеновских снимков [12].

Вместе с тем, коллектив Цзиньлинской больницы пришел к выводу, что анализ КТ-изображений головного мозга с помощью ИИ имеет куда меньшую специфичность в отношении выявления интракраниальных аневризм по сравнению со случаями, когда диагностический процесс осуществляет специалист-радиолог [13]. Тем не менее, по мнению авторов статьи, технологии ИИ в любом случае имеют определенную ценность для диагностического процесса: за счет исключительной чувствительности их применение позволяет значительно снизить рабочую нагрузку на

медицинский персонал. Подобные результаты получены коллективом упомянутого медицинского учреждения и в отношении выявления поражений легких при коронавирусной инфекции [14]. Сходного мнения придерживаются авторы из университетского медицинского центра Гронингена, оценивавшие возможность применения ИИ для диагностики солидных образований в легких [15]. С другой стороны, существуют и более сдержанные оценки ценности ИИ в автоматизации диагностического процесса: по данным исследователей из университетского госпиталя Бонна, за счет более длительной загрузки изображений в программу анализа ИИ не смог снизить время, затрачиваемое на оценку изображений [16].

В целом, однако, результаты использования ИИ для решения рутинных диагностических задач выглядят более, чем оптимистичными. Так, время, затрачиваемое на исследование биопсийного материала желудка, сокращается более, чем на 90% [17]. Столь же значительная эффективность наблюдается в урологии в отношении диагностики рака простаты [18], в неврологии (сокращение времени просмотра видеомониторинга для диагностики эпилепсии на 86%) [19] и в гематологии (сокращение времени анализа проб периферической крови на 62,7%) [20]. В офтальмологии использование ИИ делает диагностику диабетической ретинопатии быстрее на 37%, аномалий роговицы — на 99% [21, 22]. Пациенты положительно относятся к использованию ИИ в диагностике и лечении [23] при условии, что ключевая роль в интерпретации результатов, принятии решений и выстраивании взаимодействия с пациентами останется за врачами [24].

Не менее важным направлением является автоматизация административной нагрузки. Внедрение голосовых ассистентов с распознаванием речи, как показала практика клиники Мейо, позволило сократить время, затрачиваемое медсестрами на подготовку медицинской документации, на 40%, что высвободило ресурсы для непосредственного ухода за пациентами [25]. Алгоритмы для прогнозного планирования штатного расписания с применением технологии анализа больших данных (исторические показатели госпитализации, сезонность) с высокой точностью предсказывают пиковую нагрузку, позволяя избежать как недоукомплектованности, ведущей к выгоранию, так и неэффективного

избытка кадров [26]. В частности, такие ассистенты уже внедрены в госпиталях Британской Колумбии в Канаде [27].

Телемедицина и удаленный мониторинг состояния пациента. Вторым мощным инструментом оптимизации, позволяющим в условиях дефицита кадров обеспечивать максимальное покрытие населения медицинскими услугами, является телемедицина и удаленный мониторинг состояния пациентов. Эти технологии кардинально меняют географию оказания медицинской помощи, позволяя узким специалистам и консилиумам экспертов из крупных медицинских центров консультировать пациентов и коллег в удаленных, сельских и малообеспеченных регионах (т.н. «кадровых пустынях»), не прибегая к физическому перемещению. Одним из подобных примеров может служить стратегическая цель, которую поставило перед собой министерство здравоохранения Израиля. Согласно его пресс-релизу, одна из приоритетных задач ближайшего времени — «совершить скачок в системе здравоохранения, который позволит ей стать устойчивой, передовой, инновационной, обновленной и постоянно совершенствующейся за счет оптимального использования информационных и коммуникационных технологий, доступных всему населению Израиля». Первым шагом на пути к реализации данной задачи стало создание специального «общества телездравоохранения» из специалистов, работающих в области телемедицины. Также было создано несколько рабочих групп по различным специальностям (таким как телепедиатрия и телегериатрия), чтобы определить рабочие практики и сформулировать рекомендации для Министерства в сфере телемедицины [28].

Таким образом, телемедицина не сокращает потребности в кадрах, но радикально повышает доступность и «масштабируемость» уникальной экспертизы уже существующих специалистов, эффективно нивелируя географическое неравенство. Кроме того, телемедицинские платформы создают прецедент, т.н. модели «медицинского дома» (Patient-Centered Medical Home), позволяя врачу первичного звена оперативно получать консультации специалистов, не направляя пациента в другой город, тем самым повышая собственные диагностические возможности и компетенцию. Концепция «медицинского дома», в частности, разрабатывается

Агентством по исследованиям и качеству в здравоохранении США [29].

Влияние цифровизации на профессиональный ландшафт глобального здравоохранения

Цифровая трансформация приводит к глубокому и необратимому перераспределению профессиональных ролей и функций внутри медицинских организаций. Этот процесс характеризуется не исчезновением существующих профессий, а их глубокой эволюцией и появлением принципиально новых гибридных специальностей, что значительно меняет кадровый ландшафт отрасли [30].

Эволюция и специализация существующих ролей является наиболее вероятным трендом. Роль врача трансформируется от универсального эксперта-исполнителя, выполняющего весь цикл от сбора данных до постановки диагноза и назначения лечения, к роли «супервайзера данных», куратора и интерпретатора выводов, сгенерированных интеллектуальными системами [31]. Врач все больше сосредотачивается на стратегическом планировании лечения, комплексной коммуникации с пациентом и принятии окончательных решений в сложных, нестандартных и этически неоднозначных случаях, где машина не может заменить человеческое суждение и эмпатию. Его функция смещается от «действия» к «мышлению» и «взаимодействию».

Примером трансформации роли врача за счет внедрения в рутинную практику технологий ИИ может служить использование ассистента Transpara, уже вошедшего в состав базового обследования, например, в Швеции [32]. Система обеспечивает первичный скрининг маммограмм, в результате чего врачи, анализируя уже обработанные результаты, могут сконцентрировать внимание на найденных ассистентом аномалиях. Таким образом, врач становится экспертом, контролирующим выполнение рутинных задач и принимающим сложные диагностические решения. Еще один аналогичный инструмент — qure.ai, используется в больницах по всему миру (от Англии до Нигерии) для предварительного анализа КТ легких и головного мозга, позволяя значительно сократить затрачиваемое медицинскими работниками время [33, 34].

Использование ИИ, однако, не ограничивается предварительным анализом изображений.

Так, система IBM Watson for Oncology, внедренная в ряде медицинских учреждений Китая, помогает подобрать индивидуализированное лечение опухолей [35], а коммерческое приложение Siemens Healthineers Teamplay позволяет оптимизировать использование диагностического оборудования [36], агрегируя данные с томографов Siemens, анализируя дозы облучения, время исследования, и используемые протоколы. Во всех этих случаях врач становится экспертом, управляющим ИИ ассистентами, принимающим решения на основе собранной ими информации.

Широко применяются в настоящее время голосовые ассистенты, ускоряющие процессы ведения медицинской документации. Например, в США массово востребован ассистент *suki.ai*, позволяющий фиксировать аудио-данные в электронной истории болезни, а также предоставляет элементы поддержки принятия решений) [37].

Трансформация профессиональных ролей под влиянием цифровых технологий в равной степени характерна и для среднего медицинского персонала. Перевод в автоматический режим таких рутинных процессов, как мониторинг витальных функций, документирование и контроль выполнения назначений, создает условия для перераспределения обязанностей. Высвобождающийся временной ресурс позволяет медсестрам осваивать расширенные клинические полномочия, что повышает уровень их профессиональной автономии. На практике это выражается в переходе от исполнительских функций к роли оператора и координатора. Например, работа с системами автоматизированной выдачи лекарств (типа *Ruxis MedStation* [38]) сводит к минимуму ошибки дозирования [39], а интегрированные с электронной историей болезни платформы удаленного мониторинга (такие как *Philips eCareCoordinator* [40]) предоставляют медсестре уже проанализированные данные. Это смещает фокус с механического сбора информации на интерпретацию готовых показателей и принятие решений в рамках доверенной зоны ответственности.

Параллельно с эволюцией традиционных ролей наблюдается стремительное зарождение «гибридных» профессий, что формирует абсолютно новую нишу на рынке труда. Возникает устойчивая потребность в специалистах на стыке медицины, компьютерных наук, инженерии и анализа данных [41]. Прежде всего,

это биоинформатики и аналитики медицинских данных, отвечающие за сбор, очистку, анализ и интерпретацию больших массивов медицинских данных для задач персонализированной медицины, прогнозирования эпидемий и оптимизации работы лечебных учреждений [42, 43]. Не менее востребованы специалисты по медицинской кибербезопасности, чья роль связана с защитой конфиденциальных пациентских данных в условиях роста киберугроз и ужесточения регуляторных требований [44].

Значительный импульс развития получает направление, связанное с разработкой медицинского программного обеспечения и алгоритмов ИИ. Эти специалисты создают и внедряют диагностические системы, алгоритмы поддержки принятия врачебных решений и телемедицинские платформы [45]. Для обеспечения их бесперебойной работы и соответствия клиническим потребностям требуются клинические ИТ-администраторы и координаторы цифровых программ оказания медицинской помощи, которые выступают связующим звеном между техническими подразделениями и медицинским персоналом [46]. Наконец, широкое внедрение сложных систем, от хирургических роботов-ассистентов до автоматизированных лабораторных комплексов, порождает спрос на операторов и инженеров роботизированного оборудования, обеспечивающих их эксплуатацию и техническое обслуживание [47]. Формирование этого нового профессионального ландшафта свидетельствует о глубокой трансформации отрасли, в которой технологическая грамотность становится неотъемлемым компонентом медицинского образования.

Прямого «ухода в прошлое» целых профессий в обозримой перспективе не прогнозируется, однако значительно сократится потребность в выполнении узких, рутинных, легко алгоритмируемых задач (например, первичный анализ стандартизированных диагностических изображений, рутинное документирование по шаблону) [48]. Это потребует от действующих специалистов массового обучения и повышения компетенций, а от организаторов здравоохранения — формирования юридической и материальной базы для широкого внедрения новых технологий. Анализ 11 пилотных кейсов из больниц разных стран Европы (Швейцария, Финляндия,

Германия, Дания и др.) выявил общие барьеры для широкого внедрения ИИ в практику, такие, как недоверие персонала к «черным ящикам» алгоритмов, проблемы с управлением и безопасностью медицинских данных, а также этические и регуляторные сложности [49].

Трансформация требований к компетенциям медицинского персонала

Глубинная трансформация профессиональных ролей, описанная выше, закономерно влечет за собой изменение требований к профилю компетентности современного медицинского работника. Как отмечается в отчете OECD [1], сегодня уже недостаточно обладать только глубокими фундаментальными и клиническими знаниями — их необходимо дополнять цифровыми компетенциями.

В настоящее время имеет место значительный разрыв между требуемыми и реально существующими цифровыми компетенциями медицинского персонала. В зависимости от конкретного исследования, от 30 до 70% медработников сообщают, что у них отсутствуют необходимые навыки для полноценного использования цифровых технологий и работы с цифровой информацией [50]. Этот цифровой пропасть представляет собой один из ключевых барьеров на пути успешной цифровой трансформации отрасли.

В настоящее время формируются новые требования к компетенциям медицинских работников, включающие технологические, аналитические, коммуникативные и этико-правовые аспекты [51]. Необходимым условием для эффективной работы становится техническая и цифровая грамотность, выходящая за рамки базового владения электронными медицинскими картами и телемедицинскими платформами и предполагающая осмысленное понимание принципов работы ИИ с позиции пользователя-эксперта. Неотъемлемым компонентом становится развитая способность к анализу, визуализации и интерпретации данных для принятия клинических и управленческих решений, что особенно актуально в контексте развития предиктивной медицины. Парадоксальным образом, цифровизация усиливает значимость сугубо человеческих компетенций, таких как эмпатическая коммуникация в цифровой среде, верификация информации в условиях ее избытка и способность к цифровому наставничеству для пациентов и

коллег. Данный профиль также требует высокой этико-правовой компетентности, включающей обеспечение конфиденциальности данных, понимание правовых норм и нивелирование рисков алгоритмической предвзятости. Следовательно, центральной задачей для систем медицинского образования является разработка подходов к формированию именно такого, целостного набора компетенций.

Влияние цифровизации на условия работы, профессиональное выгорание и удержание кадров

Влияние цифровых технологий на условия труда, психологическое благополучие медицинских работников и, как следствие, на их удержание в профессии является амбивалентным и комплексным. Его конечный вектор — снижение или усиление выгорания, зависит не от самих технологий, а от качества их внедрения, интеграции в рабочий процесс и уровня поддержки, предоставляемой персоналу.

Потенциал применения цифровых технологий для снижения выгорания и удержания кадров является значительным и подтверждается многочисленными исследованиями. Он реализуется посредством снижения административной и рутинной когнитивной нагрузки на персонал. Автоматизация документооборота, выписки рецептов, составления расписаний и напоминаний напрямую устраняет один из ключевых драйверов выгорания — ощущение «бумажной» работы в ущерб оказанию медицинской помощи пациенту [52]. Оптимизация рабочей нагрузки, реализованная на основе алгоритмов ИИ для прогнозного планирования штата и динамического распределения смен, позволяют избежать хронической недоукомплектованности и необоснованных сверхурочных работ, которые являются прямой дорогой к эмоциональному истощению. Алгоритмы могут анализировать модели расписания и предлагать более справедливое распределение сложных случаев между командами [53]. Внедрение систем поддержки принятия клинических решений снижает эмоциональное бремя за счет уменьшения страха совершить ошибку [54]. Перспективным представляется внедрение системы на основе ИИ и носимых устройств для отслеживания уровня стресса и усталости сотрудников в режиме реального времени, что позволяет упреждающе

оказывать поддержку, рекомендовать перерывы или психологическую помощь [55].

Однако существуют и обратные, теневые стороны цифровизации, которые могут усугублять выгорание и недовольство, такие, как техностресс и увеличение скрытой нагрузки; подмена личного общения с пациентами данными и интерфейсами; сопротивление, тревожность и страх перед новыми технологиями; ухудшение социального климата в коллективе. Качественные исследования выявляют, что медперсонал зачастую отмечает не снижение, а рост общей нагрузки [56]. Это связано с появлением новых, неучтенных обязанностей: необходимость отвечать на бесчисленные цифровые сообщения пациентов в чатах и порталах, исправлять их ошибки при самостоятельной онлайн-записи, постоянно осваивать новые и не всегда дружелюбные интерфейсы систем без выделенного времени на обучение [57]. Многие врачи и медсестры выражают обеспокоенность тем, что работа с информационными системами и экранами постепенно подменяет собой прямое, живое взаимодействие с пациентом, ради которого многие и шли в профессию. Это ведет к экзистенциальной фрустрации, ощущению потери связи и снижению удовлетворенности от работы. Дополнительно, технологическая тревожность является сильным негативным фактором [58]. Страх сделать ошибку в новой системе, недоверие к «черному ящику» ИИ, опасения по поводу надежности оборудования и отсутствие мгновенной технической поддержки создают мощный психологический барьер и ведут к отказу от использования технологий или к их применению «из-под палки». Еще один немаловажный фактор — сокращение неформального общения между коллегами из-за тотальной цифровизации коммуникаций (внутренние чаты вместо личных разговоров) может негативно сказаться на сплоченности команды, взаимной поддержке и атмосфере в отделении, которые являются важными буферами против выгорания.

Таким образом, при грамотном, продуманном и обоснованном внедрении технологии выступают мощным инструментом удержания кадров, снижая рутинную нагрузку и повышая безопасность и предсказуемость труда. Однако при игнорировании человеческого фактора, недостатке обучения и поддержки, они же могут стать источником нового, цифрового стресса,

усугубляя проблемы выгорания и профессиональной деформации.

Проблемы нормативно-правового регулирования и обучения

Потребность в интеграции цифровых технологий в клиническую практику диктует необходимость формирования адекватных инфраструктурных условий, среди которых ключевое значение имеют адаптация нормативно-правового поля и трансформация системы непрерывного медицинского образования. Эти элементы выступают критическими факторами, от которых будет зависеть возможность полномасштабной реализации потенциала цифровизации.

В сфере нормативного регулирования актуальной задачей является преодоление ряда существующих барьеров. Значительным препятствием для развития телемедицинских сервисов остается региональная привязка лицензирования медицинской деятельности в США, которая ограничивает возможность оказания врачебной помощи за пределами территориального субъекта, где была выдана лицензия [59]. Это диктует потребность в гармонизации законодательства и разработке механизмов упрощенного межрегионального взаимодействия. Другим существенным аспектом является отсутствие устоявшихся и прозрачных моделей финансирования телемедицинских консультаций, удаленного мониторинга состояния пациентов и анализа данных, генерируемых цифровыми двойниками. Недостаточный уровень оплаты подобных услуг со стороны страховых компаний, включая государственные программы, не создает достаточных стимулов для медицинских организаций к инвестированию в соответствующие технологии. Кроме того, сдерживающим фактором выступает правовая неопределенность в вопросах разграничения ответственности при использовании систем поддержки врачебных решений на основе ИИ. Требуется разработка четких регламентов, определяющих степень ответственности разработчика алгоритма, медицинской организации и врача-пользователя, а также утверждение процедур валидации, сертификации и постмаркетингового надзора за подобными программными средствами [60]. Немаловажной проблемой остается отсутствие единых стандартов для обмена данными между разнородными

электронными медицинскими картами, телемедицинскими платформами и носимыми устройствами, что приводит к формированию информационных разрозненных систем и увеличению нагрузки на медицинский персонал. Параллельно с этим вопросы обеспечения кибербезопасности и конфиденциальности данных пациентов требуют первостепенного внимания.

Столь же значимым направлением является модернизация образовательных программ на всех уровнях подготовки медицинских кадров. Существующая система в значительной степени отстает от темпа технологических изменений, что обуславливает необходимость ее системного обновления. Первоочередной мерой представляется интеграция в учебные планы медицинских вузов и колледжей дисциплин, посвященных основам медицинской информатики, цифровой грамотности, биостатистики и этическим аспектам применения ИИ. Выпускники должны обладать не только фундаментальными клиническими знаниями, но и компетенциями для работы в цифровой среде. Для практикующих врачей и среднего медицинского персонала ключевое значение имеют программы повышения квалификации и переподготовки, направленные на преодоление цифрового разрыва [61]. Эффективность таких программ напрямую зависит от создания условий для их прохождения, включая выделение оплачиваемого рабочего времени, что исключает перекладывание нагрузки на личное время сотрудников. Важным условием успеха образовательной трансформации является подготовка самого преподавательского состава, который зачастую не обладает достаточной компетентностью для обучения работе с новыми технологиями. Активное внедрение в учебный процесс инновационных форматов, таких как симуляторы на основе виртуальной и дополненной реальности (VR/AR), онлайн-курсы, междисциплинарные проекты с ИТ-специалистами и разбор реальных клинических случаев с применением методов анализа больших данных, будет способствовать формированию практических навыков, необходимых для работы в условиях цифровизации.

ЗАКЛЮЧЕНИЕ

Результаты настоящего обзора по данным зарубежных исследований свидетельствуют, что на

конец 2025 г. цифровые технологии не предлагают глобальной системе здравоохранения решения проблемы кадрового дефицита, но предоставляют комплекс инструментов, позволяющих ей функционировать более эффективно, устойчиво и качественно даже в условиях объективного глобального дефицита человеческих ресурсов.

Цифровизация не приводит к прямому и массовому сокращению общей численности медицинских работников, но значительно меняет характер потребности в них. Система здравоохранения будущего будет нуждаться не в большом количестве врачей, выполняющих рутинные задачи, такие как анализ медицинских изображений или назначение лечения по стандарту; вместо этого возрастет потребность в высококвалифицированных специалистах, в равной степени обладающих фундаментальными клиническими знаниями и способных эффективно использовать современные технологии. Кроме того, вероятно, возрастет потребность в среднем медицинском персонале, наделенном цифровыми полномочиями для удаленного мониторинга и выполнения врачебных предписаний. Поэтому цифровизация рассматривается в качестве ключевого инструмента смягчения последствий глобального кадрового дефицита.

Выполненный обзор обозначил перспективу глубинной трансформации, а не замены медицинских профессий. Роли врачей и медсестер эволюционируют в сторону управления данными, их критической интерпретации и усиленного взаимодействия с пациентом. Параллельно возникает устойчивый спрос на принципиально новые гибридные профессии на стыке медицины, ИТ и наук о данных (биоинформатики, разработчики медицинского ПО, специалисты по кибербезопасности). Потребность в выполнении узких, рутинных задач будет неуклонно снижаться, что требует программ массового повышения квалификации

От всех медицинских работников требуются цифровая грамотность, навыки работы с данными, развитые мягкие навыки для коммуникации в цифровой среде, а также способность к критическому мышлению и этико-правовая компетентность. Преодоление цифрового разрыва среди действующих медицинских кадров является одной из самых важных задач для руководителей здравоохранения.

Технологии цифровизации являются мощным инструментом снижения рутинной нагрузки и борьбы с выгоранием (через автоматизацию, оптимизацию планирования, повышение безопасности), но лишь при условии их правильного внедрения, обеспечения адекватной технической поддержки и выделения ресурсов на обучение. В противном случае, они рискуют стать источником техностресса, увеличения скрытой нагрузки и профессиональной фрустрации, усугубляя кризис кадров.

Для реализации потенциала цифровизации необходимо преодоление нормативных барьеров (прозрачность и простота процедуры лицензирования, модели оплаты, ответственность за решения ИИ, интероперабельность) и значительная трансформация системы медицинского образования на всех уровнях — от интеграции цифровых дисциплин в базовые программы до создания системы непрерывного пожизненного обучения с гарантированным временем на освоение нового.

ЛИТЕРАТУРА/REFERENCES

1. Socha-Dietrich, K. Empowering the health workforce to make the most of the digital revolution. *OECD Health Working Papers*. 2021; 129. doi: 10.1787/37ff0eaa-en.
2. WHO guideline on health workforce development, attraction, recruitment and retention in rural and remote areas. 10.09.2025.
3. Ag Ahmed MA, Diakitè SL, Sissoko K, Gagnon MP, Charron S. Factors explaining the shortage and poor retention of qualified health workers in rural and remote areas of the Kayes, region of Mali: a qualitative study. *Rural Remote Health*. 2020; 20(3):5772. doi: 10.22605/RRH5772.
4. Yeung AWK, Torkamani A, Butte AJ, et al. The promise of digital healthcare technologies. *Front Public Health*. 2023; 11: 1196596. doi: 10.3389/fpubh.2023.1196596.
5. Al-Saleem AI, Aldakheel MK. Barriers to Workforce-Driven Innovation in Healthcare. *Cureus*. 2024; 16(10): e72316. doi: 10.7759/cureus.72316.
6. Al-Haimi B, Ali F, Hujainah F. Digital Transformation in Healthcare: Impact on Organizations' Strategies, Future Landscape, and Required Skills. In: *Navigating the Intersection of Business, Sustainability and Technology*. Contributions to Environmental Sciences & Innovative Business Technology. Springer, Singapore. 2023. doi: 10.1007/978-981-99-8572-2_3.
7. Jeilani A, Hussein A. Impact of digital health technologies adoption on healthcare workers' performance and workload: perspective with DOI and TOE models. *BMC Health Serv Res* 25, 271(2025). doi: 10.1186/s12913-025-12414-4.
8. Mohd J, Abid H, Ravi PS. Health informatics to enhance the healthcare industry's culture: An extensive analysis of its features, contributions, applications and limitations. *Informatics and Health*. 2024; 1(2): 123-148. doi: 10.1016/j.infoh.2024.05.001.
9. Zheng T, Lin F, Li X, et al. Deep learning-enabled fully automated pipeline system for segmentation and classification of single-mass breast lesions using contrast-enhanced mammography: a prospective, multicentre study. *EClinicalMedicine*. 2023; 58: 101913. doi: 10.1016/j.eclinm.2023.101913.
10. Raya-Povedano JL, Romero-Martín S, Elías-Cabot E, et al. AI-based Strategies to Reduce Workload in Breast Cancer Screening with Mammography and Tomosynthesis: A Retrospective Evaluation. *Radiology*. 2021; 300(1): 57-65. doi: 10.1148/radiol.2021203555.
11. Yacoub B, Varga-Szemes A, Schoepf UJ, et al. Impact of Artificial Intelligence Assistance on Chest CT Interpretation Times: A Prospective Randomized Study. *AJR Am J Roentgenol*. 2022; 219(5): 743-751. doi: 10.2214/AJR.22.27598.
12. Li N, Wu Z, Jiang C, Sun L, et al. An automatic fresh rib fracture detection and positioning system using deep learning. *Br J Radiol*. 2023; 96(1146): 20221006. doi: 10.1259/bjr.20221006.
13. Shi Z, Miao C, Schoepf UJ, et al. A clinically applicable deep-learning model for detecting intracranial aneurysm in computed tomography angiography images. *Nat Commun*. 2020; 11(1): 6090. doi: 10.1038/s41467-020-19527-w.
14. Ni Q, Sun ZY, Qi L, et al. A deep learning approach to characterize 2019 coronavirus disease (COVID-19) pneumonia in chest CT images. *Eur Radiol*. 2020; 30(12): 6517-6527. doi: 10.1007/s00330-020-07044-9.
15. Lancaster HL, Zheng S, Aleshina OO, et al. Outstanding negative prediction performance of solid pulmonary nodule volume AI for ultra-LDCT baseline lung cancer screening risk stratification. *Lung Cancer*. 2022; 165: 133-140. doi: 10.1016/j.lungcan.2022.01.002.
16. Wenderott K, Krups J, Luetkens JA, et al. Prospective effects of an artificial intelligence-based computer-aided detection system for prostate imaging on routine workflow and radiologists' outcomes. *Eur J Radiol*. 2024; 170: 111252. doi: 10.1016/j.ejrad.2023.111252.

17. Yang R, Yan C, Lu S, et al. Tracking cancer lesions on surgical samples of gastric cancer by artificial intelligent algorithms. *J Cancer*. 2021; 12: 6473-83.
18. Eloy C, Marques A, Pinto J, et al. Artificial intelligence-assisted cancer diagnosis improves the efficiency of pathologists in prostatic biopsies. *Virchows Arch*. 2023; 482: 595-604.
19. Peltola J, Basnyat P, Armand Larsen S, et al. Semiautomated classification of nocturnal seizures using video recordings. *Epilepsia*. 2023; 64(Suppl 4): S65-71.
20. Katz BZ, Feldman MD, Tessema M, et al. Evaluation of Scopio Labs X100 Full Field PBS: the first high-resolution full field viewing of peripheral blood specimens combined with artificial intelligence-based morphological analysis. *Int J Lab Hematol*. 2021; 43: 1408-16.
21. Yan Y, Jiang W, Zhou Y, et al. Evaluation of a computer-aided diagnostic model for corneal diseases by analyzing in vivo confocal microscopy images. *Front Med (Lausanne)*. 2023; 10: 1164188.
22. Yang Y, Pan J, Yuan M, et al. Performance of the AIDRScreening system in detecting diabetic retinopathy in the fundus photographs of Chinese patients: a prospective, multicenter, clinical study. *Ann Transl Med*. 2022; 10: 1088.
23. Tancredi C, Ibba S, Fantesini A, et al. Capturing patient voices: A focus group-based study unveiling the potential of AI in medical diagnosis. *Human Technology*. 2024; 20(3): 541-557. doi: 10.14254/1795-6889.2024.20-3.6.
24. Ali M, Fantesini A, Morcella MT, et al. Adoption of AI in Oncological Imaging: Ethical, Regulatory, and Medical-Legal Challenges. *Critical Reviews™ in Oncogenesis*. 2024; 29(2).
25. Bongurala AR, Save D, Virmani A, Kashyap R. Transforming health care with artificial intelligence: redefining medical documentation. *Mayo Clin Proc Digit Health*. 2024; 2(3): 342-347.
26. Căvescu AM, Popescu N. Predictive Analytics in Human Resources Management: Evaluating AIHR's Role in Talent Retention. *AppliedMath*. 2025; 5: 99. doi: 10.3390/appliedmath5030099.
27. Fraser Health Advances AI in Healthcare with Digital Navigator and Scheduling Innovations. <https://www.startupecosystem.ca/news/fraser-health-advances-ai-in-healthcare-with-digital-navigator-and-scheduling-innovations/>
28. Ministry of Health Israel. Government of Israel, Ministry of Health. National Plan for Digital. <https://www.health.gov.il/About/projects/DigitalHealth/Pages/default.aspx>.
29. Rojas SL, Ashok M, Morss DyS, et al. Contextual Frameworks for Research on the Implementation of Complex System Interventions [Internet]. Rockville (MD): Agency for Healthcare Research and Quality (US). 2014 Mar. Patient-Centered Medical Home Framework. <https://www.ncbi.nlm.nih.gov/books/NBK196203/>
30. Stoumpos AI, Kitsios F, Talias MA. Digital Transformation in Healthcare: Technology Acceptance and Its Applications. *Int J Environ Res Public Health*. 2023; 20(4): 3407. doi: 10.3390/ijerph20043407.
31. Liu X, Keane PA, Denniston AK. Time to regenerate: the doctor in the age of artificial intelligence. *J R Soc Med*. 2018; 111(4): 113-116. doi: 10.1177/0141076818762648.
32. <https://medical.sectra.com/case/ai-frees-up-valuable-time-for-radiologists-in-a-swedish-healthcare-region/>
33. Qure.ai impact stories. The impact of AI at The Royal Bolton NHS Hospital, UK. https://www.qure.ai/impact_stories/the-impact-of-ai-at-the-royal-bolton-nhs-hospital-uk.
34. Qure.ai impact stories. On Ground with IHVN and Fujifilm in Nigeria. https://www.qure.ai/impact_stories/on-ground-with-ihvn-and-fujifilm-in-nigeria.
35. Zou FW, Tang YF, Liu CY, Ma JA, Hu CH. Concordance Study Between IBM Watson for Oncology and Real Clinical Practice for Cervical Cancer Patients in China: A Retrospective Analysis. *Front Genet*. 2020; 11: 200. doi: 10.3389/fgene.2020.00200.
36. Siemens Healthineers. «Облачное решение teamplay — приложения для управления производительностью». <https://www.siemens-healthineers.com/ru/digital-health-solutions/digital-solutions-overview/service-line-managment-solutions/teamplay>.
37. Suki.ai. The AI infrastructure for halthcare. <https://www.suki.ai/>
38. BD Pyxis MedStation ES System. Automated dispensing cabinet for single and multi-facilities medication management. <https://www.bd.com/en-uk/products-and-solutions/products/product-families/bd-pyxis-medstation-es-system>.
39. Jung YY, Walsh Á, Patel J, Lai K. Benefits and challenges associated with implementation and ongoing use of automated dispensing cabinet for medicines: a scoping review. *Explor Res Clin Soc Pharm*. 2025; 18: 100599.
40. Philips eCareCoordinator Clinical dashboard for ambulatory health. <https://www.philips.cz/healthcare/product/HCNOCTN482/ecarecoordinator-clinical-dashboard-for-ambulatory-health>.

41. Global strategy on digital health 2020-2025. Geneva: World Health Organization; 2021.
42. Whitepaper “unlocking healthcare’s future: the invaluable role of clinical informatics”. https://www.himss.org/sites/hde/files/media/file/2024/04/18/wp_value-of-clinical-informatics-1.pdf.
43. Gyldenkærne C, Hansen JU, Hertzum M, Mønsted T. Innovation tactics for implementing an ML application in healthcare: a long and winding road. *Int J Hum Comput Stud.* 2024; 181: 103162
44. Ethics and governance of artificial intelligence for health: WHO guidance. Geneva: World Health Organization; 2021.
45. Topol, E.J. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med.* 2019; 25: 44-56. doi: 10.1038/s41591-018-0300-7.
46. <https://www.techtarget.com/searchhealthit/definition/clinical-informatics>.
47. Hamilton A. The Future of Artificial Intelligence in Surgery. *Cureus.* 2024; 16(7): e63699. doi: 10.7759/cureus.63699.
48. Gou F, Liu J, Xiao C, Wu J. Research on artificial-intelligence-assisted medicine: a survey on medical artificial intelligence. *Diagnostics (Basel).* 2024; 14: 1472.
49. Klumpp M, Hintze M, Immonen M, et al. Artificial intelligence for hospital health care: application cases and answers to challenges in European hospitals. *Healthcare (Basel).* 2021; 9: 961.
50. Closing the digital skills gap in healthcare POLICY BRIEF 72 Identifying core digital skills and competencies and education and training opportunities for health professionals in the European Union. https://eurohealthobservatory.who.int/docs/librariesprovider3/publicationsnew/policybrief-bewell-digital-v3-30042025.pdf?sfvrsn=5533673_2.
51. Jose A, Tortorella GL, Vassolo R, Kumar M, Mac Cawley AF. Professional Competence and Its Effect on the Implementation of Healthcare 4.0 Technologies: Scoping Review and Future Research Directions. *Int J Environ Res Public Health.* 2022; 20(1): 478. doi: 10.3390/ijerph20010478.
52. How to Automate Repetitive Tasks in Healthcare. Automation in healthcare industry. <https://www.aalpha.net/blog/how-to-automate-repetitive-tasks-in-healthcare/>
53. Yildirim Ş, Yücekaya AD, Hekimoğlu M, et al. AI-Driven Predictive Maintenance for Workforce and Service Optimization in the Automotive Sector. *Appl. Sci.* 2025; 15(11): 6282. doi: 10.3390/app15116282.
54. Shahmoradi L, Safdari R, Ahmadi H, Zahmatkeshan M. Clinical decision support systems-based interventions to improve medication outcomes: A systematic literature review on features and effects. *Med J Islam Repub Iran.* 2021; 35: 27. doi: 10.47176/mjiri.35.27.
55. Kakhi K, Jagatheesaperumal SK, Khosravi A, Alizadehsani R, Acharya UR. Fatigue monitoring using wearables and AI: Trends, challenges, and future opportunities. *Comput Biol Med.* 2025; 195: 110461. doi: 10.1016/j.combiomed.2025.
56. Bernburg M, Gebhardt JS, Groneberg DA, Mache S. Impact of Digitalization in Dentistry on Technostress, Mental Health, and Job Satisfaction: A Quantitative Study. *Healthcare (Basel).* 2025; 13(1): 72. doi: 10.3390/healthcare13010072.
57. Biro JM, Handley JL, Malcolm McCurry J, et al. Opportunities and risks of artificial intelligence in patient portal messaging in primary care. *NPJ Digit Med.* 2025; 8(1): 222. doi: 10.1038/s41746-025-01586-2.
58. Wirkkala M, Wijk K, Larsson AC, Engström M. Technology frustration in healthcare - does it matter in staff ratings of stress, emotional exhaustion, and satisfaction with care? A cross-sectional correlational study using the job demands-resources theory. *BMC Health Serv Res.* 2024; 24(1): 1557. doi: 10.1186/s12913-024-11906-z.
59. Board on Health Care Services; Institute of Medicine. The Role of Telehealth in an Evolving Health Care Environment: Workshop Summary. Washington (DC): National Academies Press (US). 2012; 4. Available from: <https://www.ncbi.nlm.nih.gov/books/NBK207146/>
60. Jones C, Thornton J, Wyatt JC. Artificial intelligence and clinical decision support: clinicians' perspectives on trust, trustworthiness, and liability. *Med Law Rev.* 2023; 31(4): 501-520. doi: 10.1093/medlaw/fwad013.
61. Tolentino R, Baradaran A, Gore G, Pluye P, Abbasgholizadeh-Rahimi S. Curriculum Frameworks and Educational Programs in AI for Medical Students, Residents, and Practicing Physicians: Scoping Review. *JMIR Med Educ.* 2024; 10: e54793. doi: 10.2196/54793.

ВАСИЛЬЕВ Ю.А.,

д.м.н., ГБУЗ города Москвы «Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы», Москва, Россия; e-mail: VasilevYA1@zdrav.mos.ru; ORCID: 0000-0002-5283-5961

ГАЛКИН В.Н.,

д.м.н., профессор, ГБУЗ города Москвы «Городская клиническая больница имени С.С. Юдина Департамента здравоохранения города Москвы», Москва, Россия; e-mail: galkinvn2@zdrav.mos.ru; ORCID: 0000-0002-6619-6179

РАВОДИН Р.А.,

д.м.н., ГБУЗ города Москвы «Городская клиническая больница имени С.С. Юдина Департамента здравоохранения города Москвы», Москва, Россия; e-mail: rracad@mail.ru; ORCID: 0000-0002-0737-0317

НАНОВА О.Г.,

к.б.н., ГБУЗ города Москвы «Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы», Москва, Россия; e-mail: NanovaOG@zdrav.mos.ru; ORCID: 0000-0001-8886-3684

САВИН Н.А.,

к.ф.-м.н., ГБУЗ города Москвы «Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы», Москва, Россия; e-mail: SavinNA2@zdrav.mos.ru; ORCID: 0000-0001-9199-7229

БЛОХИН И.А.,

к.м.н., ГБУЗ города Москвы «Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы», Москва, Россия; e-mail: BlokhinIA@zdrav.mos.ru; ORCID: 0000-0002-2681-9378

МЫНКО О.И.,

ГБУЗ города Москвы «Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы», Москва, Россия; e-mail: MynkoOI@zdrav.mos.ru; ORCID: 0009-0005-3984-4045

ВЛАДИМИРСКИЙ А.В.,

д.м.н., профессор, ГБУЗ города Москвы «Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы», Москва, Россия; e-mail: VladzimirskijAV@zdrav.mos.ru; ORCID: 0000-0002-2990-7736

ОМЕЛЯНСКАЯ О.В.,

ГБУЗ города Москвы «Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы», Москва, Россия; e-mail: OmelyanskayaOV@zdrav.mos.ru; ORCID: 0000-0002-0245-4431

ИССЛЕДОВАНИЕ ТОЧНОСТИ МЕДИЦИНСКОГО ИЗДЕЛИЯ «ПРОРОДИНКИ» ДЛЯ ДИАГНОСТИКИ БАЗАЛЬНОКЛЕТОЧНОЙ КАРЦИНОМЫ

DOI: 10.25881/18110193_2026_1_52

Аннотация. Ранняя диагностика злокачественных новообразований кожи остается актуальной задачей современной медицины. Большинство клинических подходов, нацеленных на скрининг пигментной и беспигментной базальноклеточной карциномы, можно отнести к малоэффективным. Технологии компьютерного зрения и машинного обучения открывают новые возможности для создания эффективных методов выявления подозрительных новообразований кожи. Однако большинство алгоритмов, разработанных в этой области, имеют ограниченную доказательную базу из-за отсутствия внешней проспективной валидации.

Целью данного исследования являлось проведение внешней валидации алгоритма искусственного интеллекта для оценки вероятности злокачественности пигментных и беспигментных новообразований кожи по фотоснимкам. Целевой аудиторией приложения являются пациенты. Также приложение может быть использовано врачами-клиницистами, например, врачами-дерматологами, в ходе первичного приема. В исследовании приняли участие 132 пациента с жалобами на наличие локального новообразования кожи. Результаты гистологических и цитологических исследований использовались в качестве референс-теста, а тестируемое приложение «ПроРодинки» в качестве индекс-теста. Алгоритм продемонстрировал высокую чувствительность 86% в диагностике базальноклеточной карциномы, однако специфичность составила 41%.

Для повышения специфичности алгоритма целесообразно повторное обучение с применением методов сэмплинга, оптимизации гиперпараметров и уменьшения размерности данных. Также целесообразно внедрение функционала автоматической оценки качества входящих изображений для исключения снимков неудовлетворительного качества.

Данное исследование подчеркивает важность валидации разработанных алгоритмов, направленных на классификацию новообразований с предложением рекомендаций по дальнейшим действиям. Такой подход открывает перспективы для дальнейшего совершенствования диагностических систем на основе нейронных сетей.

Ключевые слова: базальноклеточная карцинома, скрининг, искусственный интеллект, внешняя валидация.

Для цитирования: Васильев Ю.А., Галкин В.Н., Раводин Р.А., Нанова О.Г., Савин Н.А., Блохин И.А., Мынко О.И., Владимирский А.В., Омелянская О.В. Исследование точности медицинского изделия «ПроРодинки» для диагностики базальноклеточной карциномы. Врач и информационные технологии. 2026; 1: 52-63. DOI: 10.25881/18110193_2026_1_52.

VASILEV YU.A.,

DSc, State Budget-Funded Health Care Institution of the City of Moscow "Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department", Moscow, Russia; e-mail: VasilevYA1@zdrav.mos.ru; ORCID: 0000-0002-5283-5961

GALKIN V.N.,

DSc, Professor, State Budgetary Healthcare Institution of the City of Moscow "City Clinical Hospital named after S.S. Yudin of the Moscow City Department of Healthcare", Moscow, Russia; e-mail: galkinvn2@zdrav.mos.ru; ORCID: 0000-0002-6619-6179

RAVODIN R.A.,

DSc, State Budgetary Healthcare Institution of the City of Moscow "City Clinical Hospital named after S.S. Yudin of the Moscow City Department of Healthcare", Moscow, Russia; e-mail: rracad@mail.ru; ORCID: 0000-0002-0737-0317

NANOVA O.G.,

PhD, State Budget-Funded Health Care Institution of the City of Moscow "Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department", Moscow, Russia; e-mail: NanovaOG@zdrav.mos.ru; ORCID: 0000-0001-8886-3684

SAVIN N.A.,

PhD, State Budget-Funded Health Care Institution of the City of Moscow "Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department", Moscow, Russia; e-mail: SavinNA2@zdrav.mos.ru; ORCID: 0000-0001-9199-7229

BLOKHIN I.A.,

PhD, State Budget-Funded Health Care Institution of the City of Moscow "Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department", Moscow, Russia; e-mail: BlokhinIA@zdrav.mos.ru; ORCID: 0000-0002-2681-9378

MYNKO O.I.,

State Budget-Funded Health Care Institution of the City of Moscow "Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department", Moscow, Russia; e-mail: MynkoOI@zdrav.mos.ru; ORCID: 0009-0005-3984-4045

VLADZYMYRSKYY A.V.,

DSc, Professor, State Budget-Funded Health Care Institution of the City of Moscow "Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department", Moscow, Russia; e-mail: VladzimirskijAV@zdrav.mos.ru; ORCID: 0000-0002-2990-7736

OMELYANSKAYA O.V.,

State Budget-Funded Health Care Institution of the City of Moscow "Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department", Moscow, Russia; e-mail: OmelyanskayaOV@zdrav.mos.ru; ORCID: 0000-0002-0245-4431

DIAGNOSTIC ACCURACY OF THE PRORODINKI MEDICAL DEVICE FOR BASAL CELL CARCINOMA

DOI: 10.25881/18110193_2026_1_52

Abstract. *Early diagnosis of skin cancer remains a pressing issue in modern medicine. Most clinical approaches aimed at screening for pigmented and amelanotic basal cell carcinoma are considered ineffective. Computer vision and machine learning offer new opportunities for developing effective methods for detecting suspicious skin lesions. However, most algorithms developed in this area have limited evidence due to the lack of external prospective validation.*

The aim of this study was to externally validate an artificial intelligence algorithm for assessing the malignancy risk of pigmented and amelanotic skin lesions based on photographs. The app's target audience is patients. It can also be used by clinicians, such as dermatologists, during initial consultations. The study involved 132 patients complaining of localized skin lesions. Histological and cytological results were used as the reference test, while the "ProRodinki" app served as the index test. The algorithm demonstrated high sensitivity of 86% in diagnosing basal cell carcinoma, but its specificity was 41%.

To improve the algorithm's specificity, retraining using sampling, hyperparameter optimization, and data dimensionality reduction is advisable. Automatic image quality assessment could also be used to exclude images of unsatisfactory quality.

This study highlights the importance of validating developed algorithms aimed at classifying tumors and providing recommendations for further action. This approach opens up prospects for further improvement of diagnostic systems based on neural networks.

Keywords: *basal cell carcinoma, screening, artificial intelligence, external validation.*

For citation: *Vasilev Yu.A., Galkin V.N., Ravodin R.A., Nanova O.G., Savin N.A., Blokhin I.A., Mynko O.I., Vladzimirskyy A.V., Omelyanskaya O.V. Diagnostic accuracy of the ProRodinki medical device for basal cell carcinoma. Medical doctor and information technology. 2026; 1: 52-63. DOI: 10.25881/18110193_2026_1_52.*

ВВЕДЕНИЕ

Базальноклеточная карцинома (БКК) или базалиома является распространённым злокачественным новообразованием (ЗНО) кожи, представляющим собой серьёзную проблему в современной онкологии [1]. БКК развивается из базальных клеток эпидермиса. Повреждение ДНК в этих клетках приводит к генетическим мутациям и нарушениям, вызывающим их неконтролируемую пролиферацию [2]. Базалиома может проявляться в различных клинических формах [3]. Это связано как с кумулятивным эффектом солнечного воздействия, так и фототипом кожи человека. Агрессивные подтипы базалиомы могут быстро прогрессировать и требуют своевременной диагностики.

Метастазы ЗНО кожи, включая базалиому и меланому, высокорезистентны к лучевой терапии и традиционным химиотерапевтическим средствам, а новые виды лучевой и системной терапии (стереотаксическая лучевая терапия, iPD1 и iBRAF) отличаются высокой стоимостью лечения при его умеренной эффективности. В связи с этим выявление и лечение ЗНО кожи (БКК) на ранних стадиях в большинстве случаев позволяет избежать дорогостоящего лечения и снизить смертность [4, 5].

Особенностью ЗНО кожи является отчетливое изменение формы, цвета и размеров в процессе развития опухоли. Эти визуальные признаки являются ключевыми для раннего выявления заболевания. На сегодняшний день, согласно стандартам оказания медицинской помощи [6], основными методами ранней диагностики ЗНО кожи остаются клинический осмотр и дерматоскопия. Поскольку оба этих метода основаны на визуальной оценке подозрительно новообразования или его изображения, их можно автоматизировать с помощью технологий компьютерного зрения [7–9] и алгоритмов машинного обучения. Развитие этих технологий открывает перспективы для создания доступных и удобных инструментов самостоятельной диагностики, позволяющих большей части населения оперативно проверять подозрительные новообразования кожи. Это, в свою очередь, может существенно повысить выявляемость ЗНО кожи на ранних стадиях, когда лечение наиболее эффективно.

Несмотря на значительный интерес и обилие исследований в данной области, большинство разработок в сфере машинной диагностики ЗНО кожи носят ретроспективный характер (разработаны на архивных данных) и не проходят строгую проверку эффективности на новых и независимых данных, полученных в ходе проспективных внешних исследований [10]. Это означает, что результаты многих исследований могут быть недостаточно надежными для клинического применения. На момент написания данной статьи лишь один сервис на основе искусственного интеллекта, DermaSensor, получил одобрение FDA, подтвердив свою клиническую эффективность [11, 12]. Однако DermaSensor представляет собой отдельное специализированное устройство, что ограничивает его широкую доступность и потенциал для массового внедрения. В России имеется сервис для диагностики пигментных новообразований кожи «ПроРодинки», получивший статус медицинского изделия, но документация о проведении валидации на клинических данных не размещена в открытом доступе. В связи с чем актуальной задачей является валидация существующих, доступных и интегрированных решений для автоматизированной диагностики пигментных и беспигментных ЗНО кожи (БКК) на независимых данных с целью подтверждения их клинической эффективности.

Цель исследования — проведение внешней валидации алгоритма искусственного интеллекта медицинского изделия «ПроРодинки» для оценки злокачественности новообразований кожи по фотоснимкам, полученным в условиях реальной клинической практики.

Гипотезы — данное исследование является описательным и не подразумевает проверки статистических гипотез.

МАТЕРИАЛЫ И МЕТОДЫ

Целевая популяция

Критерии включения пациентов в исследование:

1. Пациенты, имеющие жалобы:
 - а. на новообразования кожи и обратившиеся за помощью к специалисту с целью их удаления;

- b. на новообразования кожи, считающие их подозрительными без использования приложения «ПроРодинки» и обратившиеся за помощью к специалисту с целью их удаления;
 - c. на подозрительные/сомнительные новообразования кожи, выявленные при объективном осмотре специалистом без использования приложения «ПроРодинки», и которым планируется проведение эксцизионной биопсии для верификации диагноза;
2. Клинически подозрительные/сомнительные новообразования кожи, выявленные при объективном осмотре врачом дерматологом или онкологом без использования инструментальных методов диагностики;
 3. Пациенты, которым планируется выполнение эксцизионной биопсии или цитологического исследования новообразований кожи в течение 3–5 дней с момента включения в исследование, и которые способны перенести это вмешательство;
 4. Наличие подписанной формы информированного согласия на участие в исследовании;
 5. Возраст пациента старше 18 лет на период включения в исследование (на момент подписания формы согласия).
- Критерии исключения пациентов из исследования:

1. Пациенты, которым не планируется выполнение эксцизионной биопсии или цитологического исследования новообразований кожи в ближайшие 3 месяца от включения в исследование или которые не способны перенести это вмешательство;
2. Имелось прижизненное патологоанатомическое (цитологическое) подтверждение природы новообразований (доброкачественных или злокачественных), которые планировалось подвергнуть удалению в рамках данного исследования;
3. Новообразования, расположенные подкожно или в мягких тканях и по клиническим признакам не имеющие связи с кожей;
4. Аллергическая реакция на лекарственные препараты, применяемые при проведении инцизионной/эксцизионной биопсии или широкого иссечения;
5. Неспособность пациента выполнять процедуры исследования (в том числе контактировать

с исследователем в рамках визитов наблюдения) или иные причины, которые, по мнению главного исследователя, могут стать препятствием для участия пациента в исследовании; Потенциально подходящих пациентов выявляли при первичном обращении на основании жалоб и данных очного осмотра врача в Онкологическом центре № 1 ГKB им. С.С. Юдина в период с 15.08.2024 по 20.01.2025; далее для них последовательно проверяли критерии включения и исключения.

Источник случаев: Онкологический центр №1 ГKB им С.С. Юдина, амбулаторные визиты в период с 15.08.2024 по 20.01.2025 гг.

Способ формирования выборки: сплошной.

Дизайн исследования

Для проведения внешней валидации алгоритма искусственного интеллекта, проводящего оценку злокачественности новообразований кожи по фотоснимкам, основными задачами являются: точная идентификация и классификация новообразований, дифференцировка доброкачественных новообразований от злокачественных. Анализируемые метрики включают: чувствительность, специфичность, точность, прогностическую ценность положительного результата, прогностическую ценность отрицательного результата.

Исследование имеет одномоментный дизайн и является низко-интервенционным. Процедура врачебных визитов в рамках данного исследования была стандартизирована и включала несколько этапов, направленных на сбор данных [13] и обследование пациентов в Онкологическом центре №1 ГKB им С.С. Юдина.

Медицинское заключение формировалось на основании дерматоскопического исследования и цитологического (либо гистологического) заключения. Фотодокументирование новообразования кожи проводилось с использованием мобильного приложения «ПроРодинки» изготовителя ООО «АИМЕД» (Россия, 121205, г. Москва, тер. Инновационного центра Сколково), в соответствии с «Инструкцией по использованию мобильного приложения «ПроРодинки» [14]. Все клинические фотографии выполнялись врачом с использованием камеры смартфона (протокол фоторегистрации нестандартизирован).

Фотодокументирование новообразования кожи проводилось в два этапа: с фиксацией основных анатомических ориентиров, макрофотография с фокусировкой в центре изображения и в масштабе не менее 10% от всей фотографии. Ответ приложения был получен непосредственно после фотофиксации.

Дерматоскопическое исследование проводилось на дерматоскопе DermLite 3, который применялся в виде готового комплекта с фотоадаптером или в комплекте со специальными пластиковыми кассетами с магнитным фотоадаптером. В качестве иммерсионного средства применялся гель для проведения УЗ-исследований. Дерматоскопическая фотография проводилась с центральным расположением новообразования кожи на изображении. В случае, если новообразование было больше контактной платы дерматоскопа, фотодокументировались все поля.

На усмотрение врача в зависимости от клинической картины новообразования предполагаемого клинического диагноза и места локализации пациенту проводился цитологический соскоб или любой вариант инцизионной/эксцизионной биопсии.

Обоснование выбора референсного стандарта

В качестве референсного стандарта использовали гистологическое исследование (приоритетно). При невозможности получения достаточного биопсийного материала допускалось цитологическое исследование в соответствии с Клиническими рекомендациями «Базальноклеточный рак кожи (МКБ-10: С44)» Минздрава России (2024) [15].

Ослепление и доступ к данным

Результаты референсного стандарта были недоступны исполнителям индекс-теста. Результаты индекс-теста были доступны исполнителям референсного стандарта.

Обоснование размера выборки

Определение необходимого размера выборки проводилось при помощи веб-инструмента «Presize», раздел «Precision of sensitivity» (<https://shiny.ctu.unibe.ch/presize/>) [16, 17]. С учетом валидации приложения «ПроРодинки» на базе НМИЦ им. Блохина [14, 18], продемонстрировавшей чувствительность в 93,5%, и ширине доверительного интервала $\delta = 0,1$ минимально необходимый размер выборки составляет $n = 92$. За период проведения исследования был набран объём данных, превышающий минимально необходимый размер выборки ($n = 131$). Схема формирования выборки представлена на рисунке 1.

Обращение с неопределёнными результатами индекс-теста

При сравнении дерматоскопических снимков со снимками, полученными на смартфон при использовании приложения «ПроРодинки», последние имели неудовлетворительное качество (объект вне фокуса, размытое изображение) в 75% случаев. Вне зависимости от качества снимка программа «ПроРодинки» проводила анализ изображения, данные учитывались в анализе.

Статистическая обработка данных

В качестве референс-теста использовали результаты гистологических либо цитологических заключений. В качестве индекс-теста использовали результаты тестируемого приложения

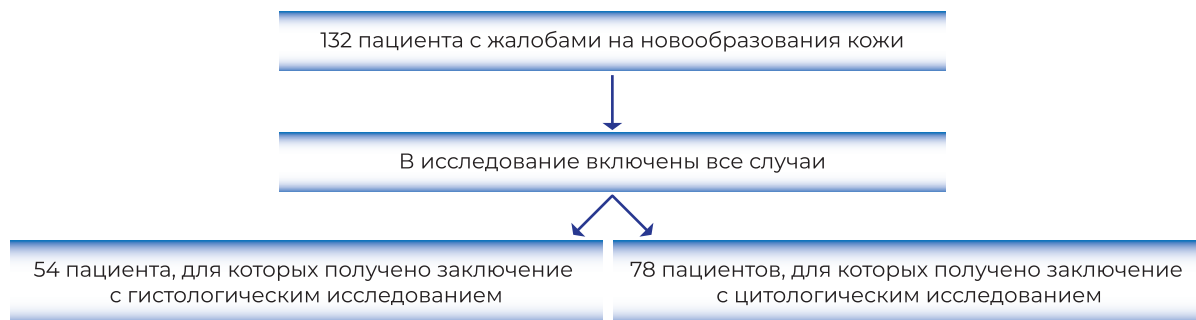


Рисунок 1 — Схема формирования выборки.

Таблица 1 — Базовые характеристики пациентов

Показатель	Основная группа, среднее значение ± среднее квадратичное отклонение	
Количество пациентов	132	
Пол	Мужской	46
	Женский	86
Средний возраст, лет	73,7±9,19	

«ПроРодинки». Поскольку данные были собраны в полном объеме, обработка недостающих данных не предусматривалась.

Для оценки эффективности приложения были построены таблицы сопряженности, а затем рассчитаны значения метрик с 95% доверительным интервалом (ДИ). В связи с ожидаемым риском подгрупп малого размера расчёты 95% ДИ были произведены по методу Клоппера-Пирсона. Эти расчёты были проведены для гистологических и цитологических заключений отдельно, а затем для гистологических и цитологических заключений в совокупности. Статистическая обработка выполнялась в программном обеспечении Posit RStudio 2024.12 [19].

РЕЗУЛЬТАТЫ

Общее число пациентов, для которых было получено заключение с помощью приложения «ПроРодинки» и медицинское заключение, составило 132 (86 женщин и 46 мужчин, средний возраст пациентов 73,3±9,19 года). Медицинское заключение было основано на результатах комплексного обследования, описанного в главе «Материалы и методы». В исследование были включены все пациенты обратившиеся с жалобами на новообразования кожи (рисунок 1). Анализ базовых характеристик пациентов представлен в таблице 1.

Результаты испытаний с учетом только гистологических заключений

Число пациентов, для которых получено заключение с гистологическим исследованием, составило 54. Из них число пациентов с подтвержденным ЗНО (БКК) составило 42, число пациентов с подтвержденным ДНО (доброкачественное новообразование) — 12. Результаты тестирования приложения «ПроРодинки» представлены в матрице сопряженности (Таблица 2, Приложение А). Значение чувствительности индексного теста составило 86% (95% ДИ: 72–95%), значение

Таблица 2 — Таблица сопряженности, полученная на основе гистологических заключений

	Индекс-тест	Истинный	Ложный
Референс-тест			
Положительный		36	6
Отрицательный		6	6

специфичности — 50% (95% ДИ: 21–79%), точность — 78% (95% ДИ: 64–88%), прогностическое значение положительного результата (PPV) — 86% (95% ДИ: 72–95%), прогностическое значение отрицательного результата (NPV) — 50% (95% ДИ: 21–79%).

Результаты испытаний с учетом только цитологических заключений

Число пациентов, для которых получено заключение с цитологическим исследованием, составило 78. Из них число пациентов с подтвержденным ЗНО (БКК) составило 68, число пациентов с подтвержденным ДНО — 10. Результаты тестирования приложения «ПроРодинки» представлены в матрице сопряженности (Таблица 3, Приложение Б). Значение чувствительности индексного теста составило 87% (95% ДИ: 76–94%), значение специфичности — 30% (95% ДИ: 7–65%), точность — 79% (95% ДИ: 69–88%), прогностическое значение положительного результата (PPV) — 89% (95% ДИ: 79–96%), прогностическое значение отрицательного результата (NPV) — 25% (95% ДИ: 6–57%).

Таблица 3 — Таблица сопряженности, полученная на основе цитологических заключений

	Индекс-тест	Истинный	Ложный
Референс-тест			
Положительный		59	7
Отрицательный		3	9

Таблица 4 — Таблица сопряженности, полученная на основе цитологических и гистологических заключений

Индекс-тест \ Референс-тест	Истинный	Ложный
Положительный	95	13
Отрицательный	9	15

Результаты испытаний с учетом гистологических и цитологических заключений в совокупности

Суммарное число пациентов, для которых получено заключение с гистологическим или цитологическим исследованием, составило 132. Из них число пациентов с подтвержденным ЗНО (БКК) составило 110, число пациентов с подтвержденным ДНО — 22. Результаты тестирования приложения «ПроРодинки» представлены в матрице сопряженности (Таблица 4, Приложение В). Значение чувствительности индексного теста составило 86% (95% ДИ: 78–92%), значение специфичности — 41% (95% ДИ: 21–64%), точность — 79% (95% ДИ: 71–85%), прогностическое значение положительного результата (PPV) — 88% (95% ДИ: 80–93%), прогностическое значение отрицательного результата (NPV) — 38% (95% ДИ: 19–59%).

ОБСУЖДЕНИЕ

По результатам исследования алгоритм «ПроРодинки» показал высокий уровень чувствительности 86% (95% ДИ: 78–92%), точности 79% (95% ДИ: 71–85%) и прогностического значения положительного результата 88% (95% ДИ: 80–93%) в отношении ранней диагностики пигментных и беспигментных ЗНО кожи. Уровни специфичности и прогностического значения отрицательного результата алгоритма составили 41% (95% ДИ: 21–64%) и 38% (95% ДИ: 19–59%), соответственно, причиной чего может быть несбалансированность данных в обучающем наборе. В связи с высокой чувствительностью алгоритма влияние неудовлетворительного качества изображений на низкую специфичность алгоритма маловероятно. Согласно данным мета-анализа, показатели чувствительности и специфичности для аналогичных алгоритмов в среднем составляют 86% (95% ДИ: 84–90%) и 86% (95% ДИ: 82–91%) [10]. Важно отметить, что заявленные разработчиком алгоритма метрики,

полученные в исследовании проводимым НМИЦ им. Блохина, значительно превышают результаты, полученные в нашем исследовании. Однако ознакомиться с данным заключением НМИЦ им. Блохина не предоставляется возможным в связи с закрытым доступом к документу. По этой причине трудно достоверно определить причину расхождения в полученных характеристиках алгоритма. Кроме того, в работе Короткий С.С. и др. [20] также были продемонстрированы более высокие показатели чувствительности (85%) и специфичности (93%) для приложения «ПроРодинки», при анализе изображений из набора данных, содержащего снимки новообразований кожи высокого качества. В отличие от этого, наше исследование моделировало реальную ситуацию клинической практики, где качество изображений, получаемых с помощью смартфонов, может значительно варьироваться. Это подчеркивает важность проведения валидации алгоритмов машинного обучения в условиях, максимально приближенных к реальным, и предоставления данных в открытом доступе.

Важно отметить, что до начала исследования врачи не имели опыта работы с данным приложением, что могло послужить причиной получения снимков неудовлетворительного качества и подчеркивает необходимость стандартизации протокола. В связи с чем метрики алгоритма, полученные в данном исследовании, могут отличаться от действительных значений. Для улучшения специфичности алгоритма можно провести повторное обучение, применяя методы сэмплинга, уменьшения размерности, а также оптимизации гиперпараметров. Для повышения точности обработки входящих изображений целесообразно внедрение компьютерных методов, которые будут проводить оценку качества изображения путем анализа яркости и контрастности. Подобная предварительная фильтрация позволит снизить диагностические ошибки, возникающие из-за субъективной оценки качества снимка пользователем. Кроме того, применение разработанной методологии тестирования и мониторинга программного обеспечения на основе технологий искусственного интеллекта для медицинской диагностики может повысить качество внедряемого продукта [21].

Диагностическая точность систем компьютерного зрения для поддержки принятия врачебных

решений, к которым относится «ПроРодинки», может быть улучшена за счет использования текстурного анализа. Например, в исследовании Wang Z. et al. [22] была представлена автоматизированная система, объединяющая дерматоскопию, текстурный анализ и метаданные пациентов для анализа кожных поражений. Авторы показали, что комбинированный текстурный анализ позволяет количественно оценить характеристики интенсивности, пространственную неоднородность и морфологические особенности, обеспечивая всестороннее понимание структуры новообразования. В сочетании с клиническими данными (возраст, пол, локализация образования) текстурный анализ способен значительно повысить точность диагностики и создать основу для персонализированных моделей, предсказывающих развитие заболевания.

Согласно мета-анализу, около 98% исследований в области диагностики ЗНО кожи сосредоточены на классификации заболеваний как пигментный невус/меланома или как доброкачественное/злокачественное немеланоцитарное новообразование. Однако только 2% разработанных алгоритмов ставят перед собой более практическую задачу: классификацию новообразований (на доброкачественные или подозрительные) с выдачей рекомендаций (например, визит к врачу или проведение биопсии). Данная задача является наиболее приближенной к рутинной практике врача-дерматолога, и разработанный алгоритм нацелен на работу в этом направлении [6, 23].

Настоящее исследование имеет ряд ограничений. Во-первых, работа проводилась на базе одного медицинского учреждения, что может ограничивать обобщаемость результатов на популяцию пациентов. Во-вторых, анализ проводился с использованием данных, собранных с помощью мобильного приложения «ПроРодинки», и качество полученных данных может зависеть от навыков использования приложения врачами, а также от технических характеристик используемых устройств. В-третьих, оценка качества изображения выполнялась субъективно, что

может повлиять на точность итоговых результатов. Наконец, оценка предложенного алгоритма проводилась в условиях большого процента выбывших пациентов и требует дальнейшего тестирования и валидации в реальных клинических условиях на большей и более сбалансированной выборке.

ЗАКЛЮЧЕНИЕ

В ходе выполненного исследования алгоритм искусственного интеллекта показал высокие показатели чувствительности и прогностического значения положительного результата в отношении диагностики пигментных и беспигментных ЗНО кожи. Это указывает на потенциал алгоритма в качестве инструмента для скрининга. Однако следует отметить, что специфичность работы алгоритма пока остается на неудовлетворительном уровне. Направлениями для дальнейшей работы представляются изучение влияния различных методов предобработки изображений и их качества на точность диагностики, а также обоснование экономической эффективности применения приложения «ПроРодинки».

Конфликт интересов: Авторы заявляют об отсутствии конфликта интересов. Исследователи не имеют финансовой или иной заинтересованности, связанной с производителем приложения.

Источник финансирования: Данная статья подготовлена авторским коллективом в рамках НИР «Научное обоснование методов лучевой диагностики опухолевых заболеваний с использованием радиомического анализа», (№ ЕГИСУ: № 123031500005-2) в соответствии с соответствием с Приказом от 17.12.2024 г. № 1184 «Об утверждении государственных заданий, финансовое обеспечение которых осуществляется за счет средств бюджета города Москвы государственным бюджетным (автономным) учреждениям подведомственным Департаменту здравоохранения города Москвы, на 2025 год и плановый период 2026 и 2027 годов» Департамента здравоохранения города Москвы.

ЛИТЕРАТУРА/REFERENCES

1. Costache M, Miricescu D, Totan A, et al. Emerging concepts and latest advances regarding the etiopathogenesis, morphology and immunophenotype of basal cell carcinoma. Rom J Morphol Embryol. 2018; 59(2): 427-433.

2. Krakowski AC, Alam M, Bhatia A, et al. Advanced basal cell carcinoma: What dermatologists need to know about diagnosis. *J Am Acad Dermatol.* 2022; 86(6S): S1-S13.
3. Lubeek SFK, Hollestein LM, Nijsten T, Wakkee M. The epidemiology and clinicopathological features of basal cell carcinoma in patients 80 years and older: a systematic review. *JAMA Dermatol.* 2017; 153(1): 71-78.
4. Geller AC, Greinert R, Sinclair C, et al. A nationwide population-based skin cancer screening in Germany: proceedings of the first meeting of the International Task Force on Skin Cancer Screening and Prevention (September 24 and 25, 2009). *Cancer Epidemiol.* 2010; 34: 355-358.
5. Katalinic A, Waldmann A, Weinstock MA, et al. Does skin cancer screening save lives? An observational study comparing trends in melanoma mortality in regions with and without screening. *Cancer.* 2012; 118: 5395-5402.
6. Приказ Министерства здравоохранения Российской Федерации от 20 декабря 2012 г. №1143н «Об утверждении стандарта первичной медико-санитарной помощи при злокачественных новообразованиях кожи (меланома, рак) I-IV стадии (обследование в целях установления диагноза заболевания и подготовки к противоопухолевому лечению)». Доступно по: https://minzdrav.gov-murman.ru/documents/poryadki-okazaniya-meditsinskoy-pomoshchi/pr_MZ_RF_%201143n.pdf. Ссылка активна на 17.04.2025. [Приказ Ministerstva zdravoohraneniya Rossijskoj Federacii ot 20 dekabrya 2012 g. №1143n «Ob utverzhdenii standarta pervichnoj mediko-sanitarnoj pomoshchi pri zlokachestvennyh novoobrazovaniyah kozhi (melanoma, rak) I-IV stadii (obsledovanie v celyah ustanovleniya diagnoza zabolevaniya i podgotovki k protivopuholevomu lecheniyu)». Dostupno po: https://minzdrav.gov-murman.ru/documents/poryadki-okazaniya-meditsinskoy-pomoshchi/pr_MZ_RF_%201143n.pdf. Ssylka aktivna na 17.04.2025. (In Russ.)]
7. Russakovsky O, Deng J, Su H, et al. ImageNet Large Scale Visual Recognition Challenge. *Int J Comput Vis (IJCV).* 2015.
8. Владимирский А.В. Компьютерное зрение в лучевой диагностике: первый этап Московского эксперимента. — 2-е изд. — Москва: Издательские решения, 2023. — 388 с. [Vladimirskij AV. Komp'yuternoe zrenie v luchevoj diagnostike: pervyj etap Moskovskogo eksperimenta. Moskva: Izdatel'skie resheniya, 2023. 388 p. (In Russ.)]
9. Васильев Ю.А. Перспективы применения компьютерного зрения для выявления камней в мочевыделительной системе и новообразований печени и почек на изображениях компьютерной томографии органов брюшной полости и забрюшинного пространства // *Digital Diagnostics.* — 2024. — Т.5. — №1. — С.101-119. [Vasil'ev YUA. Perspektivy primeneniya komp'yuternogo zreniya dlya vyyavleniya kamnej v mochevydelitel'noj sisteme i novoobrazovaniy pecheni i pochek na izobrazheniyah komp'yuternoj tomografii organov bryushnoj polosti i zabryushinnogo prostranstva. Digital Diagnostics. 2024; 5(1): 101-119. (In Russ.)] doi: 12.17816/DD515814.
10. Jones OT, et al. Artificial intelligence and machine learning algorithms for early detection of skin cancer in community and primary care settings: a systematic review. *Lancet Digit Health.* 2021; 4(6): e466-e476.
11. www.fda.gov [Internet]. Office of the Commissioner. FDA Roundup: January 16, FDA. [доступ от 17.04.2025]. Доступ по ссылке <https://www.fda.gov/news-events/press-announcements/fda-roundup-january-16-2024><https://www.fda.gov/news-events/press-announcements/fda-roundup-january-16-2024> (2024).
12. Venkatesh KP, Kadakia KT, Gilbert S. Learnings from the first AI-enabled skin cancer device for primary care authorized by FDA. *npj Digit Med.* 2024; 7: 156. doi: 10.1038/s41746-024-01161-1.
13. Васильев Ю.А. Подготовка набора данных для обучения и тестирования программного обеспечения на основе технологии искусственного интеллекта. — Ridero: Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы, 2024. — 140 с. [Vasil'ev YUA. Podgotovka nabora dannyh dlya obucheniya i testirovaniya programmnoho obespecheniya na osnove tekhnologii iskusstvennogo intellekta. Ridero: Nauchno-prakticheskij klinicheskij centr diagnostiki i telemedicinskih tekhnologij Departamenta zdravoohraneniya goroda Moskvy, 2024. 140 s. (In Russ.)]
14. Инструкция по использованию ПроРодинки МЕД [доступ от 17.04.2025]. Доступ по ссылке: <https://prorodinki.ru/instruction><https://prorodinki.ru/instruction>

15. Клинические рекомендации «Базальноклеточный рак кожи (МКБ-10: С44)» [доступ от 05.09.2025]. Доступ по ссылке: https://cr.minzdrav.gov.ru/preview-cr/467_3
16. Hanley JA, McNeil BJ. The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*. 1982;143(1):29-36.
17. Presize. Shiny. Published 2023. Accessed July 9, 2025. <https://shiny.ctu.unibe.ch/presize/>
18. ICH GCP. Clinical Trials Registry: NCT05697822. Published 2023. Accessed July 9, 2025. <https://ichgcp.net/clinical-trials-registry/NCT05697822>.
19. Блохин И.А. Проверка гипотез исследования с использованием языка R // *Digital Diagnostics*. — 2023. — Т. 4, № 2. — С. 238-247. [Blohin IA. Proverka gipotez issledovaniya s ispol'zovaniem yazyka R. *Digital Diagnostics*. 2023; 4(2): 238-247. (In Russ.)]
20. Короткий С.С. и др. Comparison analysis of AI based smartphone applications for self examination of skin cancer risk // *Вестник Российского университета дружбы народов. Серия: Инженерные исследования*. — 2023. — Т.24. — №3. — С.262-270. [Korotkij SS, et al. Comparison analysis of AI based smartphone applications for self examination of skin cancer risk. *Vestnik Rossijskogo universiteta druzhby narodov. Seriya: Inzhenernye issledovaniya*. 2023; 24(3): 262-270. (In Russ.)]
21. Васильев Ю.А., Владимирский А.В., Омелянская О.В. и др. Методология тестирования и мониторинга программного обеспечения на основе технологий искусственного интеллекта для медицинской диагностики // *Digital Diagnostics*. — 2023. — Т.4. — №3. — С.252-267. [Vasil'ev YUA, Vladimirsij AV, Omelyanskaya OV, et al. Metodologiya testirovaniya i monitoringa programmogo obespecheniya na osnove tekhnologij iskusstvennogo intellekta dlya medicinskoj diagnostiki. *Digital Diagnostics*. 2023; 4(3): 252-267. (In Russ.)] doi: 10.17816/DD321971.
22. Wang Z, et al. Radiomic and deep learning analysis of dermoscopic images for skin lesion pattern decoding. *Sci Rep*. 2024; 14(1): 19781.
23. Приказ Министерства труда и социальной защиты Российской Федерации от 14 марта 2018 г. №142н «Об утверждении профессионального стандарта «Врач-дерматовенеролог». [Prikaz Ministerstva truda i social'noj zashchity Rossijskoj Federacii ot 14 marta 2018 g. №142n «Ob utverzhdenii professional'nogo standarta «Vrach-dermatovenerolog». (In Russ.)] Доступно по: https://medprofsouz.ru/media/doc/profstandart/prikaz_mintruda_rf_142n.pdf. Ссылка активна на 17.04.2025.

Приложение

Формат матрицы сопряженности и расчеты диагностических показателей

TP	FP
TN	FN

где: TP – истинно-положительные исходы;
N – истинно-отрицательные исходы;
FP – ложно-положительные исходы;
FN – ложно-отрицательные исходы.

Приложение Б

Расчёт прогностических показателей модели «ПроРодинки», валидированной на основе цитологических заключений

$$\text{Чувствительность (sens)} = \frac{TP}{TP + FN} = \frac{59}{59 + 9} = 0,868$$

$$\text{Специфичность (spec)} = \frac{TN}{TN + FP} = \frac{3}{3 + 7} = 0,3$$

$$\text{Точность (acc)} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{59 + 3}{59 + 3 + 7 + 9} = 0,794$$

$$\text{Положительная прогностическая ценность (PPV)} = \frac{TP}{TP + FP} = \frac{59}{59 + 9} = 0,894$$

$$\text{Отрицательная прогностическая ценность (NPV)} = \frac{TN}{TN + FN} = \frac{3}{3 + 9} = 0,25$$

Приложение А

Расчёт прогностических показателей модели «ПроРодинки», валидированной на основе гистологических заключений

$$\text{Чувствительность (sens)} = \frac{TP}{TP + FN} = \frac{36}{36 + 6} = 0,856$$

$$\text{Специфичность (spec)} = \frac{TN}{TN + FP} = \frac{6}{6 + 6} = 0,5$$

$$\text{Точность (acc)} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{6 + 6}{36 + 6 + 6 + 6} = 0,778$$

$$\text{Положительная прогностическая ценность (PPV)} = \frac{TP}{TP + FP} = \frac{36}{36 + 6} = 0,857$$

$$\text{Отрицательная прогностическая ценность (NPV)} = \frac{TN}{TN + FN} = \frac{6}{6 + 6} = 0,5$$

Приложение В

Расчёт прогностических показателей модели «ПроРодинки», валидированной на основе гистологических и цитологических заключений в совокупности

$$\text{Чувствительность (sens)} = \frac{TP}{TP + FN} = \frac{95}{95 + 15} = 0,864$$

$$\text{Специфичность (spec)} = \frac{TN}{TN + FP} = \frac{9}{9 + 13} = 0,409$$

$$\text{Точность (acc)} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{95 + 9}{95 + 9 + 13 + 15} = 0,788$$

$$\text{Положительная прогностическая ценность (PPV)} = \frac{TP}{TP + FP} = \frac{95}{95 + 13} = 0,88$$

$$\text{Отрицательная прогностическая ценность (NPV)} = \frac{TN}{TN + FN} = \frac{9}{9 + 15} = 0,375$$

КАШИРИНА И.Л.,

д.т.н., профессор, МИРЭА – Российский технологический университет, Москва, Россия;
e-mail: kashirina@mirea.ru; ORCID: 0000-0002-8664-9817

СТАРИЧКОВА Ю.В.,

к.т.н., МИРЭА – Российский технологический университет, Москва, Россия;
e-mail: starichkova@mirea.ru; ORCID: 0000-0003-1804-0761

ЛЕ Ч.К.,

МИРЭА – Российский технологический университет, Москва, Россия; e-mail: letrungkienlk4@gmail.com

ТОНКАЯ НАСТРОЙКА ЯЗЫКОВОЙ МОДЕЛИ RuBERT ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ АНАЛИЗА МЕДИЦИНСКИХ ЗАПРОСОВ

DOI: 10.25881/18110193_2026_1_64

Аннотация. Цель исследования состояла в повышении точности семантического поиска медицинской информации на русском языке путем тонкой настройки языковой модели RuBERT на специализированном датасете RuMedDaNet с применением метода обучения Matryoshka Representation Learning для создания компактных и эффективных векторных представлений текста.

Материалы и методы. В исследовании использовался датасет RuMedDaNet, содержащий русскоязычные медицинские тексты. Для оптимизации производительности поиска применялись различные техники обучения эмбеддингов (векторных представлений текста), включая подход «матрёшка», позволяющий уменьшить размерность векторных представлений без существенной потери качества.

Результаты. Эксперименты показали значительное улучшение ключевых метрик поиска (NDCG, MRR) по сравнению с базовой моделью RuBERT. Обученная в исследовании языковая модель загружена на платформу Hugging Face, где теперь она доступна для открытого использования заинтересованными специалистами.

Заключение. Предложенный метод тонкой настройки RuBERT эффективен для задач поиска в медицинских RAG (Retrieval Augmented Generation)-системах. В статье обсуждаются текущие ограничения предлагаемого подхода и направления дальнейших исследований.

Ключевые слова: RuBERT, тонкая настройка, RuMedDaNet, медицинские тексты, векторный поиск, Matryoshka Representation Learning.

Для цитирования: Каширина И.Л., Старичкова Ю.В., Ле Ч.К. Тонкая настройка языковой модели RuBERT для повышения точности анализа медицинских запросов. *Врач и информационные технологии.* 2026; 1: 64-73.
DOI: 10.25881/18110193_2026_1_64.

KASHIRINA I.L.,

DSc., Professor, MIREA – Russian Technological University, Moscow, Russia;
e-mail: kash.irina@mail.ru; ORCID: 0000-0002-8664-9817

STARICHKOVA YU.V.,

PhD., MIREA – Russian Technological University, Moscow, Russia;
e-mail: starichkova@mirea.ru; ORCID: 0000-0003-1804-0761

LE T.K.,

MIREA – Russian Technological University, Moscow, Russia; e-mail: letrungkienlk4@gmail.com

FINE-TUNING THE RUBERT LANGUAGE MODEL TO IMPROVE THE ACCURACY OF MEDICAL QUERY ANALYSIS

DOI: 10.25881/18110193_2026_1_64

Abstract. *The aim of the study was to improve the accuracy of semantic search of medical information in Russian by fine-tuning the RuBERT language model on the specialized RuMedDaNet dataset using the Matryoshka Representation Learning method to create compact and efficient vector representations of text.*

Materials and Methods. *The study utilized the RuMedDaNet dataset, which contains Russian-language medical texts. Various embedding training techniques were applied to optimize performance, including the “matryoshka” approach, which enables reducing the dimensionality of vector representations without loss of quality.*

Results. *Experiments demonstrated a significant improvement in key search metrics (NDCG, MRR) compared to the baseline RuBERT model. The language model trained in the study has been uploaded to the Hugging Face platform, where it is now available for open use.*

Conclusion. *The proposed RuBERT fine-tuning method was effective for search tasks in medical RAG systems. The current limitations of the approach and directions for further research are discussed.*

Keywords: *RuBERT, fine-tuning, RuMedDaNet, medical texts, information extraction, Matryoshka Representation Learning.*

For citation: *Kashirina I.L., Starichkova Yu.V., Le T.K. Fine-tuning the RuBERT language model to improve the accuracy of medical query analysis. Medical doctor and information technology. 2026; 1: 64-73. DOI: 10.25881/18110193_2026_1_64.*

ВВЕДЕНИЕ

Современное развитие медицины характеризуется стремительной цифровизацией и внедрением технологий искусственного интеллекта в процессы диагностики и консультирования. Однако эффективность существующих систем поддержки принятия врачебных решений существенно ограничена недостаточной точностью семантического анализа медицинских текстов, особенно в условиях высокой вариативности клинической терминологии и необходимости прецизионной интерпретации профессиональной информации. Качественный семантический поиск и извлечение релевантных данных становятся критическими факторами для создания надежных медицинских информационных систем, способных не только накапливать знания, но и контекстуально интерпретировать сложные клинические кейсы с учетом тонких смысловых нюансов профессиональной коммуникации.

Метод Retrieval Augmented Generation (RAG) [1] значительно расширяет возможности современных больших языковых моделей (LLM) за счёт добавления в запрос модели дополнительной релевантной информации из предметной области на этапе генерации ответов. Ключевым фактором, определяющим эффективность RAG-систем, является качество используемых моделей эмбедингов, то есть моделей, формирующих числовое векторное представление текстовых данных. Универсальные модели, несмотря на их широкую языковую компетенцию, зачастую демонстрируют недостаточную эффективность в узкоспециализированных областях, таких как медицина, где терминология и контекст существенно отличаются от общеупотребительного языка.

Особую сложность представляет обработка медицинских текстов на русском языке из-за его богатой морфологии и ограниченного количества специализированных лингвистических ресурсов. Широко используемая на практике модель RuBERT (Russian BERT) [2] подтвердила свою высокую эффективность в задачах общего понимания русского языка, однако её производительность в медицинской сфере остаётся недостаточной. Например, в задаче ответов на вопросы из набора данных RuMedDaNet [3, 4], точность RuBERT составила лишь 67,19%, что значительно ниже человеческого уровня точности ответов врачей-специалистов (93,36%).

В данной работе предлагается подход к улучшению качества эмбедингов для медицинских RAG-систем на русском языке. Используемая в исследовании методика включает тонкую настройку RuBERT на специализированном наборе данных RuMedDaNet, а также применение техники обучения представлений "матрёшка" (Matryoshka Representation Learning) [5] для оптимизации эффективности поиска. Исследование вносит вклад в развитие методов адаптации языковых моделей к узкоспециализированным доменам, уделяя особое внимание медицинскому NLP на русском языке — области, которая остается недостаточно изученной в сравнении с англоязычными аналогами.

ОБЗОР СВЯЗАННЫХ РАБОТ

Эффективность поиска (Retrieval) в RAG-системах во многом определяется качеством векторных представлений текста, генерируемых моделями эмбедингов [1]. Эти модели преобразуют текстовые данные в плотные (то есть не разреженные) числовые векторы, что позволяет осуществлять семантический поиск на основе векторного сходства. Однако большинство современных моделей эмбедингов обучаются на общедоступных корпусах текстов, что снижает их эффективность при работе со специализированными доменами.

Экспериментальные данные свидетельствуют о том, что адаптация предобученных моделей к конкретной предметной области способна существенно улучшить качество поиска. В частности, в работе [6] продемонстрировано, что тонкая настройка эмбедингов на доменно-специфичных данных может повысить эффективность поиска на 7–22% в зависимости от размерности векторных представлений.

Модель RuBERT, разработанная DeepPavlov [2], является одной из наиболее значимых моделей для обработки русского естественного языка. Сохраняя оригинальную архитектуру BERT, эта модель была специально адаптирована для русского языка за счёт обучения на обширном корпусе текстов, включающем русскоязычную Википедию и новостные источники. Несмотря на успешное применение в различных NLP-задачах, таких как анализ тональности и языковое моделирование [6], эффективность RuBERT в узкоспециализированных областях, включая медицину, остаётся низкой. Это связано со специфичностью

медицинской терминологии и особенностями профессионального языка, которые слабо представлены в общедоступных обучающих данных.

Оценка возможностей языковых моделей в медицинской сфере осуществляется с помощью специализированных бенчмарков, в частности RuMedBench [2]. Результаты тестирования на данных этого бенчмарка демонстрируют существенный разрыв между человеческой и машинной производительностью. Наиболее показательным примером является задача ответа на вопросы из набора RuMedDaNet, где разница в точности человека и RuBERT достигает 20 процентов [2], что подчёркивает необходимость дальнейшей адаптации моделей для медицинских приложений.

Современные методы дообучения языковых моделей на специализированных данных демонстрируют высокую эффективность в профессиональных областях. Последние исследования сосредоточены на оптимизации обучения через специализированные форматы обучающих данных, такие как положительные пары (семантически близкие текстовые фрагменты), триплеты (наборы из исходного текста, его семантического аналога и противоречащего по смыслу текста) и ранжированные пары (тексты с оценкой степени их смысловой близости). Эти подходы генерируют дифференцированные обучающие сигналы, что позволяет точнее адаптировать векторные представления текста (эмбединги) к конкретным задачам.

Особый интерес представляет метод Matryoshka Representation Learning (MRL) [5], организующий эмбединги по принципу матрёшки. Ключевая идея заключается в том, чтобы распределить семантическую информацию по приоритету: наиболее значимые признаки кодируются в начальных компонентах вектора, а второстепенные — в последующих. Это позволяет в процессе обучения сокращать размерность представлений в несколько раз, сохраняя до 99,9% исходной точности. Благодаря компактности и высокой эффективности, MRL-эмбединги становятся оптимальным решением для систем, работающих в условиях ограниченных вычислительных ресурсов, что важно для развертывания модели в медицинских организациях.

Стоит отметить, что в настоящий момент существуют специализированные модели, такие как RuBioBERT и RuBioRoBERTa [7], которые были

целенаправленно предобучены на крупных корпусах русскоязычных биомедицинских текстов (научные публикации, клинические рекомендации, выписки) и валидированы на наборах данных бенчмарка RuMedBench. Их появление является важным шагом в развитии медицинского NLP для русского языка. Как показано в [7], RuBioRoBERTa превосходит базовую модель RuBERT на 3–10% по ключевым метрикам, а в задаче RuMedNER даже превышает человеческую точность. Успех этих моделей подтверждает ценность доменно-специфичного предобучения для медицинского NLP. Однако эти модели предназначены для общего понимания медицинских текстов и используют фиксированную скрытую размерность эмбедингов (1024). Исследование, предлагаемое в данной статье, имеет другую цель, оно направлено на получение компактных низкоразмерных векторных представлений для эффективного поиска в медицинских RAG-системах.

МАТЕРИАЛЫ И МЕТОДЫ

Данное исследование основывается на модели RuBERT, а именно на варианте DeepPavlov/rubert-base-cased. Базовая архитектура этой модели включает 12 слоёв трансформера с размером эмбедингов в 768 измерений, что обеспечивает баланс между вычислительной эффективностью и размером векторных представлений [2]. Модель была предварительно обучена на большом русскоязычном наборе данных, что обеспечивает ей широкое понимание русского языка. Эта основа делает модель подходящей для дальнейшей адаптации к специализированным областям через тонкую настройку.

Для тонкой настройки использовался набор данных RuMedDaNet из бенчмарка RuMedBench [3]. Датасет RuMedDaNet предназначен для решения задачи ответов на вопросы типа "да/нет", охватывающую различные медицинские области, включая фармакологию, анатомию и терапевтическую медицину. Каждый пример в наборе данных состоит из: медицинского контекста, предоставляющего основную информацию; вопроса, связанного с этим контекстом; ответа "да" или "нет".

Пример:

Контекст: "Эпилепсия — это хроническое полиэтиологическое заболевание головного мозга, доминирующим проявлением которого являются повторяющиеся эпилептические приступы, возникающие вследствие

повышенного гиперсинхронного разряда нейронов головного мозга."

Вопрос: "Эпилепсия является заболеванием головного мозга человека?"

Ответ: "да" [3]

Выбор набора данных RuMedDaNet для тонкой настройки модели оптимизации эмбедингов был обусловлен рядом ключевых факторов. Во-первых, RuMedDaNet содержит структурированные тройки "медицинский контекст — вопрос — ответ (типа "да/нет")", что идеально соответствует задаче оптимизации поиска релевантных контекстов для RAG-систем и отвечает цели улучшения точности анализа медицинских запросов через повышение качества эмбедингов. Во-вторых, RuMedDaNet является частью общепризнанного бенчмарка RuMedBench, используемого для оценки русскоязычных медицинских моделей, что обеспечивает простую воспроизводимость результатов. В-третьих, четкие связи "вопрос-контекст" позволяют генерировать позитивные (релевантные) и негативные (нерелевантные) пары для обучения эффективных эмбедингов.

В рамках данного исследования набор данных RuMedDaNet был адаптирован для обучения моделей построения векторных представлений текста. На основе этого набора данных были сформированы семантически связанные пары вопросов и соответствующих им контекстов, которые стали основой для дообучения модели. Для оптимизации процесса использовалась функция потерь Multiple Negatives Ranking Loss [8], которая учит модель отличать релевантные данные от случайных, используя отрицательные примеры (то есть примеры с ответом "нет") из текущего набора данных.

Для повышения эффективности обучения был реализован подход, который можно описать как структурированное контекстно-контрастное представление данных. Его ключевая идея заключается в особом расположении семантически связанных примеров в обучающей выборке, когда тексты со схожей тематикой или близкими терминами в процессе обучения подаются модели последовательно. Это создаёт эффект усиленного контрастного восприятия — модель начинает тоньше различать нюансы между похожими медицинскими понятиями (такими как "гипертензия" и "гипертония"), одновременно сохраняя способность к широкому

обобщению на уровне крупных тематических разделов (кардиология, онкология и др.). Такой подход представляется важным именно для медицинских текстов, где необходима способность модели различать терминологические нюансы. Медицинская лексика часто содержит ситуативные синонимы ("инфаркт" и "ОИМ"), контекстно-зависимые трактовки терминов, а также тонкие различия между клинически близкими состояниями. Традиционные методы обучения могут "размывать" эти различия, тогда как предлагаемая стратегия может повысить способность модели улавливать подобные детали.

Процесс тонкой настройки был реализован с использованием фреймворка SentenceTransformers [8], который предоставляет эффективные инструменты для обучения и оптимизации моделей эмбедингов. Был применен многоэтапный подход к обучению.

Сначала модель была настроена с использованием функции потерь Multiple Negatives Ranking Loss (1) для формирования прочной основы медицинских знаний.

$$\text{Loss} = \sum_{i=1}^P \sum_{j=1}^N \max(0, f(q, p_i) - f(q, n_j) + \text{margin}) \quad (1)$$

где: P — количество положительных примеров, N — количество отрицательных примеров, q — входной запрос, p_i — i -й положительный пример, n_j — j -й отрицательный пример, f — функция, измеряющая схожесть между векторами запроса и примера, margin — гиперпараметр, определяющий желаемое разделение между положительными и отрицательными примерами.

На следующем этапе была использована функция потерь Matryoshka Loss для оптимизации модели по производительности на нескольких размерах эмбедингов (64, 128, 256, 512 и 768).

В завершение был проведен процесс доработки с комбинацией перечисленных функций потерь для обеспечения согласованности между различными целями оптимизации.

Формула функции потерь Matryoshka Loss (2) выглядит следующим образом:

$$\text{Loss}_{\text{MRL}} = \sum_{d_i \in M} w_{d_i} \cdot \text{Loss}_{d_i} \quad (2)$$

Таблица 1 — Гиперпараметры модели

Размер батча	16
Скорость обучения	$2e^{-5}$
Количество эпох	4
С линейным разогревом и спадом	да
Весовое затухание (weight decay)	0,01
Ограничение градиента (gradient clipping)	1,0
Максимальная длина последовательности	512

где: w_{d_i} — вес, назначенный размерности d_i , $Loss_{d_i}$ — функция потерь для задачи (например, кросс-энтропия или ранжирование), применяемая к эмбедингам размером d_i .

Гиперпараметры обучения, представленные в таблице 1, были тщательно подобраны на основе предварительных экспериментов.

Для повышения скорости обучения и эффективной работы с длинными последовательностями в данном исследовании использовался метод Flash Attention 2 [9], реализованный через механизм SDPA (Scaled Dot-Product Attention) [10]. Этот подход оптимизирует вычисления за счёт перераспределения операций внимания [11], что позволило значительно ускорить обработку сложных текстовых данных. Применение Flash Attention 2 не только сократило время обучения, но и улучшило точность анализа за счёт более глубокого учёта контекстных связей в длинных медицинских описаниях. Это особенно важно для задач, требующих одновременного анализа множества взаимосвязанных терминов, таких как диагностические критерии или фармакологические взаимодействия.

Для проверки качества поиска с использованием предложенной модели эмбедингов использовалась тестовая часть набора данных RuMedDaNet, на основе которой был сформирован тестовый корпус медицинских контекстов (исходный датасет [3], составленный медицинскими экспертами, содержит 1564 примера для обучения и валидации и 512 примеров для тестирования). Целью эксперимента было определить, насколько точно модели извлекают релевантные фрагменты текста по заданному вопросу.

Производительность модели оценивалась с помощью двух ключевых поисковых метрик: NDCG (Normalized Discounted Cumulative Gain), которая учитывает не только наличие релевантных документов в ответе на запрос, но и

их позицию в результатах поиска и MRR (Mean Reciprocal Rank), отражающую среднюю позицию первого корректного ответа.

Формула расчета NDCG имеет вид [12]:

$$NDCG = \frac{DCG}{IDCG} \quad (3)$$

где:

$$DCG = \sum_{i=1}^k \frac{(2^{r_i} - 1)}{\log_2(i + 1)},$$

$$IDCG = \sum_{i=1}^k \frac{(2^{r_i^*} - 1)}{\log_2(i + 1)}$$

где: k — количество рассматриваемых ответов на запрос, r_i — релевантность результата на позиции i в ранжированном списке ответов на запрос, r_i^* — релевантность результата на позиции i в идеально отсортированном списке.

Формула расчета MRR выглядит следующим образом [13]:

$$MRR = \frac{1}{N} \sum_{i=1}^k \frac{1}{rank_i}, \quad (4)$$

где: N — количество запросов, $rank_i$ — позиция первого релевантного результата для i -го запроса.

Эксперименты проводились для эмбедингов разной размерности от 64 до 768 измерений. Такой подход позволил проанализировать эффективность метода Matryoshka Representation Learning, который оптимизирует распределение информации в векторах, сохраняя высокую точность даже при сокращении их размера.

Исследование выполнялось в среде Python версии 3.9.1. с использованием графического процессора NVIDIA RTX 3090 (24 ГБ VRAM). Для загрузки и предварительной обработки датасета использовалась библиотека datasets версии 3.3.1. Для построения, обучения и оценки моделей эмбедингов применялись библиотеки sentence_transformers версии 3.3.1 и torch версии 2.5.1. Для публикации и управления моделями в репозитории Hugging Face Hub использовалась библиотека huggingface_hub версии 0.29.0.

РЕЗУЛЬТАТЫ

Первоначальная оценка эффективности проводилась на оригинальной версии модели

RuBERT без дополнительной доменной адаптации. Результаты, представленные в Таблице 2, отражают значения метрики NDCG при различных размерностях векторных представлений.

Анализ данных выявил устойчивую зависимость между размерностью эмбедингов и качеством поиска: с уменьшением количества измерений наблюдается постепенное снижение показателей эффективности. Такая закономерность объясняется фундаментальным ограничением базовых моделей — недостаточной емкостью низкоразмерных векторных представлений для кодирования всей необходимой семантической информации. Особенно критичным это становится при работе со специализированными медицинскими терминами и понятиями, требующими точного различения смысловых нюансов. Полученные результаты подтверждают необходимость адаптации моделей для работы с узкоспециализированными доменами. После тонкой настройки на наборе данных RuMedDaNet наблюдаются существенные улучшения в производительности поиска на всех размерах эмбедингов, что также отражено в таблице 2.

Улучшения присутствуют и по другой метрике оценки. Таблица 3 показывает значения метрики MRR для обеих моделей (базовой и дообученной). Результатом является значительное улучшение показателей во всех размерностях, особенно заметное на эмбедингах с меньшей размерностью. Такая закономерность свидетельствует о том, что тонкая настройка позволяет модели эффективнее выделять ключевую информацию в каждом измерении, улучшая общую эффективность без снижения производительности.

Проведенные эксперименты подтвердили эффективность подхода Matryoshka Representation Learning. Анализ сохранения относительной производительности модели на разных размерностях эмбедингов в сравнении с полными 768-мерными представлениями представлен в Таблице 4.

Результаты показывают, что модель, настроенная с использованием предлагаемого подхода, сохраняет более 94% производительности при использовании всего 128 измерений, что соответствует шестикратному уменьшению исходного размера. Даже при сокращении размерности эмбедингов до 64 (уменьшение исходного размера в 12 раз) модель демонстрирует

Таблица 2 — Сравнение значений метрики NDCG между базовой и настроенной моделями

Размерность	Базовая модель	Настроенная модель	Улучшение
768	0,5128	0,7201	40,43%
512	0,5064	0,7018	38,59%
256	0,4891	0,7001	43,14%
128	0,4523	0,6778	49,86%
64	0,3986	0,6196	55,44%

Таблица 3 — Сравнение значений метрики MRR между базовой и настроенной моделями

Размерность	Базовая модель	Настроенная модель	Улучшение
768	0,4832	0,6720	39,07%
512	0,3773	0,6606	75,09%
256	0,3612	0,6581	82,20%
128	0,3324	0,638	91,93%
64	0,2743	0,5799	111,41%

Таблица 4 — Сохранение производительности эмбедингов с уменьшенной размерностью относительно 768-мерных эмбедингов

Размерность	% полной производительности (NDCG)	% полной производительности (MRR)
512	97,46%	98,03%
256	97,22%	97,93%
128	94,12%	94,94%
64	86,04%	86,29%

более 86% от исходной эффективности. Такой баланс между уменьшением размерности и сохранением точности делает данный подход особенно полезным для систем с ограниченными вычислительными ресурсами.

На практике уменьшение размерности эмбедингов в 6 раз позволит пропорционально снизить размеры векторных баз данных в медицинских RAG-системах и повысить скорость обработки запросов к большим языковым моделям, что сегодня является крайне актуальной задачей.

Предлагаемая в данном исследовании модель получила название Med-Bert-Matryoshka-v1 и была загружена на платформу Hugging Face, где




Рисунок 1 — График сравнения метрик NDCG и MRR.

теперь она доступна для открытого использования и дальнейшего развития сообществом специалистов в области искусственного интеллекта [14].

Для оценки качества работы модели в задачах информационного поиска было проведено сравнение с несколькими ведущими моделями построения эмбедингов. В качестве метрик использовались MRR и NDCG с мерой косинусного сходства.

Среди сравниваемых моделей эмбедингов рассматривались:

- 1) GigaChat-embedding [15] — проприетарная модель для построения эмбедингов, отличающаяся высокой производительностью;
- 2) Med-Bert-Matryoshka-v1 [14] — модель, предлагаемая в данном исследовании для повышения эффективности поиска в медицинских векторных базах данных;
- 3) MiniLM-L12-v2 [16] — компактная модель построения эмбедингов, разработанная для высокой вычислительной эффективности;
- 4) RuBert_tiny2 [17] — облегчённая версия RuBERT, адаптированная для работы с русскоязычными данными;
- 5) Sbert_large_nlu_ru [18] — крупноразмерная модель, ориентированная на обработку естественного русского языка.

Результаты исследования (рисунок 1) показали, что GigaChat-embedding, будучи коммерческой моделью, демонстрирует наивысшую эффективность по обеим метрикам (MRR и NDCG). Это объясняется значительными вычислительными ресурсами, задействованными при её обучении и оптимизации.

Тем не менее, обученная в данном исследовании open source модель Med-Bert-Matryoshka-v1 также показала высокую конкурентоспособность, заняв второе место с показателями метрик MRR = 0,71 и NDCG = 0,75. Это свидетельствует о её способности обеспечивать точное и релевантное извлечение информации из текстовых данных при формировании моделей эмбедингов, что особенно важно в RAG — системах.

Остальные модели продемонстрировали более скромные результаты. MiniLM-L12-v2 достигла значений около 0,5 по обеим метрикам, что указывает на её ограниченную эффективность в задачах поиска, несмотря на низкую вычислительную сложность. RuBert_tiny2 и Sbert_large_nlu_ru показали ещё более низкие результаты — в диапазоне 0,3–0,35 и 0,2–0,25 соответственно, что свидетельствует о неэффективности их применения в задачах информационного поиска медицинских данных по сравнению с исследуемой моделью.

Таким образом, проведённое сравнение подтверждает, что модель Med-Bert-Matryoshka-v1, представляющая собой RuBERT, дообученную на русскоязычных медицинских данных, является эффективной моделью получения эмбедингов для решения задач поиска информации, уступив в вычислительном эксперименте только коммерческому решению GigaChat-embedding.

ОБСУЖДЕНИЕ

Результаты данного исследования, показывающие значительный прирост качества после тонкой настройки на медицинских данных

(Таблицы 2, 3), полностью согласуются с выводом авторов RuMedBench [3, 4] о том, что универсальные языковые модели демонстрируют существенный разрыв в эффективности при работе со специализированной медицинской терминологией по сравнению с человеческим уровнем. Данное исследование предлагает один из возможных способов для преодоления этого разрыва.

Хотя базовая модель RuBERT показывает высокую эффективность в обработке общеупотребительной лексики, её применение в медицинских контекстах является ограниченным из-за недостатка специализированных знаний. Проведённая донастройка на корпусе RuMedDaNet позволяет устранить этот пробел, значительно повышая точность распознавания и кодирования медицинских данных.

Применение метода Matryoshka Representation Learning (MRL) позволило не только повысить точность, но и добиться существенного сокращения вычислительных затрат. Это согласуется с результатами работы [5] о том, что ключевая семантическая информация может быть эффективно упакована в начальных измерениях вектора. Проведенный в данном исследовании эксперимент показал, что даже при шестикратном сжатии (с 768 до 128 измерений) модель Med-Bert-Matryoshka-v1 сохраняет более 94% эффективности. Это открывает возможности для существенного снижения вычислительных затрат на генерацию эмбедингов, их индексирование и поиск — крайне важный фактор для ресурсоёмких сред, таких как мобильные медицинские приложения или системы с ограниченными аппаратными возможностями.

Хотя тонкая настройка существенно улучшила качество работы модели, анализ ее ошибок позволил выявить ряд устойчивых проблем. В частности, модель демонстрирует снижение эффективности в следующих случаях.

Сложные вопросы, требующие многошаговых рассуждений. Модель не всегда корректно обрабатывает запросы, предполагающие анализ взаимосвязей между несколькими медицинскими концепциями, что является общей проблемой для современных языковых моделей в медицине [19]. Это указывает на то, что, несмотря на успешное усвоение терминологии, система не всегда способна распознавать сложные логические цепочки.

Редкие термины и узкоспециализированные процедуры. Вопросы, содержащие малоупотребительную лексику или редко встречающиеся в обучающих данных медицинские процедуры, обрабатываются менее точно. Данное ограничение подтверждает необходимость использования более репрезентативных и разнообразных наборов данных при дообучении.

Неоднозначные формулировки и зависимость от контекста. Запросы, допускающие множественную интерпретацию, нередко приводят к ошибкам.

Подобные случаи иллюстрируют сложность работы с медицинским языком, где точность формулировок и понимание контекста играют существенную роль. Выявленные ограничения определяют перспективные направления для дальнейших исследований. Среди возможных улучшений — расширение обучающей выборки за счёт более разнородных медицинских текстов, включая данные, ориентированные на развитие навыков клинического мышления [19], а также разработка специализированных методов обучения, лучше учитывающих семантические нюансы медицинской терминологии, интеграция формализованных медицинских знаний и онтологий в процесс обучения, как это предлагается, например, в работе [20].

Как уже отмечалось, существуют и другие успешные подходы к адаптации языковых моделей для медицины, такие как RuBioRoBERTa [7], которая показала превосходство над RuBERT в задачах общего понимания медицинских текстов. Однако данное исследование фокусируется на иной, но не менее важной задаче — оптимизации компактных векторных представлений именно для эффективного поиска в RAG-системах, а не на решении широкого круга NLP-задач. Это объясняет и выбранные в исследовании метрики оценки.

ЗАКЛЮЧЕНИЕ

Проведённое исследование демонстрирует существенное улучшение качества семантических эмбедингов, используемых для информационного поиска в рамках архитектуры RAG. Оптимизированная модель Med-Bert-Matryoshka-v1 обеспечивает более точную релевантность извлекаемых данных, что непосредственно влияет на достоверность генерируемых ответов на медицинские запросы и важно для обеспечения клинической надежности ИИ-решений.

Перспективными направлениями для дальнейших исследований могут стать: расширение спектра используемых русскоязычных медицинских текстов для тонкой настройки, интеграция формализованных медицинских знаний в процесс обучения, а также разработка специализированных функций потерь, учитывающих особенности медицинской терминологии.

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

Финансирование. Авторы заявляют, что не получали финансовой поддержки при проведении данного исследования, написании и/или публикации данной статьи.

ЛИТЕРАТУРА/REFERENCES

1. Lewis P, Perez J, Piktus A, et al. Retrieval-augmented generation for knowledge-intensive NLP tasks. *Adv Neural Inf Process Syst.* 2020; 33: 9459-9474. doi: 10.48550/arXiv.2005.11401.
2. Kuratov Y, Arkhipov M. Adaptation of deep bidirectional multilingual transformers for Russian language. *arXiv. Preprint posted online May 17, 2019.* doi: 10.48550/arXiv.1905.07213.
3. MedBench [Internet]. Открытый набор задач в области здравоохранения [cited 2025 May 3]. Available from: <https://medbench.ru/>
4. Blinov P, Chertok A, Drozdov A, et al. RuMedBench: a Russian medical language understanding benchmark. *Artif Intell Med.* 2022; 383-392. doi: 10.1007/978-3-031-09342-5_38.
5. Kusupati A, Ordonez V, Parikh D, et al. Matryoshka representation learning. *Adv Neural Inf Process Syst.* 2022; 35: 30233-30249. doi: 10.48550/arXiv.2205.13147.
6. Devlin J, Chang MW, Lee K, Toutanova K. BERT: Pre-training of deep bidirectional transformers for language understanding. *Proc NAACL-HLT.* 2019; 1: 4171-4186. doi: 10.18653/v1/N19-1423.
7. Yalunin A, Nesterov A, Umerenkov D. RuBioRoBERTa: a pre-trained biomedical language model for Russian language biomedical text mining. *arXiv. Preprint posted online April 8, 2022.* doi: 10.48550/arXiv.2204.03951.
8. Reimers N, Gurevych I. Sentence-BERT: Sentence embeddings using Siamese BERT-networks. *Proc EMNLP-IJCNLP.* 2019; 3982-3992. doi: 10.18653/v1/D19-1410.
9. Dao T, Fu T, Ermon S, et al. FlashAttention: Fast and memory-efficient exact attention with IO-awareness. *Adv Neural Inf Process Syst.* 2022; 35: 16344-16359. doi: 10.48550/arXiv.2205.14135.
10. Dao T. Flashattention-2: Faster attention with better parallelism and work partitioning. *arXiv. Preprint posted online July 17, 2023.* arXiv: 2307.08691. doi: 10.48550/arXiv.2307.08691.
11. Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need. *Adv Neural Inf Process Syst.* 2017; 30. doi: 10.48550/arXiv.1706.03762.
12. Wang Y, et al. A theoretical analysis of NDCG type ranking measures. *J Mach Learn Res.* 2013; 25-54. doi: 10.48550/arXiv.1304.6480.
13. Craswell N. Mean Reciprocal Rank. In: Liu L, Özsu MT, eds. *Encyclopedia of Database Systems.* Springer; 2009. doi: 10.1007/978-0-387-39940-9_488.
14. TrungKienCding. Med-Bert-Matryoshka-v1 [Internet]. Hugging Face [cited 2025 May 3]. Available from: <https://huggingface.co/TrungKienCding/Med-Bert-Matryoshka-v1>.
15. GigaChatEmbeddings [Internet]. [cited 2025 May 3]. Available from: <https://deepwiki.com/ai-forever/gigachain/3-gigachatembeddings>.
16. Sentence-transformers/all-MiniLM-L12-v2 [Internet]. Hugging Face [cited 2025 May 3]. Available from: <https://huggingface.co/sentence-transformers/all-MiniLM-L12-v2>.
17. Cointegrated/rubert-tiny2 [Internet]. Hugging Face [cited 2025 May 3]. Available from: <https://huggingface.co/cointegrated/rubert-tiny2>.
18. Ai-forever/sbert_large_nlu_ru [Internet]. Hugging Face [cited 2025 May 3]. Available from: https://huggingface.co/ai-forever/sbert_large_nlu_ru.
19. Jin, D., Pan, E., Oufattole, N., Weng, W. H., Fang, H., & Szolovits, P. (2021). What Disease Does This Patient Have? A Large-Scale Open Domain Question Answering Dataset from Medical Exams. *Applied Sciences*, 11(14), 6421. doi: 10.3390/app11146421.
20. Радюш Д.В. Методы интеграции знаний для разработки вопросно-ответных систем. *Russian Technological Journal.* — 2025. — №13(3). — С.21-43. [Radyush DV. Knowledge injection methods in question answering. *Russian Technological Journal.* 2025; 13(3): 21-43. (In Russ).] doi: 10.32362/2500-316X-2025-13-3-21-4300.

КРЕМНЕВА Е.И.,

д.м.н., ФГБНУ РЦНН, г. Москва, Россия; e-mail: kremneva@neurology.ru;
ORCID: 0000-0001-9396-6063

СЕМЕНОВ Д.С.,

к.т.н., ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: SemenovDS4@zdrav.mos.ru;
ORCID: 0000-0002-4293-2514

СМОРЧКОВА А.К.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: SmorchkovaAK@zdrav.mos.ru;
ORCID: 0000-0002-9766-3390

ХОРУЖАЯ А.Н.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: KhoruzhayaAN@zdrav.mos.ru;
ORCID: <https://orcid.org/0000-0003-4857-5404>

КУЛИГОВСКИЙ Д.В.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: KuligovskiiDV@zdrav.mos.ru

АДАМИЯ Н.Д.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: AdamiyaND1@zdrav.mos.ru

ЕРИЖОКОВ Р.А.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: ErizhokovRA@zdrav.mos.ru;
ORCID: 0009-0007-3636-2889

ОМЕЛЯНСКАЯ О.В.,

ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: OmelyanskayaOV@zdrav.mos.ru;
ORCID: 0000-0002-0245-4431

ВЛАДЗИМИРСКИЙ А.В.,

д.м.н., д.и.н., ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: VladzimirskijAV@zdrav.mos.ru;
ORCID: 0000-0002-2990-7736

ВАСИЛЬЕВ Ю.А.,

д.м.н., ГБУЗ «НПКЦ ДиТ ДЗМ», г. Москва, Россия; e-mail: VasilevYA1@zdrav.mos.ru;
ORCID: 0000-0002-5283-5961

ОЦЕНКА ЭФФЕКТИВНОСТИ ПРИМЕНЕНИЯ ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ ДЛЯ СУБТРАКЦИИ MOSMEDREG В ДИАГНОСТИКЕ РАССЕЯННОГО СКЛЕРОЗА ПО ДАННЫМ МАГНИТНО-РЕЗОНАНСНОЙ ТОМОГРАФИИ

DOI: 10.25881/18110193_2026_1_74

Аннотация. Цель работы — оценить эффективность автоматизированного программного обеспечения MosMedReg для субтракционного анализа МРТ головного мозга в динамике у пациентов с рассеянным склерозом в условиях рутинной амбулаторной практики. В исследование включены 30 пар МРТ, выполненных на аппаратах 1,5 Тл разных производителей, с использованием последовательностей T2, FLAIR и T1 с контрастированием и вариативной толщиной срезов. Для обработки применялись алгоритмы регистрации и субтракции на базе библиотеки SimpleElastix. Изображения анализировались экспертом вручную и с помощью программного обеспечения, результаты оценивались по клинической и технической шкалам.

Программное обеспечение обеспечило успешную регистрацию и субтракцию во всех случаях, включая серии с различиями в толщине срезов и проекциях. Среднее количество выявленных новых очагов при использовании MosMedReg не отличалось от экспертной оценки ($p = 0,25$), однако в ряде случаев субтракция позволила выявить клинически значимые изменения, не отмеченные при стандартном анализе. Отмечались и ложноположительные находки, связанные с техническими артефактами при несоответствии параметров сканирования.

Результаты подтверждают воспроизводимость и практическую применимость субтракционного анализа с помощью MosMedReg для повышения объективности и стандартизации диагностики в амбулаторной практике.

Ключевые слова: рассеянный склероз; магнитно-резонансная томография; субтракция; автоматизация; программное обеспечение; регистрация изображений.

Для цитирования: Кремнева Е.И., Семенов Д.С., Сморгочова А.К., Хоружая А.Н., Кулиговский Д.В., Адамия Н.Д., Ерижков Р.А., Омелянская О.В., Владимирский А.В., Васильев Ю.А. Оценка эффективности применения программного обеспечения для субтракции MosMedReg в диагностике рассеянного склероза по данным магнитно-резонансной томографии. *Врач и информационные технологии.* 2026; 1: 74-89. DOI: 10.25881/18110193_2026_1_74.

KREMNEVA E.I.,

DSc, RCNN; Russian Center for Neurology and Neurosciences, Moscow, Russia; e-mail: kremneva@neurology.ru;
ORCID: 0000-0001-9396-6063

SEMENOV D.S.,

PhD, Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: SemenovDS4@zdrav.mos.ru;
ORCID: 0000-0002-4293-2514

SMORCHKOVA A.K.,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: SmorchkovaAK@zdrav.mos.ru;
ORCID: 0000-0002-9766-3390

KHORUZHAYA A.N.,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: KhoruzhayaAN@zdrav.mos.ru;
ORCID: 0000-0003-4857-5404

KULIGOVSKIY D.V.,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: KuligovskiiDV@zdrav.mos.ru

ADAMIA N.D.,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: AdamiyaND1@zdrav.mos.ru

ERIZHOKOV R.A.,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: ErizhokovRA@zdrav.mos.ru;
ORCID: 0009-0007-3636-2889

OMELYANSKAYA O.V.,

Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: OmelyanskayaOV@zdrav.mos.ru;
ORCID: 0000-0002-0245-4431

VLADZYMYRSKIY A.V.,

DSc, Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: VladzimirskijAV@zdrav.mos.ru;
ORCID: 0000-0002-2990-7736

VASILEV YU.A.,

DSc, Moscow Center for Diagnostics and Telemedicine, Moscow, Russia; e-mail: VasilevYA1@zdrav.mos.ru;
ORCID: 0000-0002-5283-5961

MOSMEDREG SUBTRACTION SOFTWARE EFFECTIVENESS IN MULTIPLE SCLEROSIS DIAGNOSIS USING MAGNETIC RESONANCE IMAGING DATA

DOI: 10.25881/18110193_2026_1_74

Abstract. *The aim of this study was to evaluate the effectiveness of the automated MosMedReg software for subtraction analysis of longitudinal brain MRI in patients with multiple sclerosis in a routine outpatient setting. The study included 30 paired MRI examinations performed on 1.5 T scanners from different manufacturers using T2, FLAIR, and contrast-enhanced T1 sequences with variable slice thicknesses. Image processing was performed using registration and subtraction algorithms based on the SimpleElastix library. Images were assessed manually by an expert and with the assistance of the software; results were evaluated using clinical and technical scoring systems.*

The software provided successful registration and subtraction in all cases, including series different in slice thickness and projections. The average number of newly identified lesions using MosMedReg did not differ from expert assessment ($p = 0.25$); however, in several cases, subtraction enabled the detection of clinically significant changes that were not observed in standard analysis. False-positive findings associated with technical artifacts due to scan parameter mismatches were also noted.

The results confirm the reproducibility and practical applicability of subtraction analysis with MosMedReg for improving the objectivity and standardization of multiple sclerosis diagnosis in outpatient practice.

Keywords: *multiple sclerosis; magnetic resonance imaging; subtraction; automation; software; image registration.*

For citation: *Kremneva E.I., Semenov D.S., Smorchkova A.K., Khoruzhaya A.N., Kuligovskiy D.V., Adamia N.D., Erizhokov R.A., Omelyanskaya O.V., Vladzimirskyy A.V., Vasilev Yu.A. MosMedReg Subtraction Software effectiveness in Multiple Sclerosis Diagnosis Using Magnetic Resonance Imaging Data. Medical doctor and information technology. 2026; 1: 74-89. DOI: 10.25881/18110193_2026_1_74.*

ВВЕДЕНИЕ

Рассеянный склероз (РС) хроническое аутоиммунное заболевание центральной нервной системы, характеризующееся развитием нейровоспаления, демиелинизацией, глиозом и потерей нейронов [1, 2]. Заболеванию подвержено приблизительно 2,8 миллиона человек во всем мире с глобальной распространенностью 35,9 случаев на 100 000 населения [3, 4]. При этом чаще всего манифестация происходит в молодом возрасте, что приводит к инвалидизации трудоспособного и экономически наиболее активного населения. Согласно критериям McDonald 2017 года, магнитно-резонансная томография (МРТ) является одним из основных параклинических инструментов с высокой чувствительностью и точностью, что позволяет с ее помощью проводить раннюю диагностику заболевания и отслеживать динамику состояния пациента при лечении [5]. Согласно клиническим рекомендациям, пациентам с РС требуется регулярное выполнение МР-исследований, зачастую — ежегодно или чаще, для мониторинга эффективности терапии и активности заболевания [6].

Однако проблема диагностических ошибок при РС остается критически высокой. Исследования показали, что частота неправильной постановки диагноза РС составляет 15% (95% ДИ: 9–26%), а гиподиагностика встречается в 36% случаев (95% ДИ: 20–55%). Время до исправления неправильного диагноза может достигать 15,9 лет, а диагностическая задержка для установления правильного диагноза РС составляет в среднем 17,3 месяца [7]. Это происходит потому, что визуальный анализ последовательных МР-исследований представляет собой трудоемкую и субъективную задачу. Структурированные протоколы заключений при МР мониторинге РС способны снизить среднее время интерпретации с 11,0 до 8,5 минут [8], но в реалиях российской практики в большинстве случаев их стандартизация и структуризация отсутствуют. Межэкспертная вариабельность среди нейрорентгенологов даже при выявлении очагов, накапливающих контрастный препарат, составляет $k = 0,76$, что указывает на высокую субъективность процесса интерпретации [9]. Чувствительность стандартного рентгенологического обследования для выявления новых очагов, отражающего активность патологического

процесса, составляет всего 58,3% по сравнению с консенсусной экспертной оценкой [10].

Субтракционный анализ — методика автоматического пространственного сопоставления (регистрации) и вычитания изображений, представляет собой перспективный подход к решению этих проблем. Исследования показывают, что 3D субтракционные изображения обеспечивают повышенную чувствительность к выявлению активных очагов РС и меньшую подверженность артефактам по сравнению с традиционным визуальным анализом [11]. Автоматизированные методы типа SuBLIME демонстрируют высокую точность в выявлении активности заболевания при использовании логистической регрессии с множественными МР-последовательностями и субтракционными изображениями [12]. Современные алгоритмы на основе искусственного интеллекта (ИИ) достигают чувствительности 93,3% в нахождении новых очагов при сохранении высокой специфичности [10], а метод Statistical Detection of Change позволяет выявлять новые очаги у 15,0% пациентов по сравнению с 8,0% при стандартном визуальном анализе [13].

Тем не менее, подобные программные решения либо отсутствуют в арсенале рутинных диагностических систем, либо представлены как специализированные модули для аппаратов конкретных производителей, требующих специализированного оборудования и работающих только с данными, полученными по одному протоколу [14]. Это ограничивает их доступность, особенно в условиях дистанционной работы с диагностическими исследованиями. Научная и практическая значимость программ субтракционного анализа до сих пор не получила достаточной количественной оценки в условиях реальной клинической практики. Отсутствуют масштабные независимые исследования, напрямую сравнивающие традиционный и автоматизированный подходы к анализу динамики РС по данным МРТ в условиях различных протоколов сканирования. Поэтому целью данной работы стала оценка эффективности разработанного авторским коллективом программного обеспечения (ПО) MosMedReg для автоматической регистрации и субтракции МР-изображений в выявлении новых и увеличивающихся очагов у пациентов с РС.

МАТЕРИАЛЫ И МЕТОДЫ

Этическое одобрение

Исследование одобрено Независимым этическим комитетом Московского регионального отделения Российского общества рентгенологов и радиологов (протокол № 03/2025 от 27.03.2025).

Дизайн исследования

Проведено ретроспективное сравнительное обсервационное исследование, включавшее слепую экспертную оценку с использованием стандартизированных шкал и сравнение результатов автоматизированного анализа с рутинной клинической практикой.

Программное обеспечение

Для автоматизированного сравнения МР-исследований в динамике использовалось ПО MosMedReg, реализующее алгоритмы сегментации и субтракции изображений на основе библиотеки SimpleElastix [15].

ПО реализует последовательность классических алгоритмов регистрации и вычитания без использования методов ИИ. Программа принимает на вход две серии DICOM-изображений, автоматически определяет порядок срезов и выполняет пространственное совмещение изображений с помощью многоступенчатого алгоритма:

сначала применяется жёсткая (translation, affine), затем нежёсткая (B-spline) регистрация на базе библиотеки SimpleElastix. Затем из каждой пары совмещённых срезов поэлементно вычитаются значения сигнала, формируя новую субтракционную серию. Полученные результаты сохраняются в формате DICOM для последующего анализа в стандартных программах визуализации. Алгоритм устойчив к отличиям в проекциях (позволяет совместить, например, аксиальную серию с сагиттальной) и толщине срезов (например, сопоставляет срезы с толщиной среза 1 и 3 мм), не требует использования обучающих выборок и выполняет обработку за счёт классических математических и итерационных методов регистрации.

ПО изначально разрабатывалось как универсальное решение для обработки КТ-исследований с контрастированием. В рамках настоящей работы оно было адаптировано для работы с МР-изображениями за счёт добавления процедуры нормализации интенсивности сигнала, позволяющей устранить различия в яркости между сериями, полученными на разных аппаратах или при различных параметрах сканирования.

Программа имеет минималистичный интерфейс (рисунок 1): пользователю необходимо выбрать два исследования (более раннее и более позднее при сравнении серий (например,

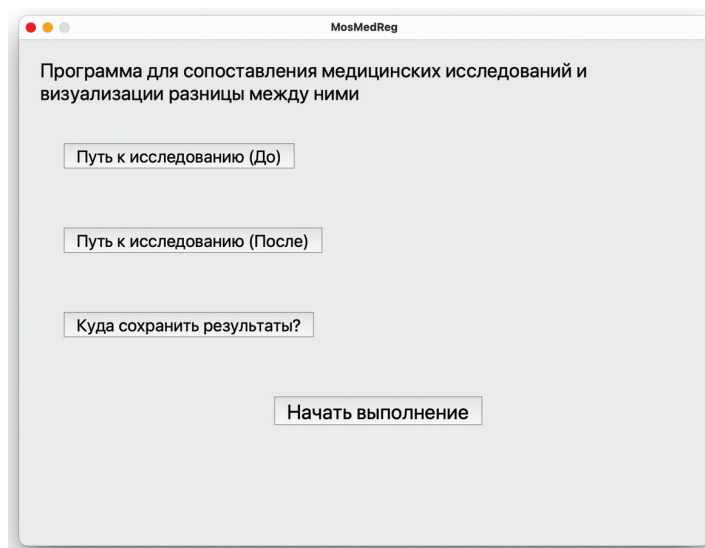


Рисунок 1 — Интерфейс программы MosMedReg.

T2-ВИ) в динамике или до и после контрастного усиления), указать директорию для сохранения результатов и нажать кнопку запуска. Все вычисления выполняются локально и не требуют специализированного оборудования или подключения к PACS: время анализа одной серии составляет менее одной минуты при использовании стандартного офисного компьютера (например, процессор Intel Core i5, 16 ГБ оперативной памяти без необходимости подключения дискретной видеокарты). Результаты сохраняются в формате DICOM и могут быть использованы для дальнейшего анализа в любом ПО для просмотра результатов рентгенологических исследований.

ПАЦИЕНТЫ

В исследование включены 30 пар анонимизированных МР-исследований головного мозга с внутривенным контрастным усилением, выполненных в два временных момента (MPT1 и MPT2) у пациентов с установленным диагнозом РС.

Все МР-исследования проводились в 12 медицинских организациях амбулаторного звена в период с 2020 по 2025 год на аппаратах 1,5 Тл различных производителей (Siemens, Philips, GE, Toshiba). Выборка сформирована ретроспективно случайным образом из регистра пациентов с установленным диагнозом. Средний возраст включённых пациентов составил $32,6 \pm 8,6$ года (диапазон: от 20 до 45 лет), женщин — 18 (60%), мужчин — 12 (40%). Интервал между MPT1 и MPT2 варьировал от 161 до 1835 сут (среднее — 441 сут).

Исследование проводилось в строгом соответствии с федеральным законом № 152-ФЗ «О персональных данных». Все данные, использованные в исследовании, были предварительно анонимизированы: из DICOM-файлов и pdf-файлов заключений удалены персональные сведения, включая ФИО, дату рождения, идентификаторы пациентов и медицинских учреждений. Информированное согласие не требовалось, поскольку использовались ранее полученные исследования, и пациенты уже подписывали стандартное согласие на обработку персональных данных в рамках оказания медицинской помощи.

Критерии включения:

- возраст старше 18 лет;
- подтвержденный диагноз РС;

- наличие не менее двух МРТ головного мозга, включающих серии до и после введения внутривенного контрастного вещества (КВ) и выполненных с интервалом не менее полугода;
- наличие сопоставимых серий: T2, FLAIR до контрастного усиления (КУ) и T1 после КУ. Критерии невключения:
- наличие иной патологии головного мозга (доброкачественные и злокачественные новообразования, состояние после острого нарушения мозгового кровообращения, сосудистые мальформации и пр.);
- низкое качество изображений, в том числе с выраженными артефактами, затрудняющими интерпретацию (невозможно оценить количество очагов) и автоматическую обработку изображений.

Во всех включённых случаях использовались стандартные протоколы с получением FLAIR, T2- и T1-взвешенных изображений до контрастирования, а также T1-взвешенных изображений после введения контрастного вещества с толщиной среза от 1 до 5 мм. Выбор режимов FLAIR и T2 обусловлен их высокой чувствительностью к выявлению очагов демиелинизации, а T1 после КУ — необходимостью оценки активных очагов с нарушением гематоэнцефалического барьера.

МЕТОДИКА АНАЛИЗА

Оценка эффективности внедряемых программных решений в клинической практике требует строгого количественного анализа, позволяющего объективно и воспроизводимо сравнивать результаты работы автоматизированных алгоритмов с традиционными методами интерпретации изображений. Применение формализованных количественных показателей (например, числа выявленных новых или увеличившихся очагов, времени анализа, баллов по клинической и технической шкалам) обеспечивает возможность не только внутреннего контроля качества, но и сопоставления полученных данных с результатами других исследований. Такой подход позволяет минимизировать влияние субъективного фактора, расширяет возможности статистического анализа и формирует основу для дальнейшего масштабирования и внедрения ПО в рутинную практику.

В данном исследовании анализ выполнялся в три этапа. На первом этапе из базы данных Единого радиологического информационного сервиса Единой медицинской информационно-аналитической системы г. Москвы (ЕРИС ЕМИАС) были отобраны пары МР-исследований головного мозга пациентов с подтвержденным диагнозом РС. Отобранные МР-изображения были анонимизированы и подготовлены для обработки. Также были выгружены соответствующие анонимизированные текстовые протоколы, описания и заключения для дальнейшей оценки первичной интерпретации описавшего их врача-рентгенолога. Из этих документов извлечены «базовые» значения числа очагов и изменений их размеров («Заключение из ЕРИС» в Таблице 1).

На втором этапе данные были подвергнуты автоматизированной субтракции с использованием MosMedReg. Для каждого случая субтракция выполнялась по следующим сериям:

- FLAIR (аксиальный и/или сагиттальный);
- T2 (аксиальный);
- T1 постконтрастный (аксиальный и/или сагиттальный).

Для каждой импульсной последовательности каждого пациента на вход программы подавались пары серий изображений, которые автоматически сопоставлялись, нормализовались и вычитались. Результатом являлись субтракционные серии в формате DICOM, сохранявшиеся в выделенную директорию для последующего анализа. Примеры изображений приведены в разделе Результаты.

На третьем этапе исходные и полученные изображения оценивались врачом-экспертом (нейрорентгенологом), имеющим опыт работы с нейровизуализацией более 15 лет. В ходе анализа фиксировались:

- число вновь выявленных очагов на T2 и FLAIR изображениях;
- число новых очагов накопления контраста на T1-ВИ после КУ;
- наличие очагов с изменением размеров.

Порядок оценки каждой пары МРТ-исследований экспертом был стандартизирован и включал в себя следующие последовательные этапы: сначала — оценка субтракционных изображений, затем — анализ исходных серий, после — оценка исходного протокола описания и заключения врача-рентгенолога амбулаторного звена. Последний этап — финальное заключение с оценкой по двум шкалам.

Для объективизации результатов применялись две шкалы:

- **Клиническая шкала** — оценка диагностической ценности субтракции и влияния на итоговое заключение (0 — «информации не добавлено», 1 — «новая информация отсутствует, но ускорен анализ», 2 — «обнаружены дополнительные очаги, не изменившие заключение» (например, в исходном описании был описан новый очаг — т.е. динамика отрицательная — при субтракции был найден еще один новый очаг), 3 — «обнаружены изменения, повлиявшие на заключение» (например, выявлен новый очаг, тогда как в исходном заключении в ЕРИС было указано «без динамики»), Таблица 1.
- **Техническая шкала** — оценка качества субтракционных изображений (от 0 — «нужные изображения отсутствуют» (полученное в результате работы ПО изображение не отвечает параметрам субтракционного), 1 — «качество субтракционных изображений не позволяет их оценить», 2 — «удовлетворительное качество»), Таблица 2.

Таблица 1 — Распределение баллов по клинической шкале

Балл по шкале	Интерпретация	Сравнение с заключением из ЕРИС		Сравнение с заключением эксперта	
		Кол-во случаев	Доля (%)	Кол-во случаев	Доля (%)
0	Субтракция не дала новой информации	2	6,7	2	6,7
1	Новая информация отсутствует, но ускорен анализ	21	70,0	25	83,3
2	Обнаружены дополнительные очаги, не изменившие заключение	3	10,0	2	6,7
3	Обнаруженные очаги повлияли на заключение	4	13,3	1	3,3

Оценка выполнялась вслепую без доступа к медицинской документации пациентов.

Обоснование размера выборки

Размер выборки был определен исходя из расчета минимально детектируемой разницы между методами анализа с использованием ПО для субтракции и без него при уровне значимости 5% и мощности 80%.

Статистический анализ

Для описания результатов использовались абсолютные и относительные частоты, а также распределения по баллам клинической и технической шкал. При необходимости рассчитывались точечные оценки и доверительные интервалы. Для оценки значимости различий при сравнении между группами, оцененными одним экспертом, использовался расчет критерия Вилкоксона для связанных выборок. Статистическая значимость установлена на уровне $p < 0,05$. Статистическая обработка выполнялась в программной среде Python с использованием стандартных библиотек анализа данных.

РЕЗУЛЬТАТЫ

В исследование вошли 30 пар МР-исследований (120 пар серий T2-, T1-ВИ, FLAIR, T1-ВИ с КУ), соответствующих критериям включения. Из них:

- полностью обработанные случаи (все три типа импульсных последовательностей): 23 из 30 (76,67%);

- частично обработанные случаи (из-за ошибки ПО): 7 из 30 (23,33%).

Оценка диагностической информативности по клинической шкале

Результаты клинической шкалы представлены в таблице 1.

В 13,3% случаев (4/30) субтракция позволила выявить новые изменения, которые повлияли на заключение врача (оценка 3).

В 10 % случаев (3/30) были выявлены дополнительные очаги, не повлиявшие на заключение, но зафиксированные в описании (оценка 2).

В 70–83% случаев использование ПО субъективно ускоряло (упрощало) анализ без добавления новой информации (оценка 1).

В 6,7% случаев субтракция не дала новой информации и не повлияла на скорость анализа (оценка 0).

Оценка качества субтракции по технической шкале

В результате обработки 3 пар импульсных последовательностей (MPT1-MPT2) для каждого из 30 пациентов было получено 90 серий субтракционных МР-изображений. Среди них 11 серий оказались непригодными для анализа с клинической точки зрения. Причем, у одного пациента не удалось совместить все 3 пары серий, у одного — 2 и у пятерых — по одной. Распределение баллов по сериям представлено в таблице 2.




Рисунок 2 — Распределение значений по клинической шкале: а — сравнение с заключением из ЕРИС, б — сравнение с экспертом нейрорентгенологом.

Таблица 2 — Распределение баллов по технической шкале

Балл по шкале	Интерпретация	Кол-во серий	Доля (%)
0	Отсутствие серий для работы ПО	0	0
1	Качество субтракционных изображений не позволяет их оценить	11	9,1
2	Качество удовлетворительное	109	90,9

Таблица 3 — Результаты применения ПО экспертом

Параметр	Было в описании	Дополнительно выявлено экспертом (в сравнении с описанием)	Дополнительно выявлено экспертом с использованием ПО (в сравнении с описанием)
Новые очаги на T2	14	13	8
Новые очаги на FLAIR	14	18	12
Очаги с накоплением на T1	9	0	1
Изменение размеров имеющихся очагов	1	4	2
Всего	38	+35	+23

Влияние субтракции на поиск новых очагов

Для количественной оценки влияния использования ПО на диагностику выполнено сравнение числа выявленных новых очагов РС и изменения размеров имеющихся очагов.

Так как основным критерием стала минимизация пропуска новых очагов, мы суммировали общее по всей выборке пациентов число очагов, выявленных в сравнении с первым исследованием. В результате, исходя из гипотезы о снижении числа пропусков с применением ПО, «базовым» значением стало число очагов (или измененных размеров очагов) в описании из ЕРИС. С этим значением сравнивали число очагов, которые дополнительно смог выявить эксперт с и без использования ПО.

Такой подход не характеризует состояния пациентов, однако позволяет оценить решение задачи «поиск новых очагов». Из анализа исключено 12 серий изображений из-за отсутствия точного указания числа очагов в исходном тексте описания (формулировка «множественные очаги»). Результаты применения ПО экспертом представлены в таблице 3.

При оценке различий между количеством дополнительно выявленных очагов одним и тем же экспертом с использованием ПО и без ($n = 4$) статистически значимого отличия получено не было ($W = 1,0$; $p = 0,25$).

Следует отметить, что в некоторых случаях экспертом было выявлено меньше очагов, чем описано в исходном протоколе. Так, при анализе исходных изображений и результатов субтракции зафиксировано на 2 очага меньше на сериях T2-изображений и на 4 очага меньше на T1 с КУ (на всей выборке пациентов). Если бы эксперт оценивал только результат субтракции (без исходных изображений), это бы привело к пропуску еще 8 очагов на T2 и 4 очагов на T1 с КУ. В основном, описываемые «новые» очаги были субкортикальной и юстакортикальной локализации.

Во включенных в работу МР-исследованиях толщина среза варьировалась в следующем диапазоне:

- T2: средняя толщина среза до (МРТ1) — 4,3 мм (диапазон: 2–5 мм), после (МРТ2) — 4,4 мм (3–5 мм);
- FLAIR: до — 4,2 мм (3–5 мм), после — 3,85 мм (1–5 мм), при этом в ряде случаев использовались тонкие срезы, включая изотропные серии;
- T1 с КУ: до — 2,28 мм (1,2–5 мм), после — 2,26 мм (1–5 мм), с включением 3D-серий с толщиной $\leq 1,5$ мм у части пациентов.

Несмотря на выраженную вариативность толщины срезов, алгоритм субтракции успешно справился с обработкой во всех случаях. Более

того, в ряде наблюдений субтракция выполнялась на изображениях, полученных в разных проекциях (например, аксиальная серия «до» и сагиттальная «после»), что не привело к сбоям в работе ПО и обеспечило клинически интерпретируемый результат. Это подтверждает устойчивость алгоритма к несовпадению проекций и параметров сканирования в условиях рутинной амбулаторной практики.

ПРИМЕРЫ КОРРЕКТНОЙ И НЕКОРРЕКТНОЙ ОБРАБОТКИ

Пример 1. Выявление новых очагов на T2-ВИ

У пациента № 8 (рисунок 3) при сравнении T2-взвешенных изображений за 2022 и 2023 год субтракция позволила четко визуализировать появление новых очагов. Визуально определяются один юстакортикальный очаг в правой лобной доле и два очага в глубоком белом веществе левой лобной доли, которые были неубедительны при оценке исходных изображений. Субтракционное изображение позволило объективизировать нарастание очаговой симптоматики и повысить уверенность в заключении.

Пример 2. Устойчивость алгоритма при несовпадении толщины и проекций

На изображениях пациентов № 10 (рисунок 4, верхний ряд) и № 5 (рисунок 4, нижний ряд) продемонстрирована работа алгоритма

субтракции при значительных различиях в параметрах сканирования. У пациента № 10 использованы T1-взвешенные изображения с КУ, полученные с интервалом в один год: аксиальные срезы толщиной 2 мм (2023 г.) и сагиттальные 1 мм (2024 г., представлена аксиальная реформация). Несмотря на существенные различия, алгоритм выполнил регистрацию, хотя субтракционное изображение содержит артефакты. При этом известная венозная ангиома в островковой доле не попала в область «новых» изменений, что соответствует клинической стабильности.

У пациента № 5 (нижний ряд) изображения выполнены также в разных проекциях: коронарные 1,2 мм (2022 г.) и аксиальные 2 мм (2024 г.). Несмотря на это, субтракция позволила получить качественное изображение без значимых артефактов.

Пример 3. Пропущенный очаг, выявленный при субтракции

У пациента № 13 при сравнении FLAIR-изображений, выполненных в 2023 и 2025 гг., субтракция позволила четко визуализировать новый очаг в правом полушарии, не описанный врачом амбулаторного звена при первичном анализе (рисунок 5). Очаг был зафиксирован экспертом на субтракционном изображении и классифицирован как значимый, что отразилось в присвоении максимального балла по клинической шкале (оценка 3).




Рисунок 3 — МР-изображения пациента № 8 (T2-ВИ): а — исследование от 2022 года; б — субтракционное изображение (2023 минус 2022); в — исследование от 2023 года. Отмечается появление нового очага в правой лобной доле и двух дополнительных очагов в левой (стрелки).




Рисунок 4 — Примеры субтракции T1-взвешенных изображений с различиями в толщине и проекциях: а — исходное изображение (2023), б — субтракционное изображение, в — контрольное исследование (2024). Стрелкой указана венозная аномалия развития (венозная ангиома). г — изображение 2022 г. (коронарное), д — субтракция, е — изображение 2024 г. (аксиальное). Видна устойчивость алгоритма к различиям в параметрах и ориентации данных.




Рисунок 5 — МР-изображения пациента №13 (FLAIR): а — исследование от 2023 года (акс, 5 мм); б — исследование от 2025 года (тот же режим); в — субтракционное изображение. Выявлен новый очаг в правом полушарии, не отмеченный в исходном описании.

ОБСУЖДЕНИЕ

Результаты настоящего исследования подтвердили исходную гипотезу о том, что использование разработанного ПО MosMedReg для субтракционного анализа способствует повышению диагностической эффективности при оценке МРТ-исследований у пациентов с РС. Ключевыми итогами стали обнаружение дополнительных очагов в 23,3% случаев при сравнении с первичными заключениями из ЕРИС ЕМИАС и изменение клинического заключения в 13,3% случаев, что демонстрирует практическую значимость автоматизированного подхода. Техническая эффективность алгоритма (90,9% успешных обработок) оказалась приемлемой для рутинного клинического использования, особенно учитывая высокую вариативность параметров сканирования в реальной практике. Способность ПО обрабатывать изображения, полученные в разных проекциях и с различной толщиной срезов, подтверждает его универсальность и адаптивность к условиям многопрофильных медицинских учреждений.

Применение субтракционного анализа позволяет выявлять новые очаги и очаги накопления контрастного вещества, которые не были заметны на исходных изображениях, однако эффективность работы алгоритмов зависит от исходных данных, в том числе импульсных последовательностей и их параметров [16, 17]. Особенно критичным является наличие артефактов движения и большая толщина среза [18]. Алгоритм показал наилучшую эффективность при работе с тонкими срезами (≤ 2 мм), особенно в последовательностях FLAIR и T1 с контрастным усилением. В этих режимах обеспечивалась высокая точность регистрации и визуализация изменений без выраженных артефактов. В то же время при использовании T2-взвешенных изображений с преимущественной толщиной среза 5 мм эффективность субтракции была ограничена, что связано с низким пространственным разрешением и вариабельностью геометрии между исследованиями. Тем не менее, субтракционные изображения особенно полезны для анализа областей с нативным T1-гиперинтенсивным сигналом (менее применимо для головного мозга) или с постконтрастным T1-гиперинтенсивным сигналом (например, вблизи с сосудистыми структурами), где патологическое накопление

контраста может быть замаскировано [19], а также на T2-ВИ изображениях вблизи ликворосодержащих пространств, имеющих сигнал, который близок к таковому от очагов субкортикальной/перивентрикулярной локализации.

Эти особенности следует учитывать при выборе серий для анализа в клинической практике.

Полученные результаты согласуются с данными других исследований эффективности субтракционного анализа при РС. Moraal и соавторы в работе 2010 года продемонстрировали, что 3D субтракционная визуализация обеспечивает улучшенное выявление активных очагов РС по сравнению с традиционным анализом [20]. Наши данные об обнаружении дополнительных 8 очагов на T2 и 12 очагов на FLAIR также говорят о повышении чувствительности при использовании метода субтракции. Более поздние исследования подтверждают перспективность автоматических подходов для анализа МРТ при РС. Liu и соавторы в 2023 году показали, что алгоритм Statistical Detection of Change способен выявлять новые очаги у 15,0% пациентов по сравнению с 8,0% при стандартном визуальном анализе [21]. Наши результаты (13,3% случаев изменения заключения) находятся в сопоставимом диапазоне, что подтверждает валидность подхода. Недавнее валидационное исследование Sacca и соавторов продемонстрировало превосходство систем на основе ИИ над стандартными радиологическими заключениями: чувствительность 93,3% против 58,3% [10]. Хотя наше исследование имело другой дизайн, полученные данные о 23,3% дополнительно выявленных случаев согласуются с этими выводами о существенном приросте диагностической информации при использовании автоматизированных методов.

Важно отметить, что сами субтракционные изображения являются результатом математической постобработки, поэтому их качество зависит не только от исходных данных, но и от применяемых алгоритмов субтракции.

Задача сопоставления (регистрации) двух изображений в лучевой диагностике не нова. Активное развитие разработки ПО, решающего данную задачу, началось в 90х — 2000-х годах и обусловлено, в первую очередь, ускорением вычислительных алгоритмов [22, 23]. При этом использовались как нежесткие методы

регистрации, позволяющие определить локальные изменения на изображении, так и автоматизированные системы, обеспечивающие и субтракцию (вычитание).

Важнейшим шагом в повышении качества решения задачи регистрации стало применение глубокого обучения и таких моделей, как U-net и VoxelMorph [24]. Глубокие методы обучения обеспечивают высокую точность и гибкость, позволяя адаптироваться к различным типам изображений и клиническим задачам, однако они требуют больших объемов обучающих данных для разработки и мощных вычислительных ресурсов как для разработки, так и для применения [25,26]. Кроме того, для применения может возникнуть необходимость переобучения на локальных данных [27].

Разработанное ПО демонстрирует несколько ключевых преимуществ перед существующими коммерческими решениями. В отличие от функционирующих только с оборудованием конкретного производителя модулей типа Teamplay (Siemens) или AIR Recon DL (GE), наше решение является универсальным и может работать с данными любых производителей МР-томографов. Время обработки менее одной минуты на стандартном ПК обеспечивает практическую применимость в рутинной практике. Устойчивость алгоритма к различиям в параметрах сканирования особенно важна в условиях российской системы здравоохранения, где пациенты часто обследуются на различном оборудовании в разных медицинских организациях. Способность обрабатывать изображения с толщиной срезов от 1 до 5 мм и в различных проекциях расширяет возможности применения ПО. В нашем решении использовался итеративный алгоритм SimpleElastix с открытым исходным кодом. Он требует настройки для конкретной задачи, но позволяет значимо сократить время работы [25].

Существует построенное на базе Elastix дополнение для распространенного ПО для обработки медицинских изображений 3DSlicer — SlicerElastix [28]. Однако его установка требует технических навыков, а приложение направлено в первую очередь на регистрацию, но не субтракцию. Аналогичное решение представляет собой RegLSM [29]. Оно предназначено в первую очередь для сопоставления КТ и МР-изображений головного мозга, но также не обеспечивает

субтракцию и требует специальных технических навыков для использования.

Таким образом, в рамках данного исследования было показано, что разработанное ПО повышает точность диагностики РС по данным МРТ с КУ, не требует дополнительной квалификации интерпретирующего врача-рентгенолога и может быть использовано на любом персональном компьютере. Впоследствии доработки алгоритма при необходимости позволят использовать его и для функциональных МР-последовательностей типа МР-перфузии, оценка которой у пациентов с РС представляет собой перспективное диагностическое направление [30].

Ограничения

Настоящее исследование имеет ряд существенных ограничений, которые необходимо учитывать при интерпретации результатов. Ретроспективный характер исследования не позволяет оценить влияние результатов субтракционного анализа на реальные клинические решения и исходы лечения. Включение 30 пациентов является относительно небольшой выборкой, что ограничивает статистическую мощность исследования и может влиять на точность оценки эффективности ПО, особенно для редких типов изменений. Привлечение единственного эксперта-нейрорентгенолога для оценки результатов создает потенциальный риск субъективности и не позволяет оценить межэкспертную надежность метода. 9,1% неудачных обработок указывают на необходимость дальнейшего совершенствования алгоритма. Критерии включения могли привести к селекции технически более качественных исследований, что может завышать эффективность ПО в реальной клинической практике.

Выводы

Разработанное ПО MosMedReg продемонстрировало способность повышать диагностическую эффективность при анализе МРТ-исследований у пациентов с РС. Выявление дополнительных очагов в 23,3% случаев и изменение клинических заключений в 13,3% случаев, наряду с высокой технической надежностью (90,9% успешных обработок), свидетельствуют о практической значимости автоматизированного подхода.

Следует отметить, что предлагаемое ПО предназначено прежде всего для поддержки рутинной практики, где квалификация и специализация рентгенологов могут существенно различаться. Основная ценность автоматизированного субтракционного анализа заключается не столько в превышении экспертной оценки, сколько в обеспечении стабильного и воспроизводимого уровня диагностики для широкой популяции пациентов, проходящих МРТ в амбулаторных условиях.

Несмотря на ограничения использования при выраженных артефактах, ПО упрощает анализ за счет синхронизации срезов. Простота интерфейса, низкие системные требования и совместимость с форматом DICOM позволяют легко интегрировать ПО в рутинную клиническую практику, включая амбулаторные и дистанционные сценарии. Однако для окончательных выводов о клинической эффективности необходимы дальнейшие мультицентровые проспективные исследования с более крупными выборками пациентов.

ЛИТЕРАТУРА/REFERENCES

1. Coutinho Costa VG, Araujo SE-S, Alves-Leon SV and Gomes FCA (2023) Central nervous system demyelinating diseases: glial cells at the hub of pathology. *Front. Immunol.* 14: 1135540. doi: 10.3389/fimmu.2023.1135540.
2. Захарова М.Н. Рассеянный склероз: вопросы диагностики и лечения. Практическое руководство для врачей. — Москва: Медиа Менте, 2018. 240 с. [Zakharova MN. Rasseyannyi skleroz: voprosy diagnostiki i lecheniya. Prakticheskoe rukovodstvo dlya vrachey. Moscow: Media Mente; 2018. 240 p. (In Russ.)]
3. Emilio P, Melinda M, Eva KH, et al. Multiple sclerosis: emerging epidemiological trends and redefining the clinical course, *The Lancet Regional Health Europe.* 2024; 44: 100977. doi: 10.1016/j.lanepe.2024.100977.
4. Walton C, King R, Rechtman L, et al. Rising prevalence of multiple sclerosis worldwide: Insights from the Atlas of MS, third edition. *Mult Scler.* 2020 Dec; 26(14): 1816-1821. doi: 10.1177/1352458520970841.
5. Rocca, Maria A, et al. Current and future role of MRI in the diagnosis and prognosis of multiple sclerosis. *The Lancet Regional Health — Europe.* 2024; 44: 100978. doi: 10.1016/j.lanepe.2024.100978.
6. Клинические рекомендации «Рассеянный склероз» (по итогам обсуждения на 5-м Конгрессе РОКИРС, г. Уфа, 30.09.2023 и на Президиуме ВОН 25.12.2024). 2024. Доступно по: <https://disk.yandex.ru/i/0vzicLGjK2wXBQ> (дата обращения: 17.06.2025). [Klinicheskie rekomendatsii "Rasseyannyi skleroz" (po itogam obsuzhdeniya na 5-m Kongresse ROKIRS, g. Ufa, 30.09.2023 i na Prezidiume VON 25.12.2024). 2024. Available at: <https://disk.yandex.ru/i/0vzicLGjK2wXBQ> (accessed 17.06.2025). (In Russ.)]
7. Zürrer WE, Cannon AE, Ilchenko D, et al. Misdiagnosis and underdiagnosis of multiple sclerosis: A systematic review and meta-analysis. *Multiple Sclerosis Journal.* 2024; 30(11-12): 1409-1422. doi: 10.1177/13524585241274527.
8. Lee JK, Bermel R, Bullen J, et al. Structured reporting in multiple sclerosis reduces interpretation time. *Academic Radiology.* 2021; 28(12): 1733-1738. doi: 10.1016/j.acra.2020.08.006.
9. Schlaeger S, Shit S, Eichinger P, et al. AI-based detection of contrast-enhancing MRI lesions in patients with multiple sclerosis. *Insights Imaging.* 2023; 14: 123. doi: 10.1186/s13244-023-01460-3.
10. Barnett M, Wang D, Beadnall H, et al. A real-world clinical validation for AI-based MRI monitoring in multiple sclerosis. *npj Digital Medicine.* 2023; 6: 196. doi: 10.1038/s41746-023-00940-6.
11. Eichinger P, Schön S, Pongratz V, et al. Accuracy of unenhanced MRI in the detection of new brain lesions in multiple sclerosis. *Radiology.* 2019; 291(2): 429-435. doi: 10.1148/radiol.2019181568.
12. Sweeney EM, Shinohara RT, Shea CD, et al. Automatic lesion incidence estimation and detection in multiple sclerosis using multisequence longitudinal MRI. *AJNR American Journal of Neuroradiology.* 2013; 34(1): 68-73. doi: 10.3174/ajnr.A3172.
13. Homssi M, Sweeney EM, Demmon E, et al. Evaluation of the statistical detection of change algorithm for screening patients with MS with new lesion activity on longitudinal brain MRI. *AJNR American Journal of Neuroradiology.* 2023; 44(6): 649-655. doi: 10.3174/ajnr.A7858.

14. Rovira À, Wattjes M, Tintoré M, et al. MAGNIMS consensus guidelines on the use of MRI in multiple sclerosis—clinical implementation in the diagnostic process. *Nature Reviews Neurology*. 2015; 11: 471-482. doi: 10.1038/nrneurol.2015.106.
15. Васильев Ю.А., Петрайкин А.В., Кулиговский Д.В., и др. Программа для обнаружения ликвореи по данным компьютерной томографии головного мозга. Свидетельство о государственной регистрации программы для ЭВМ №2023669002. 2023. [Vasil'ev YuA, Petrayaykin AV, Kuligovskiy DV, et al. Programma dlya obnaruzheniya likvorei po dannym komp'yuternoy tomografii golovnogo mozga. Certificate of state registration of computer program №2023669002. 2023. (In Russ.)]
16. Duan Y, et al. Segmentation of subtraction images for the measurement of lesion change in multiple sclerosis. *AJNR American Journal of Neuroradiology*. 2008; 29(2): 340-346. doi: 10.3174/ajnr.A0795.
17. Billot B, et al. SynthSeg: Segmentation of brain MRI scans of any contrast and resolution without retraining. *Medical Image Analysis*. 2023; 86: 102789. doi: 10.1016/j.media.2023.102789.
18. Meijer FJA, et al. Ultra-high-resolution subtraction CT angiography in the follow-up of treated intracranial aneurysms. *Insights Imaging*. 2019; 10: 2. doi: 10.1186/s13244-019-0685-y.
19. Tanaka R, et al. Novel developments in non-invasive imaging of peripheral arterial disease with CT: experience with state-of-the-art, ultra-high-resolution CT and subtraction imaging. *Clin Radiol*. 2019; 74(1): 51-58. doi: 10.1016/j.crad.2018.03.002.
20. Tanaka R, et al. Novel developments in non-invasive imaging of peripheral arterial disease with CT: experience with state-of-the-art, ultra-high-resolution CT and subtraction imaging. *Clinical Radiology*. 2019; 74(1): 51-58. doi: 10.1016/j.crad.2018.03.002.
21. Homssi M, Sweeney EM, Demmon E, et al. Evaluation of the statistical detection of change algorithm for screening patients with MS with new lesion activity on longitudinal brain MRI. *American Journal of Neuroradiology*. 2023; 44(6): 649-655. doi: 10.3174/ajnr.A7858.
22. Zitova B, Flusser J. Image registration methods: A survey. *Image and Vision Computing*. 2003; 21: 977-1000.
23. Twining CJ, Cootes T, Marsland S, et al. A unified information-theoretic approach to groupwise non-rigid registration and model building. In: Christensen GE, Sonka M, eds. *Information Processing in Medical Imaging*. IPMI 2005. Lecture Notes in Computer Science, vol 3565. Springer, Berlin, Heidelberg, 2005. doi: 10.1007/11505730_1.
24. Balakrishnan G, Zhao A, Sabuncu MR, et al. VoxelMorph: A learning framework for deformable medical image registration. *IEEE Transactions on Medical Imaging*. 2019; 38(8): 1788-1800. doi: 10.1109/TMI.2019.2897538.
25. Strittmatter A, Weis M, Zöllner FG. A groupwise multiresolution network for DCE-MRI image registration. *Scientific Reports*. 2025; 15: 9891. doi: 10.1038/s41598-025-94275-9.
26. Ratke A, Darsht E, Heinzelmann F, et al. Deep-learning-based deformable image registration of head CT and MRI scans. *Frontiers in Physics*. 2023; 11: 1292437. doi: 10.3389/fphy.2023.1292437.
27. Xiao H, Teng X, Liu C, et al. A review of deep learning-based three-dimensional medical image registration methods. *Quantitative Imaging in Medicine and Surgery*. 2021; 11(12): 4895-4916. doi: 10.21037/qims-21-175.
28. 3D SlicerElastix documentation. Available at: <https://github.com/lassoan/SlicerElastix/> (accessed 06.06.2025).
29. Meta VCI Map: Software tools. Available at: <https://metavcimap.org/features/software-tools/> (accessed 06.06.2025).
30. Попов В.В., Станкевич Ю.А., Василькив Л.М., Тулупов А.А. Бесконтрастное количественное исследование перфузионных изменений головного мозга при рассеянном склерозе. *Digital Diagnostics*. — 2024. — №5(S1). — С.86-88. [Popov VV, Stankevich YUA, Vasil'kiv LM, Tulupov AA. Beskontrastnoe kolichestvennoe issledovanie perfuzionnyh izmenenij golovnogo mozga pri rasseyannom skleroze. *Digital Diagnostics*. 2024; 5(S1): 86-88. (In Russ.)] doi: 10.17816/DD625953.

ЗУКОВ Р.А.,

д.м.н, профессор, КГБУЗ «Красноярский краевой клинический онкологический диспансер им. А.И. Крыжановского», г. Красноярск, Россия; ФГБОУ ВО «Красноярский государственный медицинский университет имени проф. В.Ф. Войно-Ясенецкого» Министерства здравоохранения Российской Федерации, г. Красноярск, Россия; e-mail: zukov.ra@krasgtmu.ru; ORCID ID 0000-0002-7210-3020

КОМИССАРОВА В.А.,

КГБУЗ «Красноярский краевой клинический онкологический диспансер им. А.И. Крыжановского», г. Красноярск, Россия; ФГБОУ ВО «Красноярский государственный медицинский университет имени проф. В.Ф. Войно-Ясенецкого» Министерства здравоохранения Российской Федерации г. Красноярск, Россия; e-mail: lera21734tkd@gmail.com; ORCID ID 0000-0002-5862-1761

ДАНИЛИН Т.А.,

КГБУЗ «Красноярский краевой клинический онкологический диспансер им. А.И. Крыжановского», г. Красноярск, Россия; ФГБОУ ВО «Красноярский государственный медицинский университет имени проф. В.Ф. Войно-Ясенецкого» Министерства здравоохранения Российской Федерации г. Красноярск, Россия; e-mail: timarik26@mail.ru; ORCID ID 0000-0001-6280-9233

САФОНЦЕВ И.П.,

к.м.н., доцент, КГБУЗ «Красноярский краевой клинический онкологический диспансер им. А.И. Крыжановского», г. Красноярск, Россия; ФГБОУ ВО «Красноярский государственный медицинский университет имени проф. В.Ф. Войно-Ясенецкого» Министерства здравоохранения Российской Федерации г. Красноярск, Россия; e-mail: safoncev@gmail.com; ORCID ID 0000-0002-8177-6788

СРАВНИТЕЛЬНЫЙ АНАЛИЗ ИСПОЛЬЗОВАНИЯ СИСТЕМ ПОДДЕРЖКИ ПРИНЯТИЯ ВРАЧЕБНЫХ РЕШЕНИЙ ПРИ АНАЛИЗЕ МАММОГРАФИЧЕСКИХ ИССЛЕДОВАНИЙ В КРАСНОЯРСКОМ КРАЕ

DOI: 10.25881/18110193_2026_1_90

Аннотация. Цель: Оценка эффективности технологий искусственного интеллекта (ИИ) в интерпретации маммографических изображений на примере сравнительного анализа заключений врачей-рентгенологов первичного звена и специалистов референс-центра КГБУЗ «КККОД им. А.И. Крыжановского» (КККОД).

Материалы и методы: проведен ретроспективный анализ 1012 маммографических исследований, выполненных в марте-мае 2025 г., направляемых в референс-центр КККОД согласно установленному порядку. Оценивались заключения врачей-рентгенологов референс-центра и первичного звена, а также результаты двух сервисов ИИ по шкале BI-RADS. Статистическая обработка выполнена программой StatTech 4.0.6, рассчитывался показатель дискордантности для клинических случаев, влияющих на дальнейшую тактику ведения пациентов.

Результаты: в Красноярском крае внедрение в практику врачей-рентгенологов второго ИИ-сервиса при проведении маммографического исследования привело к увеличению диагностически сложных категорий BI-RADS 3,4, что повысило нагрузку на референс-центр КККОД на 29,5%. При этом процент дискордантности не претерпел изменений (27,5%) в сравнении с 2024 годом, когда на территории края использовался один сервис ИИ. По результатам ретроспективного анализа отмечены различия в работе двух сервисов ИИ при интерпретации маммографических исследований.

Заключение: использование многофункциональных цифровых платформ на основе ИИ повышает качество профилактики и диагностики заболеваний, снижая вероятность врачебных ошибок. Однако одновременное применение нескольких сервисов увеличивает нагрузку на специалистов ввиду необходимости анализа множества вариантов интерпретаций.

Ключевые слова: искусственный интеллект, рак молочной железы, заболеваемость, маммографические исследования, референс-центр, Красноярский край.

Для цитирования: Зуков Р.А., Комиссарова В.А., Данилин Т.А., Сафонцев И.П. Сравнительный анализ использования систем поддержки принятия врачебных решений при анализе маммографических исследований в Красноярском крае. *Врач и информационные технологии.* 2026; 1: 90-100. DOI: 10.25881/18110193_2026_1_90.

ZUKOV R.A.,

DSc, Professor, A.I. Kryzhanovsky Krasnoyarsk Territorial Clinical Oncology Dispensary, Krasnoyarsk, Russia; FSBEI HE Prof. V.F. Voino-Yasenetsky KrasSMU MOH Russia; Krasnoyarsk, Russia; e-mail: zukov.ra@krasgmu.ru; ORCID ID 0000-0002-7210-3020

KOMISSAROVA V.A.,

A.I. Kryzhanovsky Krasnoyarsk Territorial Clinical Oncology Dispensary, Krasnoyarsk, Russia; FSBEI HE Prof. V.F. Voino-Yasenetsky KrasSMU MOH Russia; Krasnoyarsk, Russia; e-mail: lera21734tkd@gmail.com; ORCID ID 0000-0002-5862-1761

DANILIN T.A.,

A.I. Kryzhanovsky Krasnoyarsk Territorial Clinical Oncology Dispensary, Krasnoyarsk, Russia; FSBEI HE Prof. V.F. Voino-Yasenetsky KrasSMU MOH Russia; Krasnoyarsk, Russia; e-mail: timarik26@mail.ru; 0000-0001-6280-9233

SAFONTSEV I.P.,

PhD, Associate Professor, A.I. Kryzhanovsky Krasnoyarsk Territorial Clinical Oncology Dispensary, Krasnoyarsk, Russia; FSBEI HE Prof. V.F. Voino-Yasenetsky KrasSMU MOH Russia; Krasnoyarsk, Russia; e-mail: safoncev@gmail.com; ORCID ID 0000-0002-8177-6788

COMPARATIVE ANALYSIS OF THE USE OF MEDICAL DECISION SUPPORT SYSTEMS IN THE ANALYSIS OF MAMMOGRAPHIC STUDIES IN THE KRASNOYARSK REGION

DOI: 10.25881/18110193_2026_1_90

Abstract. *Aim: To evaluate the effectiveness of artificial intelligence (AI) technologies in interpreting mammographic images using a comparative analysis of reports from primary care radiologists and specialists from the reference center of the of the A.I. Kryzhanovsky Krasnoyarsk Territorial Clinical Oncology Dispensary (KKKOD) when interpreting mammographic studies conducted in the Krasnoyarsk Territory.*

We conducted a retrospective analysis of 1012 mammographic examinations performed in March-May 2025, sent to the KKKOD reference center according to the established procedure. The reports from KKKOD reference center and primary care radiologists, as well as the results of two AI services using the BI-RADS scale, were evaluated. Statistical processing was performed using StatTech 4.0.6, and a discordance index was calculated for clinical cases that impact subsequent patient management.

Results: in the Krasnoyarsk Region, the introduction of a second artificial intelligence (AI) service for mammography interpretation by radiologists led to an increase in the diagnostically challenging BI-RADS 3.4 categories, increasing the workload of the KKKOD reference center by 29.5%. However, the discordance rate remained unchanged (27.5%) compared to 2024, when only one AI service was used in the region. A retrospective analysis revealed differences in the performance of the two AI services when interpreting mammography examinations.

Conclusion: the use of multifunctional AI-based digital platforms improves the quality of disease prevention and diagnosis, reducing the likelihood of medical errors. However, the simultaneous use of several services increases the workload of specialists due to the need to analyze multiple interpretation options.

Keywords: *Artificial intelligence, breast cancer, incidence, mammography studies, Reference Center, Krasnoyarsk Territory.*

For citation: *Zukov R.A., Komissarova V.A., Danilin T.A., Safontsev I.P. Comparative analysis of the use of medical decision support systems in the analysis of mammographic studies in the Krasnoyarsk region. Medical doctor and information technology. 2026; 1: 90-100. DOI: 10.25881/18110193_2026_1_90.*

ВВЕДЕНИЕ

В Красноярском крае рак молочной железы (РМЖ) на протяжении 5 лет остается ведущей онкологической патологией среди женского населения, составляя около 23,1% всех зарегистрированных случаев в 2024 году [1–4]. Отмечается устойчивый рост числа впервые выявленных случаев РМЖ на 18,4% (с 1615 случаев в 2019 до 1912 случаев в 2024 году). Одновременно зафиксирован положительный тренд в структуре заболеваемости, характеризуемый повышением доли раннего выявления болезни на I–II стадиях опухолевого процесса на 3,2% (с 75,8% в 2019 году до 78,2% в 2024 году). Положительная динамика на территории региона обусловлена как широким охватом скрининговыми мероприятиями, ростом осведомленности населения, увеличением средней продолжительности жизни, так и оптимизацией диагностики путем внедрения специализированных инструментов. К таким инструментам относятся референс-центр (РЦ), функционирующий на базе КГБУЗ «Красноярский краевой клинический онкологический диспансер им. А.И. Крыжановского» (КККОД) и обеспечивающий экспертное заключение по маммографическим исследованиям категории BI-RADS 3 и 4, а также внедрение систем поддержки принятия врачебных решений (СППВР) при анализе маммографических исследований.

Современное развитие методов цифровой диагностики существенно расширило возможности раннего обнаружения злокачественных новообразований молочных желез, однако рутинный процесс чтения маммограмм остается достаточно трудоемким и подверженным влиянию человеческого фактора [5]. Для снижения вероятности диагностических ошибок и увеличения точности оценки применяются СППВР, основанные на технологиях искусственного интеллекта (ИИ) [6, 7]. Настоящее исследование посвящено двум подобным продуктам, успешно интегрированным в работу врачей-рентгенологов региона: запущенной в эксплуатацию в 2024 году ИИ-СППВР «Цельс» (ООО «Медицинские скрининг системы», регистрационное удостоверение — РЗН 2022/18861) и ИИ-сервис от платформы «Третье Мнение» (государственный регистрационный номер — 5177746328106). Внедрение второго ИИ-сервиса было связано со вступлением Красноярского края в конце

2024 года в число регионов Российской Федерации, подключившихся к национальной платформе МосМедИИ [8]. Данная платформа представляет собой централизованный сервис, использующий технологии ИИ для дистанционного анализа лучевых исследований и улучшения доступности медицинской помощи населению. В Красноярском крае работа с данной платформой организована с февраля 2025 года.

ЦЕЛЬ ИССЛЕДОВАНИЯ

Оценка эффективности технологий ИИ в интерпретации маммографических изображений на примере сравнительного анализа заключений врачей-рентгенологов первичного звена и специалистов РЦ КККОД.

МАТЕРИАЛЫ И МЕТОДЫ

Исследовательская работа осуществлялась посредством ретроспективного анализа маммографических изображений, направленных в РЦ КККОД в период март-май 2025 года. Направление маммографических исследований проводилось в соответствии региональным порядком по организации экспертного прочтения маммографических исследований: снимки категории BI-RADS 3,4 при первом прочтении через региональную телемедицинскую систему в течение одного рабочего дня с момента первого чтения направляются в РЦ КККОД [9]. Объем проанализированной выборки составил 1 012 маммографических исследований. Результаты заключений врачей-рентгенологов РЦ анализировались на основании заключений из региональной медицинской информационной системы, заключения врачей-рентгенологов первичного звена анализировались на основании заявок, поступивших в РЦ через региональную телемедицинскую систему (ПТС). Заключение относительно категорий BI-RADS, полученные с использованием технологий ИИ, вносились путем просмотра соответствующих файлов в региональном архиве медицинских изображений (РАМИ) с применением программного модуля iQ-4VIEW.

Статистический анализ проводился с использованием программного продукта StatTech 4.0.6. Расчет показателя дискордантности считался для клинически значимых расхождений, при которых различия заключений могли привести к изменению маршрутизации пациента. Коэффициент

дискордантности определялся следующим способом: отношение искомой категории BI-RADS к сумме значений этой категории и тех категорий, которые не влияют на изменение маршрута пациента, умноженное на коэффициент 100%.

РЕЗУЛЬТАТЫ

Появление инструментов, направленных на помощь в принятии врачебных решений при диагностике РМЖ, сопровождается заметным ростом числа впервые выявленных случаев данного заболевания [10]. Соответственно, наблюдается тенденция увеличения объема направлений исследований, выполненных врачами-рентгенологами первичного звена, на экспертное заключение в РЦ КККОД. Это явление обусловлено двумя вероятными факторами: ИИ-сервис способен выявить элементы патологических изменений, которые могли быть упущены врачом-рентгенологом; гипердиагностика (завышение категории BI-RADS) специалистами первичного звена с целью получения экспертного мнения. Тенденция роста числа направленных изображений в РЦ КККОД за период с 2022 по 2025 годы отражена на рисунке 1. Так, в 2024 году объем маммографических снимков, направляемых в РЦ КККОД, увеличился на 38,8% (с 6 489 в 2023 году до 9 005 в 2024 году). При сохранении данной динамики на конец 2025 года прогнозируется прирост количества направленных на пересмотр маммограмм по сравнению с показателями предыдущего периода в среднем на 29,5%. Резкий подъем графика в 2024 году объясняется внедрением

ИИ-сервиса «Цельс», а дополнительный рост в объеме направления снимков на пересмотр за 8 месяцев 2025 года в сопоставлении с аналогичным периодом прошлого года вызван началом применения второго ИИ-сервиса «Третье Мнение» в качестве СППВР в диагностике РМЖ.

Несмотря на положительную динамику увеличения числа впервые выявленных случаев РМЖ в регионе, введение дополнительного инструмента с ИИ привело к ряду организационно-методических трудностей, с которыми столкнулись специалисты РЦ и врачи-рентгенологи первичного звена. Специалисты РЦ отметили значительное возрастание нагрузки вследствие увеличения количества маммографических изображений, подлежащих экспертному анализу. Дополнительно зафиксировано появление избыточных обращений, инициированных врачами в ситуации неопределённости, возникающей при различии классификаций BI-RADS, предложенных различными ИИ-сервисами, и мнением самого специалиста. Так, в случае, когда один ИИ-сервис определяет категорию BI-RADS 2, второй ИИ-сервис выставляет BI-RADS 3, а врач-рентгенолог первичного звена делает заключение о BI-RADS 1 (рисунок 2), специалист принимает решение о направлении заявки в РЦ КККОД для пересмотра маммограмм. Из 1 012 исследований, направленных в РЦ, было 17 с неподходящей категорией (< BI-RADS 3), что составило 1,7%.

Практическое применение нового инструмента с ИИ вызвало ряд существенных сложностей для врачей-рентгенологов.




Рисунок 1 — Динамика направления маммографических исследований в РЦ КККОД.




Рисунок 2 — Отличие в категории BI-RADS между различными ИИ-сервисами.

Первое — количественный рост обрабатываемой визуальной информации. Вместо традиционных восьми изображений (четырёх стандартных снимков обеих молочных желёз в двух проекциях плюс четырёх аналогичных снимков с разметкой ИИ-сервиса «Цельс»), теперь специалистам предоставляется еще одна дополнительная серия из четырёх изображений, содержащих разметку от второго ИИ-сервиса «Третье Мнение». Визуализация рабочего экрана врача-рентгенолога представлена на рисунке 3.

Второе — расхождение в заключениях двух ИИ-сервисов, которые отличаются от заключения врача-рентгенолога. Разметка, определение плотности тканей и особенно категория BI-RADS, от которой зависят последующие шаги медицинского вмешательства [9], нередко отличаются существенными несоответствиями. На рисунке 4 представлен пример: врач-рентгенолог устанавливает категорию BI-RADS 4, ИИ-сервис «Цельс» — категорию BI-RADS 5, ИИ-сервис «Третье Мнение» — категорию BI-RADS 2. Специалист РЦ КККОД на основании пересмотра направленных маммографических изображений выдает заключение о категории BI-RADS 2, образование левой молочной железы, фиброзно-жировая инволюция молочных желез. Пациентке рекомендовано выполнение маммографии в плановом порядке 1 раз в год.

Третья проблема обусловлена техническими ограничениями используемого программного обеспечения. Привычный программный модуль iQ-4VIEW демонстрирует обработанные вторым ИИ-сервисом изображения примерно в 55% случаев, вынуждая пользователей прибегать к дополнительному ресурсу для оценки заключений, выставленных данным сервисом — платформе «Комета», что снижает удобство рабочего




Рисунок 3 — Рабочий экран врача-рентгенолога при работе с двумя ИИ-сервисами.



Рисунок 4 — Отличия в категории BI-RADS между различными ИИ-сервисами, влияющие на изменение маршрутизации пациента.

процесса и замедляет принятие своевременных решений.

При постановке цели изучения дискордантности изначально предполагался диапазон расхождений в пределах 25–30%, исходя из того факта, что КККОД не имеет доступа к полному массиву сведений о присвоении категорий BI-RADS обоими ИИ-сервисами («Цельс» и «Третье Мнение») для всего спектра проведенных цифровых маммографических исследований, хранящихся в РАМИ. Данное исследование основывалось исключительно на маммографических исследованиях, направленных в РЦ КККОД, куда направляются преимущественно случаи повышенной диагностической сложности, соответствующие категориям BI-RADS 3 и 4.

Проведение парного сравнительного анализа позволило получить следующие результаты:

1. Между заключениями врачей-рентгенологов первичного звена и сотрудниками РЦ уровень дискордантности составил 27,3%.
2. При сопоставлении заключений специалистов РЦ и заключений, выставленных

ИИ-сервисом «Цельс», расхождения достигли 29,7%.

3. Уровень несогласованности заключений между специалистами РЦ и заключениями ИИ-сервиса «Третье мнение» составил 27,9%.
4. Показатель дискордантности между заключениями врачей-рентгенологов первичного звена и заключениями, выставленными ИИ-сервисом «Цельс», достиг отметки 30,4%.
5. Величина расхождений между результатами врачей-рентгенологов первичного звена и решением ИИ-сервиса «Третье мнение» составила 25,7%.

Подробные расчеты приведены для сопоставления заключений работы врачей-рентгенологов первичного звена, работы двух ИИ-сервисов в сравнении с работой специалистов РЦ КККОД как экспертного мнения. Детальные показатели рассогласования между заключениями врачей-рентгенологов и результатами экспертов РЦ сведены в таблицу 1.

При этом установлено, что врачи-рентгенологи первичного звена недооценили значение категории в 16,9% случаев (причем в 107 случаях из 634 врачи РЦ скорректировали категорию, выставленную врачами-рентгенологами первичного звена, на BI-RADS 4 и выше). Напротив, завышенная оценка степени подозрения на наличие образования была отмечена в 44,7% случаев. Специалисты РЦ снизили категорию BI-RADS до 3 и ниже в 169 из 378 исследований, рекомендовав дальнейшее динамическое наблюдение пациенток у врача-гинеколога.

Показатель дискордантности между специалистами РЦ и ИИ-сервисом «Цельс» составил 29,7%. Подробности данного сопоставления изложены в таблице 2. Анализ продемонстрировал склонность ИИ-сервиса «Цельс» к гипердиагностике в 30,8% случаев (обнаружено в 195 исследованиях из общей совокупности 633), тогда как недостаточность чувствительности модели

Таблица 1 — Расчет дискордантности между рентгенологами первичного звена и РЦ КККОД

BI-RADS рентгенолога первичного звена		BI-RADS рентгенолога РЦ	
Категория BI-RADS	Количество снимков	Категория BI-RADS	Количество снимков
1, 2, 3	634	0-2	289
		3	238
		4-6	107
4	378	4-6	209
		0-3	169
5	0	4-6	0
		0-3	0

Дискордантность = $(107 + 169) / (634 + 378) * 100\% = 27,3\%$.

Таблица 2 — Расчет дискордантности между рентгенологами РЦ КККОД и ИИ-сервисом «Цельс»

BI-RADS рентгенолога РЦ		BI-RADS ИИ-сервис «Цельс»	
Категория BI-RADS	Количество снимков	Категория BI-RADS	Количество снимков
1, 2, 3	633	0-2	220
		3	218
		4-6	195
4	314	4-6	226
		0-3	88
5	6	4-6	6
		0-3	0

Дискордантность = $(195 + 88) / (633 + 314 + 6) * 100\% = 29,7\%$.

Таблица 3 — Расчет дискордантности между рентгенологами РЦ КККОД и ИИ-сервисом «Третье мнение»

BI-RADS рентгенолога РЦ		BI-RADS ИИ-сервис «Третье Мнение»	
Категория BI-RADS	Количество снимков	Категория BI-RADS	Количество снимков
1, 2, 3	311	0–2	254
		3	21
		4–6	34
4	138	4–6	49
		0–3	89
5	6	4–6	2
		0–3	4

Дискордантность = $(34 + 89 + 4) / (311 + 138 + 6) * 100\% = 27,9\%$.

выразилась в форме гиподиагностики в 28,0% случаев (установлено в 88 исследованиях из 314).

Так как формирование исходной базы данных происходило с использованием единого средства просмотра изображений iQ-4VIEW, то количество заключений, сформулированных ИИ-сервисом «Третье мнение», оказалось уменьшенным на 45% — получено 455 заключений для маммографических исследований. Показатель дискордантности между специалистами РЦ и ИИ-сервисом «Третье мнение» составил 27,9% (таблица 3). Полученные данные свидетельствуют о тенденции к гипердиагностике у ИИ-сервиса «Третье мнение» в 10,9% случаев (наблюдения выявлены в 34 из 311 исследований). Однако гораздо чаще встречается гиподиагностика — 64,5%. Например, в 89 случаях из 138 врач диагностировал подозрение на злокачественное новообразование (BI-RADS 4), однако ИИ-сервис «Третье мнение» оценил эти случаи как менее опасные (BI-RADS 0-3). Аналогично, в 4 ситуациях из 6, где врачи определили высокую вероятность РМЖ (BI-RADS 5), ИИ также недооценил риск. Это значит, что значительная доля возможных онкологических заболеваний может остаться незамеченной ИИ-сервисом.

Хотя уровень дискордантности между РЦ КККОД и ИИ-сервисом «Цельс» оказался выше, большее беспокойство вызывает недостаточная чувствительность подхода ИИ-сервиса «Третье мнение» к выявлению признаков потенциального злокачественного процесса (несмотря на сравнительно низкий уровень расхождений — 27,9%). Возможно, такая картина вызвана ограниченной репрезентативностью выборки, и при переходе к анализу полной

генеральной совокупности (всех маммографических исследований, проведенных в указанный временной интервал на территории региона и загруженных в базу региональных архивов медицинских изображений), показатели дискордантности для всех трёх сравниваемых групп будут заметно уменьшены.

С целью систематизации и последующего накопления статистических данных о практической эффективности применения ИИ на территории региона был разработан и внедрён стандартизированный протокол проведения маммографических исследований [11]. Обязательным элементом указанного документа стало внесение информации о категории BI-RADS, установленной ИИ. Вследствие отсутствия единой медицинской информационной системы на уровне региона, сбор необходимых данных осуществляется посредством реестрового учета территориального фонда обязательного медицинского страхования (ТФОМС), предусматривающего фиксацию ключевых полей: категорию BI-RADS, установленную врачом-рентгенологом, и категорию BI-RADS, определённую ИИ.

На сегодняшний день в Красноярском крае врачам-рентгенологам рекомендуется использовать один из имеющихся инструментов ИИ для анализа маммографических исследований либо одновременно оба указанных инструмента, при возникновении сомнений необходимо направление снимка на экспертное заключение в РЦ.

ОБСУЖДЕНИЕ

Пока ИИ остается помощником для врача-диагноста при анализе маммографических исследований, врач может использовать разметку

как ориентир, а также пользоваться шаблоном стандартизованного протокола при описании конкретной маммограммы, но все же решение о заключении по шкале BI-RADS и о дальнейшей тактике ведения пациента остается за врачом [12, 13]. Несмотря на положительные результаты ряда исследователей, предложивших автономную сортировку рентгеновских снимков на «норму» и «не норму» с высокой точностью заключения и высокой согласованностью между ИИ, врачом-рентгенологом и экспертами, внедрение аналогичных технологий в рутинную практику требует осторожности [14]. Для полноценной интеграции ИИ необходимо проведение дополнительных исследований с периодическим мониторингом работы ИИ-сервисов в реальной клинической практике. Необходимо накопить значительный опыт, детально изучить потенциальные ошибки и юридически обосновать ответственность за принятие решения при помощи ИИ.

ЗАКЛЮЧЕНИЕ

Интеграция современных технологий ИИ в медицину является важным этапом модернизации системы здравоохранения. Использование многофункциональных цифровых платформ

позволяет обеспечить высококвалифицированную помощь пациентам независимо от места проживания, улучшить уровень профилактической диагностики и снизить риск возникновения врачебных ошибок. Внедрение в практику одновременно нескольких СППВР позволяет повысить онконастороженность у специалистов первичного звена и положительно повлиять на показатели ранней диагностики злокачественных новообразований, но при этом в силу отсутствия в настоящий момент единых разработанных алгоритмов работы с несколькими СППВР увеличивается нагрузка как на врача-рентгенолога первичного звена (анализ одного и более заключений ИИ), так и специалистов РЦ в связи с ростом количества направленных исследований (заключений от ИИ). При этом возможности использования различных технологий ИИ в части всесторонней оценки результатов исследований для одного пациента позволяют врачу-рентгенологу объективно оценить все возможные варианты заключений по каждой отдельно взятой патологии и принять объективное решение для определения дальнейшей тактики.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

ЛИТЕРАТУРА/REFERENCES

1. Состояние онкологической помощи населению России в 2020 году / Под ред. Каприна А.Д., Старинского В.В., Шахзадовой — М.: МНИОИ им. П.А. Герцена – филиал ФГБУ «НМИЦ радиологии» Минздрава России, 2021. [Kaprin AD, Starinsky VV, Shakhzadova AO The state of oncological care for the population of Russia in 2020. М.: P.A. Herzen Moscow Oncology Research Institute – branch of the National Medical Research Center of Radiology of the Ministry of Health of the Russian Federation, 2021. (In Russ.)]
2. Состояние онкологической помощи населению России в 2021 году / Под ред. Каприна А.Д., Старинского В.В., Шахзадовой — М.: МНИОИ им. П.А. Герцена – филиал ФГБУ «НМИЦ радиологии» Минздрава России, 2022. [Kaprin AD, Starinsky VV, Shakhzadova AO The state of oncological care for the population of Russia in 2021. М.: P.A. Herzen Moscow Oncology Research Institute – branch of the National Medical Research Center of Radiology of the Ministry of Health of the Russian Federation, 2022. (In Russ.)]
3. Состояние онкологической помощи населению России в 2022 году / Под ред. Каприна А.Д., Старинского В.В., Шахзадовой — М.: МНИОИ им. П.А. Герцена – филиал ФГБУ «НМИЦ радиологии» Минздрава России, 2023. [Kaprin AD, Starinsky VV, Shakhzadova AO The state of oncological care for the population of Russia in 2022. М.: P.A. Herzen Moscow Oncology Research Institute – branch of the National Medical Research Center of Radiology of the Ministry of Health of the Russian Federation, 2023. (In Russ.)]
4. Состояние онкологической помощи населению России в 2023 году / Под ред. Каприна А.Д., Старинского В.В., Шахзадовой — М.: МНИОИ им. П.А. Герцена – филиал ФГБУ «НМИЦ радиологии» Минздрава России, 2024. [Kaprin AD, Starinsky VV, Shakhzadova AO The state of oncological care for the population of Russia in 2023. М.: P.A. Herzen Moscow Oncology Research Institute – branch of the National Medical Research Center of Radiology of the Ministry of Health of the Russian Federation, 2024. (In Russ.)]

5. Заридзе Д.Г. Перспективы применения искусственного интеллекта для повышения эффективности скрининга злокачественных новообразований // Общественное здоровье. — 2024. — Т.4. — №4. — С.24-42. [Zaridze DG Prospects for the use of artificial intelligence to improve the efficiency of screening for malignant neoplasms. Public Health. 2024; 4: 24-42. (In Russ.)] doi: 10.21045/2782-1676-2024-4-4-24-42.
6. Рожкова Н.И., Ройтберг П.Г., Варфоломеева А.А., Мазо М.Л. и др. Сегментационная модель скрининга рака молочной железы на основе нейросетевого анализ рентгеновских изображений // Сеченовский вестник. — 2021. — Т.11. — №3. — С.4-14. [Rozhkova NI, Roytberg PG, Varfolomeeva AA, Mazo ML, et al. Neural network-based segmentation model for breast cancer X-ray screening. Sechenov medical journal. 2021; 4: 4-14. (In Russ.)] doi: 10.47093/2218-7332.2020.11.3.4-14.
7. Морозов С.П., Говорухина В.Г., Диденко В.Г., Пучкова О.С. и др. Перспективы использования технологий искусственного интеллекта (ИИ) в скрининге рака молочной железы // Вопросы онкологии. — 2020. — Т.66. — №6. — С.603-608. [Morozov SP, Govorukhina VG, Didenko VG, Puchkova OS, et al. Prospect of application of artificial intelligence systems for breast cancer screening. Voprosy Onkologii. 2020; 6: 603-608. (In Russ.)] doi: 10.37469/0507-3758-2020-66-6-603-608.
8. Протокол заседания Оперативного штаба Министерства здравоохранения Российской Федерации от 31.10.2024 №73/13-7/578 под председательством Министра здравоохранения Российской Федерации. [Protokol zasedaniya Operativnogo shtaba Ministerstva zdravoohraneniya Rossijskoj Federacii ot 31.10.2024 №73/13-7/578 pod predsedatel'stvom Ministra zdravoohraneniya Rossijskoj Federacii. (In Russ.)]
9. Приказ Министерства здравоохранения Красноярского края от 30.09.2021 №1824-орг «Об организации Референс-центра для двойного чтения маммографических исследований» Доступно по: <http://onkolog24.ru/ru/to-specialists/normative-base>. Ссылка активна на 27.07.2024. [Order of the Ministry of Health of the Krasnoyarsk Territory dated September 30, 2021 No1824-org «On the organization of a Reference Center for double reading of mammography studies». <http://onkolog24.ru/ru/to-specialists/normative-base>. accessed 22.09.2025. (In Russ.)]
10. Зуков Р.А., Комиссарова В.А., Сафонцев И.П., Евминенко С.А. Искусственный интеллект в диагностике рака молочной железы: опыт региона // Врач и информационные технологии. — 2024. — №4. — С.72-84. [Zukov R.A., Komissarova V.A., Safontsev I.P., Evminenko S.A. Artificial intelligence in breast cancer diagnosis: regional experience. Medical doctor and information technology. 2024; 4: 72-84. (In Russ.)] doi: 10.25881/18110193_2024_4_72.
11. Письмо Министерства здравоохранения Красноярского края от 14.07.2025 №с-71-6621. [Pis'mo Ministerstva zdravoohraneniya Krasnoyarskogo kraja ot 14.07.2025 №s-71-6621. (In Russ.)]
12. Приказ Министерства здравоохранения Красноярского края от 06.08.2019 №936-орг «О маршрутизации пациенток с подозрением на рак молочной железы». Доступно по: <http://onkolog24.ru/ru/to-specialists/normative-base>. Ссылка активна на 27.07.2024. [Order of the Ministry of Health of the Krasnoyarsk Territory dated 08/06/2019 No936-org «On the routing of patients with suspected breast cancer». <http://onkolog24.ru/ru/to-specialists/normative-base>. accessed 22.09.2025. (In Russ.)]
13. Васильев Ю.А., Тыров И.А., Владзимирский А.В. и др. Двойной просмотр результатов маммографии с применением технологий искусственного интеллекта: новая модель организации массовых профилактических исследований // Digital Diagnostics. — 2023. — Т.4. — С.93-104. [Vasilev YA, Tyrov IA, Vladzimirskyy AV, et al. Double-reading mammograms using artificial intelligence technologies: A new model of mass preventive examination organization // Digital Diagnostics. 2023; 4: 93-104. (In Russ.)] doi: 10.17816/DD321423.
14. Ваньков В.В., Артемова О.Р., Карпов О.Э. и др. Итоги внедрения искусственного интеллекта в здравоохранении России // Врач и информационные технологии. — 2024. — №3. — С.32-43. [Vankov VV, Artemova OR, Karpov OE, et al. Results of the implementation of artificial intelligence in the Russian healthcare. Medical doctor and information technology. 2024; 3: 32-43. (In Russ.)] doi: 10.25881/18110193-2024-3-32.
15. Васильев Ю.А., Тыров И.А., Владзимирский А.В. и др. Автономный искусственный интеллект для сортировки результатов профилактических лучевых исследований // Профилактическая медицина. — 2024. — Т.27. — №7. — С. 23-29. [Vasilev YA, Tyrov IA, Vladzimirskyy AV, et al. Autonomous artificial intelligence for sorting the preventive imaging studies' results. Russian Journal of Preventive Medicine. 2024; 27(7): 23-29. (In Russ.)] doi: 10.17116/profmed20242707123.

