

<https://doi.org/10.29001/2073-8552-2025-40-1-28-41>
УДК 616.1:004.8(470+571)(048.8)

Системы искусственного интеллекта в профилактике и диагностике сердечно-сосудистой патологии в России (систематический обзор)

М.Н. Ковелькова, Е.Г. Яковлева

Российский национальный исследовательский медицинский университет имени Н.И. Пирогова
Министерства здравоохранения Российской Федерации (РНИМУ им. Н.И. Пирогова Минздрава России),
117997, Российская Федерация, Москва, ул. Островитянова, 1г

Аннотация

Цель исследования: анализ работ, проводимых в России за последние 5 лет, по выявлению рисков развития сердечно-сосудистых заболеваний (ССЗ) с использованием методов и технологий искусственного интеллекта (ИИ).

Материал и методы. Систематический обзор доступной литературы за последние 5 лет по использованию методов машинного обучения и представления знаний в прогнозировании развития и исходов ССЗ в России был выполнен на основе методологии Prisma. Была проанализирована 221 статья.

Обсуждение. Результат систематического обзора представляет собой анализ представленных методов построения моделей, какие чаще всего используются, и с помощью каких метрик исследователи оценивают качество полученной модели. Чаще всего применяются методы машинного обучения в сравнении с методами, основанными на знаниях (экспертными системами), 22 статьи и 7 статей соответственно. Анализируя использованные методы машинного обучения, можно отметить, что первые 5 мест среди применяемых в России методов занимают нейронные сети, регрессия, дерево решений, бустинг и случайный лес. Среди моделей представления знаний наиболее распространенными оказались онтология и семантические сети, которые часто применяются для структурирования и анализа сложных данных в различных областях знаний. Практически все исследователи в своих работах оценивали созданную модель на тестовой выборке и рассматривали численные метрики: accuracy (точность измерения), precision (точность средства измерения), полнота (recall), specificity (специфичность), sensitivity (чувствительность), AUC (площадь под ROC-кривой), F-measure (F-мера). Обсуждение представляет собой рассуждение об использовании различных метрик для оценки разных вариантов моделей.

Заключение. Обобщены итоги анализа работ, использующих ИИ для профилактики и диагностики ССЗ, дана оценка их дальнейшего применения.

Ключевые слова:	искусственный интеллект; машинное обучение; представление знаний; семантические сети; нейронные сети; сердечно-сосудистые заболевания.
Финансирование:	никто из авторов не имеет финансовой заинтересованности в представленных материалах или методах.
Для цитирования:	Ковелькова М.Н., Яковлева Е.Г. Системы искусственного интеллекта в профилактике и диагностике сердечно-сосудистой патологии в России (систематический обзор). <i>Сибирский журнал клинической и экспериментальной медицины</i> . 2025;40(1):28–41. https://doi.org/10.29001/2073-8552-2025-40-1-28-41 .

Artificial intelligence in the prevention and diagnosis of cardiovascular diseases in Russia (literature review)

Margarita N. Kovelkova, Ekaterina G. Iakovleva

2, Moskovskiy tract, Tomsk, 634050, Russian Federation N.I. Pirogov Russian National Research Medical University of the Ministry of Health of the Russian Federation (Pirogov Russian National Research Medical University),
1g, Ostrovityanova str., Moscow, 117997, Russian Federation

Abstract

Aim: To assess work carried out in Russia over the past 5 years to identify the risks of developing cardiovascular diseases using artificial intelligence (AI) methods and technologies.

Materials and methods: A systematic review of the available literature over the past 5 years on the use of machine learning and knowledge representation methods in predicting the development and outcomes of cardiovascular diseases in Russia was carried out based on the Prisma methodology. 221 articles were analyzed.

Results and discussion: The result of the systematic review is an analysis of the presented methods of model building, which ones are most often used, and with the help of which metrics researchers evaluate the quality of the obtained model. Machine learning methods are used most frequently compared to knowledge-based methods (expert systems), 22 articles and 7 articles respectively. Analysing the machine learning methods used, it can be noted that the first 5 places among the methods used in Russia are occupied by neural networks, regression, decision tree, boosting and random forest. Among the models of knowledge representation, ontology and semantic networks, which are often used for structuring and analyzing complex data in various knowledge domains, turned out to be the most widespread in the presented works. Almost all researchers in their papers evaluated the created model on a test sample and considered numerical metrics: accuracy (accuracy of measurement), precision (accuracy of the measuring instrument), completeness (recall), specificity (specificity), sensitivity (sensitivity), AUC (area under the ROC curve), F-measure (F-measure). The discussion is a discourse on the use of different metrics to evaluate different model variants.

Conclusion: The results of the analysis of works using AI for the prevention and diagnosis of cardio-vascular diseases are summarized, and an assessment of their further application is given.

Keywords:	artificial intelligence; machine learning; knowledge representation; semantic networks; neural networks; cardiovascular diseases.
Funding:	none of the authors have a financial interest in the materials or methods presented.
For citation:	Kovelkova M.N., Iakovleva E.G. Artificial intelligence in the prevention and diagnosis of cardiovascular diseases in Russia (literature review). <i>Siberian Journal of Clinical and Experimental Medicine</i> . 2025;40(1):28–41. https://doi.org/10.29001/2073-8552-2025-40-1-28-41 .

Введение

Из года в год хронические неинфекционные заболевания (ХНИЗ) являются основной причиной смертности. Согласно данным Всемирной организации здравоохранения, каждый год от неинфекционных заболеваний умирают 41 млн человек (что составляет 74% всех случаев смерти в мире). К ХНИЗ относят 4 основные группы заболеваний: сердечно-сосудистые заболевания (ССЗ) (такие как артериальная гипертензия (АГ), инфаркт (ИМ) и инсульт), онкологические заболевания, хронические респираторные болезни (такие как хроническая обструктивная болезнь легких (ХОБЛ) и астма) и сахарный диабет (СД).

Однако наибольшее число смертностей приходится на ССЗ, от которых каждый год умирают 17,9 млн человек. Далее следуют онкологические заболевания (9,3 млн случаев), хронические респираторные заболевания (4,1 млн) и СД (2,0 млн, включая обусловленные диабетом заболевания почек). Такие показатели являются причиной новых исследований в области диагностики ССЗ, их профилактики и оценки рисков возникновения болезни и смертности.

Факторами риска, способствующими развитию хронических неинфекционных сосудистых заболеваний, как правило, являются пол, возраст, высокий уровень артериального давления (АД) и холестерина в крови, психосоциальные факторы и факторы, связанные с образом жизни (курение, ожирение, низкий уровень физической активности, характер питания, СД). Ряд исследователей отмечают, что наличие АГ утяжеляет риск развития остальных ССЗ, что делает изучение АГ первоочередным. Для оценки возникновения фатальных и нефатальных исходов существуют такие шкалы, как SCORE1, SCORE2, SCORE2-OP (10-летний суммарный сердечно-сосудистый риск у здоровых лиц 40–69 лет, считающихся практически здоровыми, рассчитывается с помощью SCORE2, у лиц ≥ 70 лет – SCORE2-OP). Принципиальные отличия данных шкал от SCORE1 заключаются в оценке вероятности фатального сердечно-сосудистого события (ИМ или инсульт, или другая сердечно-сосудистая катастрофа) в 10-летней перспективе. SCORE2 и SCORE2-OP – это вероятность любого сердечно-сосудистого события, как смертельно-

го, так и не смертельного в течение того же времени¹. Однако данные шкалы можно использовать только для условно здоровых пациентов, у которых не выявлены ССЗ, нет СД, хронической болезни почек (ХБП).

Новый посыл к активному развитию профилактической направленности в ССЗ в России дала цифровизация². В 2017 г. в соответствии с посланием Президента Российской Федерации Федеральному Собранию была утверждена программа «Цифровая экономика Российской Федерации»³. В последней редакции программы среди основных сквозных цифровых технологий названы искусственный интеллект (ИИ) и технологии виртуальной и дополненной реальностей, активно развиваемые и внедряемые в здравоохранение. С января 2019 г. в России стартовал федеральный проект «Создание единого цифрового контура в здравоохранении на основе единой государственной информационной системы в сфере здравоохранения (ЕГИСЗ)»⁴.

Цифровизация здравоохранения России, включающая интеллектуальные системы поддержки принятия врачебных решений и рекомендательные системы, является мощным фактором для предиктивной медицины и повышения эффективности диагностического и лечебного процессов [1–4]. Опыт разработки и применения экспертных систем в медицине послужил важным этапом в развитии более сложных и эффективных интеллектуальных систем, используемых в современной цифровой медицине.

Цель обзора: проанализировать работы, проводимые в России за последние 5 лет, по выявлению рисков развития ССЗ с использованием методов и технологий ИИ.

Материал и методы

Искусственный интеллект – это направление исследований в современной компьютерной науке, целью которого является имитация и усиление интеллектуальной деятельности человека посредством компьютерных систем⁵. ИИ включает много направлений, но в данном обзоре остановимся на системах, основанных на знаниях и машинном обучении.

Систематический обзор доступной литературы за последние 5 лет по использованию методов машинного обучения и представления знаний в прогнозировании развития и исходов ССЗ в России был выполнен на основе методологии Prisma. Поиск источников проводился с использованием таких русскоязычных баз данных, как Российский индекс научного цитирования (РИНЦ), КиберЛенинка и Google Scholar (Академия Гугл) (рис. 1).

В исследование включались работы, использующие различные методы и технологии ИИ для обнаружения или оценки риска возникновения одного или нескольких ССЗ. Все найденные публикации были первоначально оценены по их заголовкам. На этом этапе отбирались

работы, содержащие в названии ключевые слова, относящиеся к теме исследования: искусственный интеллект, машинное обучение, семантические сети, сердечно-сосудистые заболевания, артериальная гипертензия, риск развития, представление знаний, онтология, экспертные системы, а также были удалены дубликаты.

Статьи, прошедшие первичный отбор, были проанализированы по их аннотациям (чья аннотация указывали на соответствие содержания целям нашего исследования). Далее оценивалось полнотекстовое содержание статей на предмет их релевантности теме исследования, качества методологии и соответствия критериям включения. Окончательное решение о включении статьи в обзор принималось на основе ее полного соответствия теме исследования, значимости представленных результатов и их потенциального вклада в достижение целей нашего обзора. Весь процесс отбора проводился независимо двумя исследователями. В случаях расхождения мнений, решение принималось путем обсуждения и достижения консенсуса, при необходимости с привлечением третьего исследователя.

Учитывая многогранность изучаемой темы, мы целенаправленно сузили фокус нашего систематического обзора до исследований, непосредственно связанных с антропометрическими, клиническими и лабораторными данными пациентов. Включение работ по анализу сигналов, хотя и представляющих научный интерес, значительно расширило бы масштаб исследования, что могло бы привести к размытию основных выводов и снижению практической применимости результатов обзора. Именно по этой причине исключались публикации, связанные с обработкой сигнала и изображения.

Также в рамках исследования были исключены обзоры статей и метаанализы. Данное решение было принято, поскольку основной целью работы являлся анализ первичных исследовательских данных. Включение обзорных статей, с одной стороны, могло внести уже имеющиеся мнения и интерпретации других авторов, а с другой, могло бы привести к повторному учету одних и тех же первичных исследований, что потенциально исказило бы общую картину работы.

Все работы, вошедшие в итоговый пул, можно разделить на 2 направления:

- работы, использовавшие методы машинного обучения (22);
- работы, использовавшие методы представления и использования знаний (7).

Исследования по применению машинного обучения для прогнозирования ССЗ за последние 5 лет в России

Машинное обучение (machine learning), технология извлечения знаний из данных для распознавания ситуаций и принятия решений, является в настоящее время одним из наиболее популярных направлений ИИ, приме-

¹ Рекомендации ESC по профилактике сердечно-сосудистых заболеваний в клинической практике, 2021. *Российский кардиологический журнал*. 2022;27(7):5155.

² Перечень поручений Президента России по реализации Послания Федеральному Собранию (№Пр-2346 от 5 декабря 2016 года) URL: <http://www.kremlin.ru/acts/assignments/orders/53425> (14.05.2024).

³ Распоряжение Правительства Российской Федерации от 28 июля 2017 года № 1632-р «Об утверждении программы «Цифровая экономика Российской Федерации» URL: <http://government.ru/docs/28653/> (15.05.2024).

⁴ Федеральный проект «Создание единого цифрового контура в здравоохранении на основе единой государственной информационной системы в сфере здравоохранения (ЕГИСЗ)». URL: <https://minzdrav.gov.ru/poleznye-resursy/natsproektzdravooohranenie/tsifra> Дата обращения: 16.05.2024.

⁵ Касави И.Т. и др. Энциклопедия эпистемологии и философии науки. М.: «Канон+» РООИ «Реабилитация», 2009:316.



Рис. 1. Дизайн исследования
Fig. 1. Study design

няемых для классификации и прогнозирования в медицине. Наиболее популярные алгоритмы, используемые в машинном обучении: линейная и логистическая регрессия, линейный дискриминантный анализ, деревья принятия решений, наивный Байесовский классификатор, к-ближайших соседей, метод опорных векторов, бэггинг и дерево решений, бустинг, нейросети.

В таблице 1 представлены все работы, основанные на применении методов машинного обучения, которые были проанализированы. Для детального анализа выбраны публикации с наиболее комплексным представлением данных и показателем эффективности, превышающим 84%. Далее приводится обзор этих отобранных исследований.

А.В. Гусев и соавт. построили модель прогнозирования развития ССЗ в течение 10 лет [5]. Для проведения исследования была создана база данных из 2 236 пациентов, имеющих и не имеющих ССЗ. Основными признаками пациентов, отраженными в базе, были пол, возраст, курение, уровень систолического и диастолического АД, общий холестерин, холестерин липопротеидов высокой плотности, СД, прием антигипертензивных препаратов и другие. Авторы использовали последовательную нейронную сеть с одним входным, двумя скрытыми и одним выходным слоем (платформа прогнозной аналитики Webiomed). Для предотвращения переобучения применено исключение («dropout»). На каждом слое используется функция «dense» для полного соединения слоев друг с другом, в скрытых слоях – функция активации «relu» [6]. В результате работы точность модели составила 78,8%, а площадь под ROC-кривой ошибкой (AUC) – 0,84.

Д.В. Гаврилов и соавт. создали модель предсказания сердечно-сосудистых событий при помощи комплексной

оценки факторов риска с применением методов машинного обучения [7]. В качестве данных для обучения модели были использованы данные Фрамингемского исследования (Framingham Heart Study, США) (4 363 пациента без ССЗ на момент обследования, из которых 852 умерли от ИМ и инсульта в течение 10 лет с момента начала наблюдения). У пациентов отмечались пол, возраст, систолическое АД, общий холестерин, курение/отсутствие курения, индекс массы тела (ИМТ) и частота сердечных сокращений (ЧСС).

Для построения модели использована последовательная нейронная сеть с одним входным, двумя скрытыми и одним выходным слоем. При построении учитывалась возможность переобучения и смещения веса. После тестирования модели на внешних данных точность метода составила 79,07%, а AUC – 0,86.

В.И. Горбаченко и соавт. разработали нейросетевую модель, позволившую диагностировать хроническую сердечную недостаточность (ХСН) на ранних этапах с точностью 98% [15]. Исходными данными для построения этой модели служили результаты тензиометрических исследований жидкой части крови (плазмы и сыворотки) здоровых людей и людей, страдающих ХСН, представленные в виде электронной таблицы. Всего было 132 записи, из них 65 с патологией, 67 – без патологии. На основе библиотеки `deep_tabular_augmentation` было дополнительно сгенерировано по 660 записей, соответствующих пациентам с патологией и без патологии. Эксперименты с нейронной сетью проводились с использованием библиотек TensorFlow и Keras, сеть обучалась алгоритмом Adam. Лучшие результаты получены для нейронной сети, состоящей из 3 слоев. Были получены следующие ре-

Таблица 1. Характеристики работ, основанные на методах машинного обучения

Table 1. Work characteristics based on machine learning methods

Авторы	Название и год выпуска	Метод	Предикторы и объем выборки	Лучший результат
Пушкин А.С., Шулькин Д., Борисова Л.В. и др [8].	Алгоритм стратификации риска развития инфаркта миокарда у пациентов с острым коронарным синдромом при первичном обследовании, 2020	Ансамблевый метод (бэггинг), искусственные нейронные сети	Возраст, пол, концентрация тропонина I, размер клетки, цитоплазматическая и ядерная сложность, лобулярность. Объем выборки: 307 пациентов (214 – обучающая, 93 – тестовая выборка)	Ансамбль из 6 нейронных сетей (AUC ROC: 0,77)
Белозерова Е.В., Данилов А.В., Исаенкова Е.А. и др. [9]	Прогнозирование развития гипертонической болезни с использованием моделей машинного обучения в подсистеме дистанционного кардиомониторинга, 2021	Логистическая регрессия, дерево решений	Пол, возраст, ИМТ, окружность талии, статус курения, употребление алкоголя, давление. Объем выборки: 395 записей	Логистическая регрессия (Accuracy: 96%)
Богданов Л.А., Комосский Е.А., Воронкова В.В. и др.[10]	Нейросетевые подходы к разработке прогностического модуля для оценки вероятности неблагоприятного сердечно-сосудистого исхода в общей популяции, 2022	Нейронные сети	Пол, возраст, АД, холестерин, курение, ИМТ, ЧСС. Объем выборки: 1525 субъектов	Нейронные сети (AUC: 0,88)
Болодурина И.П., Назаров А.М., Кича Д.И. и др.[11]	Разработка модели управления потоком пациентов с сердечно-сосудистыми заболеваниями методами интеллектуального анализа данных, 2020	Логистическая регрессия, алгоритм ID3, случайные леса	Возраст, пол, медицинская организация, код медицинской помощи, дата приема, длительность лечения, диагнозы (по МКБ), выявленные заболевания (атеросклероз, ишемия, гипертония, стенокардия, инфаркт миокарда). Объем выборки: Не указано	Логистическая регрессия (AUC: 0,8464)
Гаврилов Д.В., Серова Л.М., Корсаков И.Н. и др.[7]	Предсказание сердечно-сосудистых событий при помощи комплексной оценки факторов риска с использованием методов машинного обучения, 2022	Нейронные сети	Пол, возраст, АД, холестерин, курение, ИМТ, ЧСС. Объем выборки: 4363 пациента	Нейронные сети (AUC: 0,86)
Гельцер Б.И., Шахгельдян К.И., Назаров Д.А. и др.[12]	Методы машинного обучения в оценке рисков поражения органов-мишеней при «маскированной» артериальной гипертензии, 2020	Случайный лес, искусственные нейронные сети	Систолическое и диастолическое АД за день и ночь, скорость клубочковой фильтрации (СКФ), толщина интима-медиа (ТИМ), индекс массы миокарда левого желудочка (ИММЛЖ), индекс относительной толщины задней стенки левого желудочка (ИОТ ЗСЛЖ). Объем выборки: 284 пациента	Случайный лес (AUC ROC: 0,88, Specificity: 0,98)
Никонорова М.Л., Алдохина Ю.А., Пичугин Ю.А.[13]	Применение методов Data Mining для диагностики артериальной гипертензии в прикладной среде Rapid Miner, 2020	Data Mining, кластерный анализ, классификация, Decision Tree	Данные о пациентах с артериальной гипертензией, корреляционная матрица. Объем выборки: 49 параметров	Gradient Boosted Trees: точность 0,734–0,981, ROC AUC: 0,856–1,0
Голухова Е.З., Керен М.А., Завалихина Т.В. и др. [14]	Возможности методов машинного обучения для расчета персонального риска госпитальной смерти после коронарного шунтирования, 2022	Логистическая регрессия, случайный лес, CatBoost, LightGBM, XGBoost	Уровень креатинина и глюкозы, ФВ ЛЖ, возраст, поражение артерий. Объем выборки: 2182 пациента	CatBoost и LightGBM (ROC AUC: 0,666)
Горбаченко В.И., Потапов В.В., Зенин О.К. и др. [15]	Нейросетевая модель для ранней диагностики хронической сердечной недостаточности, 2021	Нейронные сети	Тензиометрические показатели плазмы и сыворотки крови. Объем выборки: 132 обучающих примера	Нейронные сети (AUC: 0,97)
Гусев А.В., Гаврилов Д.В., Корсаков И.Н. и др [5].	Перспективы использования методов машинного обучения для предсказания сердечно-сосудистых заболеваний, 2022	Нейронные сети	Пол, возраст, курение, АД, холестерин, ИМТ. Объем выборки: 2236 пациентов	Нейронные сети (AUC: 0,84)
Демченко М.В., Фирулина М.А., Каширина И.Л. [16]	Разработка медицинской информационной системы с элементами поддержки принятия решений в кардиологии, 2021	Градиентный бустинг, нейросетевая модель архитектуры MLP	Показатели состояния здоровья пациентов, данные о медицинских консультациях. Объем выборки: не указан	Модель прогнозирования инфаркта (AUC ROC: 0,858) Модель прогнозирования атеросклероза (AUC ROC: 0,89)

Продолжение таблицы 1.
Continuation of the table 1.

Авторы	Название и год выпуска	Метод	Предикторы и объем выборки	Лучший результат
Дружилов М.А., Кузнецова Т.Ю., Гаврилов Д.В., Гусев А.В. [17]	Верификация субклинического каротидного атеросклероза в рамках риск-стратификации при избыточном весе и ожирении, 2022	Случайный лес, AdaBoostClassifier («адаптивный бустинг»), KNeighborsClassifier («классификация с помощью алгоритма К-ближайшего соседа»)	Данные платформы Webiomed, УЗИ брахиоцефальных артерий. Объем выборки: не указан	Случайный лес (AUC: 0,97)
Каширина И.Л., Фириulina М.А., Бондаренко Ю.В. и др. [18]	Идентификация факторов риска смертности после инфаркта миокарда с использованием методов машинного обучения, 2021	Метод Каплана – Мейера, модель Кокса, логистическая регрессия, градиентный бустинг	Пол, возраст, АГ, ИМ, СД, ФП, острое нарушение мозгового кровообращения, ХОБЛ, ХСН, локализация ИМ, шкала KILLIP, тромболитическая терапия, чрескожные вмешательства. Объем выборки: 11457 случаев	CatBoost (AUC: 0,80)
Леонов Ю.А., Царева Г.В., Терехов М.В., Гришина В.В. [19]	Использование методов интеллектуального анализа данных для выявления ишемической болезни сердца, 2022	Нейронные сети, метод опорных векторов, деревья решений	76 атрибутов. Объем выборки: не указан	Дерево решений (Accuracy: 98,9%)
Макарихин А.В., Немков А.Г., Рейтблат О.М., Егоров Д.Б. [20]	Разработка прогностической модели наступления инфаркта миокарда на основе технологий машинного обучения, 2021	Градиентный бустинг, CatBoost, scikit-learn, eli5	47 признаков. Объем выборки: 7557 пациентов	CatBoost (Accuracy: 0,89)
Мишкин И.А., Сахаров А.А. [21]	Изучение использования алгоритмов машинного обучения в оценке риска развития сердечно-сосудистых заболеваний, 2020	Градиентный бустинг, случайный лес	Пол, возраст, ИМТ, ЧСС, систолическое АД, диастолическое АД, наследственность, курение, общий холестерин, глюкоза. Объем выборки: 800 пациентов	Градиент бустинга (фр без глюкозы и общего холестерина) (AUC: 0,851)
Невзорова В.А., Бродская Т.А., Шахгельдян К.И. и др. [22]	Методы машинного обучения в прогнозировании рисков 5-летней смертности (по данным исследования ЭССЕ-РФ в Приморском крае), 2022	Многофакторная логистическая регрессия, вейбулл-регрессия, стохастический градиентный бустинг	Возраст, пол, курение, систолическое АД, общий холестерин, СРБ, глюкоза, NT-proBNP, ЧСС. Объем выборки: 2131 человек	Многофакторная логистическая регрессия (AUC: 0,786)
Невзорова В.А., Плехова Н.Г., Присеко Л.Г. и др. [23]	Методы машинного обучения в прогнозировании исходов и рисков сердечно-сосудистых заболеваний у пациентов с артериальной гипертензией (по материалам ЭССЕ-РФ в Приморском крае), 2020	Нейросеть Keras	Пол, возраст, ИМТ, окружность талии, окружность бедер, систолическое АД, диастолическое АД, ПД, ЧСС, общий холестерин, ЛВП, ЛНП, триглицериды, ЛП(а), ApoA, ApoB, глюкоза, креатинин, мочевая кислота, Д-димер, СРБ. Объем выборки: 2131 человек	Нейросеть Keras (Чувствительность – 97,9%)
Овчаренко Е.А., Клышников К.Ю., Кутихин А.Г., Фролов А.В. [24]	Машинное обучение в задаче прогнозирования неблагоприятных сердечно-сосудистых событий у пациентов после коронарного шунтирования 2023	Логистическая регрессия, деревья решений, случайный лес, сверхслучайные деревья решений, градиентный бустинг, многослойные нейросети, метод К-средних соседей, ансамбль алгоритмов	59 факторов пред-, интра- и раннего послеоперационного периодов. Объем выборки: 152 пациента	Ансамбль алгоритмов (AUC: 0,77–0,91)
Плехова Н.Г., Невзорова В.А., Черненко И.Н. и др [25].	Прогнозирование исходов и рисков сердечно-сосудистых заболеваний с применением машинного обучения 2020	Нейронная сеть (многослойный перцептрон), Python, Keras	ИМТ, вес, обхват талии, обхват бедер, возраст, пол, средняя ЧСС, триглицериды, аполипопротеин-А, аполипопротеин-Б, липопротеин (а), тиреотропный гормон, инсулин, D-димер, глюкоза, холестерин, ЛПНП, ЛПВП, мочевая кислота, креатинин, С-реактивный белок, фибриноген, натрийуретический пептид. Объем выборки: 2000 человек (280 обучающая выборка, 187 тестовая выборка)	Нейронная сеть (точность: 97,9%)

Окончание таблицы 1.
End of the table 1.

Авторы	Название и год выпуска	Метод	Предикторы и объем выборки	Лучший результат
Рунова К.В., Юрин А.А.[26]	Классификация сердечно-сосудистых заболеваний с помощью инструментальных методов обработки информации на основе различных методов машинного обучения 2019	Метод главных компонент (PCA), анализ коррелированности переменных, классификационный анализ (Naive Bayes, Decision Tree, Random Forest, LDA)	Возраст, рост, пол, вес, систолическое АД, диастолическое АД, холестерин, глюкоза, курение, потребление алкоголя, физическая активность, наличие или отсутствие ССЗ. Объем выборки: 2000 пациентов	Random Forest (Accuracy: 72,55%)
Абдуалимов Т.П., Обрезан А.Г.[27]	Выявление поражения коронарных артерий при помощи алгоритмов глубокого обучения, 2021	Нейронная сеть, глубокое обучение	Клинические, лабораторные, инструментальные данные, ЭКГ-изображения. Объем выборки: 120 пациентов	Нейронная сеть (AUC: 0,74)

зультаты: точность RAC = 0,97, точность предсказания положительного исхода: для случая патологии RPR0 = 0,98, для случая отсутствия патологии RPR1 = 0,96, полнота SR0 = 0,96, для случая отсутствия патологии SR1 = 0,98; F1-score = 0,97, площадь под ROC-кривой AUC = 0,97. Таким образом, исследователи делают вывод, что применение нейронной сети позволяет с высокой точностью прогнозировать ХСН по результатам тензиометрии крови.

Цель исследования А.С. Пушкина и соавт. [8] заключалась в создании алгоритма стратификации риска развития ИМ на основе машинного обучения у пациентов с острым коронарным синдромом (ОКС) при первичном обследовании. Согласно доступной информации, было проведено проспективное пилотное исследование на базе сердечно-сосудистого центра СПб ГБУЗ «Городская многопрофильная больница № 2». Всего были обследованы 307 пациентов с ОКС (169 мужчин и 138 женщин). Исследователи изучали разные характеристики нейтрофилов, лимфоцитов и моноцитов: размер клетки, поляризованного бокового рассеяния и др. В исследовании в качестве метода машинного обучения применен ансамблевый метод – бэггинг (bootstrap aggregating). Ансамбль, состоящий из 6 нейронных сетей, продемонстрировал лучший результат (площадь под ROC-кривой = 0,77) на тестовой выборке.

Медицинская информационная система (МИС) с элементами поддержки принятия решений в кардиологии, основанная на методе машинного обучения, разработанная коллективом из Воронежского государственного университета [16], имеет в своем составе «модуль искусственного интеллекта», позволяющий, согласно предоставленным текущим показателям, рассчитать риск возникновения атеросклероза у пациента и риск ИМ. Для реализации расчета риска были построены соответствующие модели.

• Модель расчета риска развития ИМ [28]. Для анализа использовались обезличенные данные обо всех пациентах, поступивших в стационар больницы Воронежской области в 2015–2017 гг. с диагнозом: ИМ и выявленные случаи смерти (11 326 пациентов и 1 947 летальных исходов). Исследовались 15 признаков: пол, возраст, повторный ИМ, наличие СД, ХОБЛ, проходил ли пациент тромболитическую терапию и т. д. Для построения модели использовался метод машинного обучения – повышение градиента. Наилучшие результаты показала модель, построенная на основе метода балансировки TomekLinks

undersampling. Результатом работы модели является вероятностное значение риска смертности пациента от ИМ в течение 21 дня после перенесенного ИМ. Площадь под ROC-кривой предлагаемой модели составила 0,858.

• Модель расчета риска развития атеросклероза. Для анализа использовались обезличенные данные пациентов, предоставленные Воронежским кардиологическим диспансером. Количество обследуемых пациентов составило 522 (группа здоровых (8%) и группа с выявленным атеросклерозом (92%)) [29]. Основными маркерами атеросклероза были выбраны ArmsIndex – разница давления между правой и левой рукой; LegsIndex – разница давления между правой и левой ногами; и лодыжечно-плечевой индекс. Для построения модели было использовано 28 атрибутов из группы антропометрических, гемодинамических, лабораторных, социолого-демографических, клинических. В этом исследовании были применены следующие методы: случайный лес, классификатор дополнительных деревьев, повышение градиента и балансировка. Наибольшую AUC для пациентов с разницей давления между правой и левой рукой показал классификатор дополнительных деревьев (0,73), для пациентов с разницей давления между правой и левой ногами метод балансировки (0,71), для пациентов с измененным лодыжечно-плечевым индексом – также метод балансировки (0,89).

По мнению авторов, разработанная система представляет собой многофункциональный инструментальный с возможностью дистанционного мониторинга показателей состояния здоровья пациента и онлайн-диагностики.

А.В. Макарихин и соавт. описывают разработку прогностической модели [20]. Ими была сформирована выборка из данных 7 557 пациентов, накопленных в медицинской информационной системе Тюменской области. Авторы построили модель классификации с применением градиентного бустинга над решающими деревьями на базе свободно распространяемой библиотеки CatBoost. Для построенной модели оценивали точность (0,87), чувствительность (0,81), специфичность (0,81) и F1-меру (0,83).

И.А. Мишкин и А.А. Сахаров разработали алгоритмы оценки сердечно-сосудистого риска на основе алгоритмов машинного обучения – градиентного бустинга и случайного леса (Random forest) с целью совершенствования моделей прогноза хронических ССЗ [21]. В исследование было включено 800 записей медицинских карт амбулаторных и стационарных больных, собранных на

базах МКЦ ТулГУ и ГУЗ «ТГК БСМП им. Ваныкина» за период 2019–2020 гг. В первую группу вошли 208 пациентов, не имеющих ССЗ, во вторую группу – 594 пациента с диагностированными ССЗ атеросклеротического генеза и их осложнениями с возможными коморбидными состояниями. Были проанализированы следующие предикторы: пол, возраст, ИМТ, ЧСС, показатели систолического АД, показатели диастолического АД, данные об отягощенной наследственности по ССЗ у близких родственников, статус курения, показатели общего холестерина плазмы крови, показатели глюкозы плазмы крови. Для задачи бинарной классификации использовались градиентный бустинг (Gradient Boosting), основанный на ансамблировании моделей, из библиотеки Xgboost, а также случайный лес (Random forest) из библиотеки Sklearn, основанный на ансамблировании деревьев решений.

Наилучшие результаты показала модель, основанная на методе градиента бустинга, без учета общего холестерина крови и глюкозы ($AUC = 0,851$; $F1\text{-score} = 0,9$, среднеквадратичная ошибка составила 0,098, точность (precision) = 0,903; полнота (recall) = 0,903; специфичность составила 0,761). Из полученных результатов исследователи делают вывод, что градиентный бустинг в исследуемой популяции показал наилучший прогностический результат среди всех анализируемых методов прогноза ССЗ.

При анализе доступных работ в области машинного обучения можно выделить ряд исследований, прогнозирующих отдельно риск развития и/или утяжеления АГ. Е.В. Белозерова и соавт. описали прогнозирование развития АГ с использованием моделей машинного обучения в подсистеме дистанционного кардиомониторинга [9]. В исследование были включены данные 395 пациентов Воронежской городской клинической поликлиники № 1 в период с февраля по август 2020 г. У пациентов были описаны такие характеристики, как пол, возраст, окружность талии и бедер, курение алкоголь, прием фруктов/овощей и т. д. При разработке математических моделей прогнозирования развития АГ использовались методы построения логистической регрессии и методы формирования деревьев решений. Точность модели логистической регрессии составила 96%, а точность модели деревьев решений – 92,4%. Построенное дерево решений содержит ветви глубиной до 15 уровней с привлечением комбинации предикторов.

Авторская группа из НИИ КПССЗ (Кемерово) опубликовала работу по нейросетевым подходам к разработке прогностического модуля для оценки вероятности неблагоприятного сердечно-сосудистого исхода в общей популяции [10]. В данной работе использован массив данных 1 525 субъектов, полученный в результате международного многоцентрового проспективного исследования PURE (Prospective Urban Rural Epidemiology Study). Исследователи прогнозировали развитие АГ. У пациентов, участвующих в исследовании, учитывались следующие характеристики: пол, возраст, место проживания, сопутствующие заболевания, курение, прием лекарств, физиологические и биохимические параметры. В качестве машинного обучения была применена автоматизированная генерация нейронных сетей с использованием встроенного в программу STATISTICA скринингового модуля Automated Neural Networks (SANN) (с архитектурой многослойного перцептрона). Точность полученной нейронной сети в виртуальной диагностике АГ составила 84,5%, площадь

под ROC-кривой – 0,88 с приблизительно равными чувствительностью (83,6%) и специфичностью (85,3%).

Группой под руководством Б.И. Гельцера и К.И. Шагелдяна разработан целый ряд моделей для прогнозирования исходов у больных с ССЗ [12]. Так, например, авторы разработали модели прогнозирования рисков поражения органов-мишеней при различных фенотипах «маскированной» АГ (МАГ) на основе методов машинного обучения. В исследование были включены данные 284 пациентов (ретроспективное исследование историй болезней) в возрасте от 18 до 55 лет, находившихся на стационарном обследовании и лечении в ФГКУ «1477 Военно-морской клинический госпиталь» МО РФ в 2015–2018 гг.

У пациентов оценивались АД, отдельно систолическое АД, диастолическое АД, их вариабельность, учитывались возраст, относительный индекс массы миокарда левого желудочка и т. д. Были разработаны прогностические модели на основе методов случайный лес и искусственные нейронные сети. Для оценки точности моделей авторы использовали среднюю относительную ошибку аппроксимации (СООА), при уровне которой более 15% модели исключались из дальнейшего анализа, и множественный коэффициент детерминации. При использовании метода случайный лес множественный коэффициент детерминации составил от 0,53 до 0,76, а метода НС – от 0,21 до 0,42.

В.А. Невзорова и соавт. рассмотрели прогнозирование исходов и рисков ССЗ у пациентов с АГ [23]. В исследование были включены данные 2 800 человек, из них завершили программу обследования к 2019 г. 2 131 человек (76,1%). У пациентов оценивали следующие факторы риска: избыточная масса тела с вычислением ИМТ по формуле Кетле, окружность талии, уровни АД и пульсового давления, ЧСС, факт курения, гиподинамия; отягощение наследственности, лабораторные данные. При создании модели была построена и обучена нейронная сеть по алгоритму Adam (adaptive moment estimation, адаптивный момент оценки) с вычислением адаптивной скорости обучения для каждого параметра. Согласно опубликованным данным, чувствительность модели составила 97,9%.

Исследования, использующие системы, основанные на знаниях

Представление знаний и разработка систем, основанных на знаниях (knowledge-based systems), имеют большую историю, начало которой восходит к 70-м годам XX в. Рассмотрим некоторые системы последнего периода, связанные с проблемами предупреждения и развития болезней. Более полный список рассмотренных работ представлен в таблице 2.

В работах В.В. Грибовой и соавт. описаны разработки онтологий и семантические модели для медицины и демонстрация их на примере оценки рисков и прогноза ССЗ [30]. Для создания базы знаний авторы предлагают использовать семантические сети. Модель содержит информацию о заболевании/патологическом состоянии, риске болезни, авторе методики, исходных данных, условиях применимости, способе определения риска. К элементам модели также относятся факторы (пол, возраст пациента, заболевание и др.), признаки (лабораторные и инструментальные исследования), события (операции, контакты с пациентами и др.), прогноз. Для оценки риска осложнений используется специальный калькулятор, по-

Таблица 2. Характеристики работ, основанные на методах представления знаний
Table 2. Work characteristics based on knowledge representation methods

Автор	Название	Цель	Метод	Предикторы
Воробьев А.П., Воробьев П.А., Опарин И.С., Воробьев М.П.[32]	Выявление хронических неинфекционных заболеваний у пожилых больных с применением системы искусственного интеллекта MEDICASE, 2023	Цель исследования. Оценка эффективности системы выявления хронических неинфекционных заболеваний у пожилых пациентов с применением телемедицинских технологий	Телемедицинская система MeDiCase Алгоритм опроса представляет собой древо решений	Артериальное давление, уровень глюкозы, температура тела, насыщение кислородом, ЧСС
Грибова В.В., Гельцер Б.И., Шахгельдян К.И. и др. [33]	Гибридная технология оценки рисков и прогнозирования в кардиологии, 2022	Целью работы является разработка технологии гибридного искусственного интеллекта, объединяющего различные методы и подходы представления и использование знаний в явном (на основе онтологической модели знаний) и неявном виде (модели машинного обучения) для оценки и прогноза индивидуальных рисков развития сердечно-сосудистых событий	Облачная платформа IACPaaS, онтологический подход, многофакторная логистическая регрессия, искусственные нейронные сети	Возраст, пол, вес, рост, ИМТ, АД, ЧСС, уровень глюкозы, холестерин, курение, сопутствующие заболевания
Грибова В.В., Петряева М.В., Шалфеева Е.А.[34]	Облачный сервис поддержки принятия решений в кардиологии на основе формализованных знаний, 2020	Статья представляет сервис поддержки принятия диагностических решений в кардиологии. Описаны общие принципы разработки и концептуальная архитектура интеллектуального сервиса, его информационные и программные компоненты. Представлены возможности проведения диагностики и дифференциальной диагностики заболеваний сердца на медицинском портале облачной платформы IACPaaS	Облачная платформа IACPaaS, онтологический подход, семантическая сеть	Симптомы, лабораторные данные, инструментальные исследования, медицинские документы
Грибова В.В., Окунь Д.Б., Шалфеева Е.А.[30]	Семантические модели для оценки влияния комплекса факторов на развитие заболеваний, 2021	Целью данной работы является описание новой семантической модели и демонстрация её на примере оценки рисков и прогноза ССЗ	Семантическая модель, облачная платформа IACPaaS, онтологический подход	Симптомы, лабораторные данные, инструментальные исследования, медицинские документы
Григорьев О.Г., Кобринский Б.А., Благосклонов Н.А., Гинзбург Б.Г.[31]	Рекомендательная интеллектуальная система для управления рисками хронических заболеваний, 2023	Цель настоящего исследования – оценка персональных уровней риска развития хронических неинфекционных заболеваний (артериальная гипертензия, инфаркт миокарда, инсульт и депрессия) интеллектуальной РС для выдачи индивидуальных рекомендаций в отношении воздействия на управляемые факторы риска	Неоднородная семантическая сеть, алгоритм аргументационных рассуждений	Анкеты-опросники, данные из электронных медицинских карт, данные мобильных устройств
Ковелькова М.Н [35].	Интеллектуальная система для мониторинга риска артериальной гипертензии, 2022	Целью исследования являлось выявление и последующий мониторинг факторов риска развития артериальной гипертензии с формированием персональных рекомендаций по здоровьесбережению на основе использования проблемно ориентированной интеллектуальной системы	Извлечение знаний, концептуальные карты, семантическая сеть	Демографические характеристики, факторы образа жизни, лабораторные данные
Петряева М.В. [36]	Семантическое представление базы знаний о заболеваниях для сервиса поддержки принятия решений в кардиологии, 2022	Цель работы: сформировать базу знаний заболеваний сердечно-сосудистой системы для возможности диагностики и дифференциальной диагностики заболеваний сердца, используя облачный сервис поддержки принятия для кардиологии	Семантическая модель, облачная платформа IACPaaS	Данные из различных источников

звоняющий задавать вес (баллы) для отдельных признаков. По мнению авторов, семантические модели позволяют формировать разные типы знаний и интегрировать их в систему поддержки решения задач прогноза, оценки состояния и рисков неблагоприятных процессов.

Б.А. Кобринский и соавт. разработали интеллектуальную рекомендательную систему здоровьесбережения ИИ-ГИППОКРАТ. Цель исследования заключалась в оценке персональных уровней риска развития хронических неинфекционных заболеваний (АГ, ИМ, инсульт и депрессия) в интеллектуальной рекомендательной системе для выдачи персональных рекомендаций в отношении воздействия на управляемые факторы риска [31].

База знаний интеллектуальной рекомендательной системы реализована на основе неоднородной семантической сети. Решатель использует алгоритм аргументационных рассуждений, который позволяет подтвердить или отвергнуть гипотезу и уменьшить множество генерируемых гипотез. При построении модели учитывалось 267 факторов риска, которые включали как управляемые

факторы риска (масса, обхват талии, курение и др.), так и условно управляемые (поддающиеся медикаментозному контролю заболевания – СД и т. п.) и неуправляемые (на которые невозможно воздействовать, например, возраст и пол).

В исследовании были использованы анкетные данные 115 человек обоих полов (41 женщина и 74 мужчины) в возрасте от 20 до 91 года. Выборка была получена методом сплошного отбора. Сбор данных для апробации осуществлялся в период с 01.03.2022 по 30.09.2022 гг. включительно путем проведения открытого деперсонифицированного анкетирования на сайте <https://ai-hippocrates.ru/>.

Построенная модель предоставляет пользователю и наблюдающему его врачу оценки рисков развития АГ, ИМ, острого нарушения мозгового кровообращения и депрессии с учетом вклада каждого фактора риска [37]. На реальных данных системы ИИ-ГИППОКРАТ показана возможность оценки персональных уровней риска этих хронических заболеваний у лиц разного возраста на ос-

нове данных анкет-опросников даже при неполном их заполнении.

Обсуждение

Проанализировав полученные результаты в выбранных работах, можно отметить, что использование методов ИИ для прогнозирования риска развития ССЗ продемонстрировало целесообразность и эффективность их применения.

Чаще всего применяются методы машинного обучения в сравнении с методами, основанными на знаниях (экспертными системами), 22 статьи и 7 статей соответственно.

Анализируя использованные методы машинного обучения, можно отметить, что первые 5 мест среди применяемых в России методов занимают нейронные сети, регрессия, дерево решений, бустинг и случайный лес (рис. 2). Среди моделей представления знаний наиболее распространенными оказались онтология и семантические сети, которые часто применяются для структурирования и анализа сложных данных в различных областях знаний. Такое распределение отражает общемировые тенденции в области использования ИИ в медицине. Каждый из этих методов имеет свои преимущества и недостатки, что обуславливает их выбор для решения конкретных задач. Однако в разных работах применяется разное количество исходных данных и разные объемы контрольных выборок, что не позволяет однозначно трактовать сравниваемые исследования.

Авторские группы, имеющие доступ к электронным

медицинским картам, смогли получить для исследования большие объемы деперсонифицированных данных (до 7,5 тыс. пациентов), что могло повлиять на качество полученных результатов. По мнению А.В. Гусева и соавт., точность моделей постепенно улучшается с увеличением размера выборки, что указывает на свойство насыщения моделей по мере роста данных для обучения [38].

Следует также обратить внимание на необходимость валидации и верификации предлагаемых решений на данных из других выборок, в том числе получаемых из других медицинских организаций.

Практически все исследователи в своих работах оценивали созданную модель на тестовой выборке и рассматривали численные метрики (преимущественно для моделей, основанных на методах машинного обучения): ассигасу (точность измерения), precision (точность средства измерения), полнота (recall), specificity (специфичность), sensitivity (чувствительность), AUC (площадь под ROC-кривой), F-measure (F-мера). Однако в разных работах использовались разные метрики (рис. 3), что затрудняет сравнение созданных моделей между собой.

Чаще всего авторы оценивали качество полученных моделей с помощью расчета площади под ROC-кривой и в большинстве случаев она была выше 0,8. Такой выбор исследователей можно объяснить тем, что площадь под ROC-кривой (AUC-ROC) учитывает все возможные пороги классификации, давая более полную картину производительности модели. Эта метрика хорошо работает даже тогда, когда классы в наборе данных не сбалансированы, и, как следствие, особенно ценится в ситуациях, где кри-



Рис. 2. Методы машинного обучения, используемые при построении моделей
Fig. 2. Machine learning techniques used in model building



Рис. 3. Численные метрики, используемые при оценке качества моделей
Fig. 3. Calculated metrics used in assessment of the models quality

точно точно оценивать вероятность правильной или неправильной классификации, например, в медицине.

Представленные результаты показали хорошую прогностическую способность моделей, созданных разными методами, для выявления рисков при сердечно-сосудистой патологии.

Использование этих стандартных числовых метрик свидетельствует о том, что исследователи понимают важность тщательной оценки качества разработанных моделей машинного обучения на независимом тестовом наборе данных. Это критически важно для обеспечения надежности и точности моделей перед их внедрением в клиническую практику.

Заключение

ССЗ продолжают оставаться одними из самых часто встречающихся и угрожающих заболеваний в мире. В целях их предупреждения и борьбы с их последствиями постоянно разрабатываются новые методы для предсказания риска развития ССЗ и/или оценки рисков на разных этапах формирования патологии. В настоящее время в медицинских целях все чаще применяются различные методы и технологии ИИ. Современные интеллектуальные системы поддержки принятия решений могут быть интегрированы с электронными медицинскими картами, что отвечает магистральному пути цифровизации здравоохранения.

Анализ доступных работ по применению методов ИИ продемонстрировал возможности различных подходов в решении прогностических задач для социально значимых

ССЗ. Исследователи в своих работах используют различные методы машинного обучения, включая нейронные сети, регрессионный анализ, деревья решений, а также системы, основанные на знаниях. Многие разработанные модели показали высокую точность и эффективность в прогнозировании и диагностике ССЗ, что свидетельствует о значительном потенциале систем ИИ в улучшении качества медицинской помощи в этой области.

Для дальнейшего развития перспективным направлением является интеграция разработанных моделей в медицинские информационные системы и повседневную клиническую практику. Это может значительно помочь врачам при принятии решений, повысить точность диагностики и эффективность лечения.

В заключение стоит отметить, что широкое внедрение систем ИИ в кардиологии и других областях медицины может оказать значительное влияние на систему здравоохранения в целом. Потенциально это может привести к повышению эффективности диагностики (особенно на ранних этапах заболевания) и лечения, оптимизации использования ресурсов здравоохранения и, в конечном итоге, к улучшению качества жизни пациентов с ССЗ.

Благодарности

Авторы выражают особую благодарность доктору медицинских наук, профессору, заведующему отделом систем поддержки принятия клинических решений Федерального исследовательского центра «Информатика и управление» Российской академии наук Кобринскому Борису Аркадьевичу за оказанную помощь при написании настоящей статьи.

Литература / References

- Кобринский Б.А. Интеллектуальные рекомендательные системы для медицины: особенности и ограничения. Искусственный интеллект и принятие решений. 2022;3:51–62. Kobrinsky B.A. Intelligent Recommender Systems for Medicine: Peculiarities and Limitations. *Artificial intelligence and decision making*. 2022;3:51–62. (In Russ.). <https://doi.org/10.14357/20718594220304>.
- Кобринский Б.А. Системы искусственного интеллекта в медицинской практике: состояние и перспективы. *Вестник Росздравнадзора*. 2020;3:37–43. Kobrinsky B.A. Artificial intelligence systems in medical practice: state and prospects. *Vestnik Roszdravnadzor*. 2020;3:37–43. (In Russ.). <https://doi.org/10.35576/2070-7940-2020-3-37-43>.
- Acosta-García H., Ferrer-López I., Ruano-Ruiz J., Santos-Ramos B., Molina-López T. Computerized clinical decision support systems for prescribing in primary care: main characteristics and implementation impact – protocol of an evidence and gap map. *Syst. Rev*. 2022;11(1):283. <https://doi.org/10.1186/s13643-022-02161-6>.
- Alowais S.A., Alghamdi S.S., Alsuehaby N., Alqahtani T., Alshaya A.I., Almohareb S.N. et al. Revolutionizing healthcare: the role of artificial intelligence in clinical practice. *BMC Med. Educ*. 2023;23:689. <https://doi.org/10.1186/s12909-023-04698-z>.
- Гусев А.В., Гаврилов Д.В., Корсаков И.Н., Серова Л.М., Новицкий Р.Э., Кузнецова Т.Ю. Перспективы использования методов машинного обучения для предсказания сердечно-сосудистых заболеваний. *Врач и информационные технологии*. 2019;3:41–47. Gusev A.V., Gavrilov D.V., Korsakov I.N., Serova L.M., Novitsky R.E., Kuznetsova T.Y. Prospects for the use of machine learning methods for predicting cardiovascular disease. *Medical doctor and IT*. 2019;3:41–47 (In Russ.). URL: [https://www.vit-j.ru/upload/iblock/14f/gfw1lvkmrgssdx-fjcm9c56pdx1h0460/vit_2019_03_05.pdf\(07.08.2024\)](https://www.vit-j.ru/upload/iblock/14f/gfw1lvkmrgssdx-fjcm9c56pdx1h0460/vit_2019_03_05.pdf(07.08.2024)).
- Гусев А.В., Корсаков И.Н., Гаврилов Д.В., Серова Л.М., Новицкий Р.Э., Кузнецова Т.Ю. и др. WEBIOMED. Модель прогнозирования развития сердечно-сосудистых заболеваний в течение 10 лет. Gusev A.V., Korsakov I.N., Gavrilov D.V., Serova L.M., Novitsky R.E., Kuznetsova T.Yu. et al. WEBIOMED. Model for predicting the development of cardiovascular diseases within 10 years. URL: [https://webiomed.ru/media/predict_models_pdf_path/WML.CVD.FRS_Passport_GCJRncw.pdf\(08.08.2024\)](https://webiomed.ru/media/predict_models_pdf_path/WML.CVD.FRS_Passport_GCJRncw.pdf(08.08.2024)).
- Гаврилов Д.В., Серова Л.М., Корсаков И.Н., Гусев А.В., Новицкий Р.Э., Кузнецова Т.Ю. и др. Предсказание сердечно-сосудистых событий при помощи комплексной оценки факторов риска с использованием методов машинного обучения. *Врач*. 2020;31(5):41–46. <https://doi.org/10.29296/25877305-2020-05-08> Gavrilov D.V., Serova L.M., Korsakov I.N., Gusev A.V., Novitsky R.E., Kuznetsova T.Yu. et al. Cardiovascular diseases prediction by integrated risk factors assessment by means of machine learning. *Vrach*. 2020;31(5):41–46. (In Russ.). <https://doi.org/10.29296/25877305-2020-05-08>.
- Пушкин А.С., Шулькин Д., Борисова Л.В., Ахмедов Т.А., Рукавишников С.А. Алгоритм стратификации риска развития инфаркта миокарда у пациентов с острым коронарным при первичном обследовании. *Клиническая лабораторная диагностика*. 2020;65(6):394–400. Pushkin A.S., Shulkin D., Borisova L.V., Akhmedov T.A., Rukavishnikova S.A. Algorithm to stratify the risk of myocardial infarction in patients with acute coronary syndrome at primary examination. *Klinicheskaya Laboratornaya Diagnostika (Russian Clinical Laboratory Diagnostics)*. 2020;65(6):394–400. (In Russ.). <http://dx.doi.org/10.18821/0869-2084-2020-65-6-394-400>.
- Белозерова Е.В., Данилов А.В., Исаенкова Е.А., Калинина Л.Б., Манерова О.А., Усов Ю.И. Прогнозирование развития гипертонической болезни с использованием моделей машинного обучения в подсистеме дистанционного кардиомониторинга. *Менеджер здравоохранения*. 2022;2:76–84. <https://doi.org/10.21045/1811-0185-2022-2-76-84> Belozeroval E.V., Danilov A.V., Isaenkov E.A., Kalinina L.B., Manerova O.A., Usov Y.I. Prediction of hypertensive disease development using machine learning models in the subsystem of remote cardiac monitoring. *Health Care Manager*. 2022;2:76–84. (In Russ.). <https://doi.org/10.21045/1811-0185-2022-2-76-84>.
- Богданов Л.А., Комосский Е.А., Воронкова В.В., Толстошеев Д.Е., Марценюк Г.В., Агиенко А.С. и др. Нейросетевые подходы к разработке прогностического модуля для оценки вероятности неблагоприятного сердечно-сосудистого исхода в общей популяции. *Фундаментальная и клиническая медицина*. 2021;6(4):67–81. <https://doi.org/10.23946/2500-0764-2021-6-4-67-81> Bogdanov L.A., Komosky E.A., Voronkova V.V., Tolstosheev D.E., Marcenjuk G.V., Agienko A.S. et al. Nейросетевые подходы к разработке прогностического модуля для оценки вероятности неблагоприятного сердечно-сосудистого исхода в общей популяции. *Fundamental and Clinical Medicine*. 2021;6(4):67–81. (In Russ.). <https://doi.org/10.23946/2500-0764-2021-6-4-67-81>.
- Болодурин И.П., Назаров А.М., Кича Д.И., Забродина Л.С., Жигалов А.Ю. Разработка модели управления потоком пациентов с сердечно-сосудистыми заболеваниями методами интеллектуального анализа данных. *Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника»*. 2020;20(2):105–115. <https://doi.org/10.14529/ctcr200210> Bolodurina I.P., Nazarov A.M., Kicha D.I., Zabrodina L.S., Zhigalov A.Yu. Development of a Model for Control the Flow of Patients with Cardiovascular Diseases Using Data Mining Methods. *Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics*. 2020;20(2):105–115. (In Russ.). <https://doi.org/10.14529/ctcr200210>.
- Гельцер Б.И., Шахгельдян К.И., Назаров Д.А., Ветрова О.О., Котельников В.Н., Карпов Р.С. Методы машинного обучения в оценке рисков поражения органов-мишеней при «маскированной» артериальной гипертензии. *Кардиология*. 2020;60(5):107–114. <https://doi.org/10.18087/cardio.2020.5.n883> Geltser B.I., Shakhgelyan K.I., Nazarov D.A., Vetrova O.O., Kotelnikov V.N., Karpov R.S. Machine learning methods in assessing the risks of target organ damage in masked hypertension. *Kardiologiya*. 2020;60(5):107–114. (In Russ.). <https://doi.org/10.18087/cardio.2020.5.n883>.
- Никанорова М.Л., Алдохина Ю.А., Пичугин Ю.А. Применение методов Data Mining для диагностики артериальной гипертензии в прикладной среде Rapid Miner. *Региональная информатика (ПИ-2020)*. 2020;2:131–133. Nikanorova M.L., Aldokhina Yu.A., Pichugin Yu.A. Application of Data Mining Methods for the Diagnosis of Arterial Hypertension in Rapid Miner. *Regional Informatics (RI-2020)*. 2020;2:131–133. (In Russ.).
- Голухова Е.З., Керен М.А., Завалихина Т.В., Булаева Н.И., Акатов Д.С., Сигаев И.Ю. и др. Возможности методов машинного обучения в стратификации операционного риска у больных ишемической болезнью сердца, направляемых на коронарное шунтирование. *Российский кардиологический журнал*. 2023;28(2):5211. <https://doi.org/10.15829/1560-4071-2023-5211> Golukhova E.Z., Keren M.A., Zavalikhina T.V., Bulaeva N.I., Akatov D.S., Sigayev I.Yu. et al. Potential of machine learning methods in operational risk stratification in patients with coronary artery disease scheduled for coronary bypass surgery. *Russian Journal of Cardiology*. 2023;28(2):5211. (In Russ.). <https://doi.org/10.15829/1560-4071-2023-5211>.
- Горбаченко В.И., Потапов В.В., Зенин О.К., Милтых И.С., Грибков Д.Н. Нейросетевая модель для ранней диагностики хронической сердечной недостаточности. *Искусственный интеллект и принятие решений*. 2021;3:88–97. Gorbachenko V.I., Potapov V.V., Zenin O.K., Milytykh I.S., Gribkov D.N. Neural Network Model for Early Diagnosis of Chronic Heart Failure. *Artificial Intelligence and Decision Making*. 2021;3:88–97. (In Russ.). <https://doi.org/10.14357/20718594220309>.
- Демченко М.В., Фирюлина М.А., Каширина И.Л. Разработка медицинской информационной системы с элементами поддержки принятия решений в кардиологии. *Международный научно-исследовательский журнал*. 2021;(8(110)):69–76. <https://doi.org/10.23670/IRJ.2021.110.8.010> Demchenko M.V., Firyulina M.A., Kashirina I.L. Development of a health information system with decision support elements in cardiology. *International Research Journal*. 2021;(8(110)):69–76. (In Russ.). <https://doi.org/10.23670/IRJ.2021.110.8.010>.
- Дружилов М.А., Кузнецова Т.Ю., Гаврилов Д.В., Гусев А.В. Верификация субклинического каротидного атеросклероза в рамках риск-стратификации при избыточном весе и ожирении: роль методов машинного обучения в формировании диагностического алгоритма. *Кардиоваскулярная терапия и профилактика*. 2022;21(7):3222. <https://doi.org/10.15829/1728-8800-2022-3222> Druzhilov M.A., Kuznetsova T.Yu., Gavrilov D.V., Gusev A.V. Verification of subclinical carotid atherosclerosis as part of risk stratification in overweight and obesity: the role of machine learning in the development of a diagnostic algorithm. *Cardiovascular Therapy and Prevention*. 2022;21(7):3222. (In Russ.). <https://doi.org/10.15829/1728-8800-2022-3222>.
- Каширина И.Л., Фирюлина М.А., Бондаренко Ю.В., Десятиркова Е.Н., Ефимова О.Е., Чернышова Л.В. Идентификация факторов риска смертности после инфаркта миокарда с использованием методов машинного обучения. *Сборник докладов*

- XXIV Международной конференции по мягким вычислениям и измерениям. 2021:316–320.
- Kashirina I.L., Firyulina M.A., Bondarenko Yu.V., Desyatirikova E.N., Efimova O.E., Chernenkaya L.V. Identification of risk factors for mortality after myocardial infarction using machine learning methods. *Proceedings of the XXIV International Conference on Soft Computing and Measurements*, 2021:316–320. (In Russ.).
19. Леонов Ю.А., Царева Г.В., Терехов М.В., Гришина В.В. Использование методов интеллектуального анализа данных для выявления ишемической болезни сердца. Системный анализ, управление и обработка информации Известия Тульского государственного университета. *Технические науки*. 2022;7:171–178. <https://doi.org/10.24412/2071-6168-2022-7-171-179>
 - Leonov Yu.A., Tsareva G.V., Terekhov M.V., Grishina V.V. Application of Data Mining Methods for Identifying Coronary Heart Disease. System analysis, management and information processing Bulletin of Tula State University. *Technical Sciences*. 2022;7:171–178. (In Russ.). <https://doi.org/10.24412/2071-6168-2022-7-171-179>
 20. Макарихин А.В., Немков А.Г., Рейтблат О.М., Егоров Д.Б. Разработка прогностической модели наступления инфаркта миокарда на основе технологий машинного обучения. *Вестник новых медицинских технологий*. 2021;28(4):103–106. <https://doi.org/10.24412/1609-2163-2021-4-103-106>
 - Makarikhin A.V., Nemkov A.G., Reitblat O.M., Egorov D.B. Development of a predictive model of myocardial infarction based on machine learning technologies. *Journal of new medical technologies*. 2021;28(4):103–106. (In Russ.). <https://doi.org/10.24412/1609-2163-2021-4-103-106>
 21. Мишкин И.А., Сахаров А.А. Изучение использования алгоритмов машинного обучения в оценке риска развития сердечно-сосудистых заболеваний. *Кардиология*. 2021;60(7):15–24. <https://doi.org/10.14357/20718594220702>
 - Mishkin I.A., Sakharov A.A. Study of the use of machine learning algorithms in assessing the risk of cardiovascular disease. *Cardiology*. 2021;60(7):15–24. (In Russ.). <https://doi.org/10.14357/20718594220702>
 22. Невзорова В.А., Бродская Т.А., Шахгельдян К.И., Гельцер Б.И., Костерин В.В., Присеко Л.Г. Методы машинного обучения в прогнозировании рисков 5-летней смертности (по данным исследования ЭССЕ-РФ в Приморском крае). *Кардиоваскулярная терапия и профилактика*. 2022;21(1): 34–42. <https://doi.org/10.15829/1728-8800-2022-2908>
 - Nevzorova V.A., Brodskaya T.A., Shakhgelyan K.I., Geltser B.I., Kosterin V.V., Priseko L.G. Machine learning for predicting 5-year mortality risks: data from the ESSE-RF study in Primorsky Krai. *Cardiovascular Therapy and Prevention*. 2022;21(1):2908. (In Russ.). <https://doi.org/10.15829/1728-8800-2022-2908>
 23. Невзорова В.А., Плехова Н.Г., Присеко Л.Г., Черненко И.Н., Богданов Д.Ю., Мокшина М.В. и др. Методы машинного обучения в прогнозировании исходов и рисков сердечно-сосудистых заболеваний у пациентов с артериальной гипертензией (по материалам ЭССЕ-РФ в Приморском крае). *Российский кардиологический журнал*. 2020;25(3):10–16. <https://doi.org/10.15829/1560-4071-2020-3-3751>
 - Nevzorova V.A., Plekhova N.G., Priseko L.G., Chernenko I.N., Bogdanov D.Y., Mokshina M.V. et al. Machine learning for predicting the outcomes and risks of cardiovascular diseases in patients with hypertension: results of ESSE-RF in the Primorsky Krai. *Russian Journal of Cardiology*. 2020;25(3):10–16. (In Russ.). <https://doi.org/10.15829/1560-4071-2020-3-3751>
 24. Овчаренко Е.А., Клышников К.Ю., Кутихин А.Г., Фролов А.В. Машинное обучение в задаче прогнозирования неблагоприятных сердечно-сосудистых событий у пациентов после коронарного шунтирования. Клиническая и экспериментальная хирургия. *Журнал имени академика Б.В. Петровского*. 2023,11(3):16–28. <https://doi.org/10.33029/2308-1198-2023-11-3-16-28>
 - Ovcharenko E.A., Klyshnikov K.Yu., Kutikhin A.G., Frolov A.V. Machine learning in the problem of adverse cardiovascular events prognosis in patients after coronary artery bypass surgery. *Clinical and Experimental Surgery. Petrovsky Journal*. 2023,11(3):16–28. (In Russ.). <https://doi.org/10.33029/2308-1198-2023-11-3-16-28>
 25. Плехова Н.Г., Невзорова В.А., Черненко И.Н., Присеко Л.Г., Степанюгина А.К. Прогнозирование исходов и рисков сердечно-сосудистых заболеваний с применением машинного обучения. Сборник XXIV Международной конференции по мягким вычислениям и измерениям. 2020:305–309. EDN: PINICI
 - Plekova N.G., Nevzorova V.A., Chernenko I.N., Priseko L.G., Stepanyugina A.K. Predicting the outcomes and risks of cardiovascular diseases using machine learning. *Proceedings of the XXIV International Conference on Soft Computing and Measurements*. 2020:305–309. (In Russ.). EDN: PINICI
 26. Рунова К.В., Юрин А.А. Классификация сердечно-сосудистых заболеваний с помощью инструментальных методов обработки информации на основе различных методов машинного обучения. *Colloquium-journal*. 2019;13-3(37):115–120.
 - Runova K.V., Yurin A.A. Classification of cardiovascular diseases using instrumental information processing methods based on various machine learning methods. *Colloquium-journal*. 2019;13-3(37):115–120. (In Russ.).
 27. Абдуалимов Т.П., Обрезан А.Г. Выявление поражения коронарных артерий при помощи алгоритмов глубокого обучения. *Кардиология: новости, мнения, обучение*. 2021,9(2):9–13. <https://doi.org/10.33029/2309-1908-2021-9-2-9-13>
 - Abdualimov, T.P., Obrezan, A.G. Detection of coronary artery disease using deep learning algorithms. *Kardiologiya: novosti, mneniya, obucheniye*. [Cardiology: News, Opinions, Training]. 2021,9(2):9–13. (In Russ.). <https://doi.org/10.33029/2309-1908-2021-9-2-9-13>
 28. Kashirina I., Firyulina M. Building models for predicting mortality after myocardial infarction in conditions of unbalanced classes, including the influence of weather conditions. *CEUR Workshop Proceedings*. 2020;2790:188–197. URL: <https://ceur-ws.org/Vol-2790/paper18.pdf> (07.08.2024).
 29. Demchenko M.V., Kashirina I.L. The development of the atherosclerosis diagnostic models under conditions of unbalanced classes. *Journal of Physics Conference Series*. 2020;1479(1):012026. <https://doi.org/10.1088/1742-6596/1479/1/012026>
 30. Грибова В.В., Окунь Д.Б., Шалфеева Е.А. Семантические модели для оценки влияния комплекса факторов на развитие заболеваний. *Онтология проектирования*. 2021;11(4):464–477. <https://doi.org/10.18287/2223-9537-2021-11-4-464-477>
 - Gribova V.V., Okun D.B., Shalfeeva E.A. Semantic models for assessing the influence of complex factors on disease development. *Ontology of designing*. 2021;11(4):464–477. (In Russ.). <https://doi.org/10.18287/2223-9537-2021-11-4-464-477>
 31. Григорьев О.Г., Кобринский Б.А., Благодослов Н.А., Гинзбург Б.Г. Рекомендательная интеллектуальная система для управления рисками хронических заболеваний. *Информационные технологии и вычислительные системы*. 2023;2:27–37. <https://doi.org/10.14357/20718632230203>
 - Grigoriev O.G., Kobrinsky B.A., Blagosklonov N.A., Ginzburg B.G. Recommendation intelligent system for chronic disease risk management. *Information Technology and Computational Systems*. 2023;2:27–37. (In Russ.). <https://doi.org/10.14357/20718632230203>
 32. Воробьев А.П., Воробьев П.А., Опарин И.С., Воробьев М.П. Выявление хронических неинфекционных заболеваний у пожилых больных с применением системы искусственного интеллекта MED-ICASE. *Проблемы стандартизации в здравоохранении*. 2019;11–12:42–49. <https://doi.org/10.26347/1607-2502201911-12042-049>
 - Vorobiev A.P., Vorobyov P.A., Oparin I.S., Vorobyev M.P. Identification of chronic non-communicable diseases in elderly patients using the MED-ICASE AI system. *Health Care Standardization Problems*. 2019;11–12:42–49. (In Russ.). <https://doi.org/10.26347/1607-2502201911-12042-049>
 33. Грибова В.В., Гельцер Б.И., Шахгельдян К.И., Петряева М.В., Шалфеева Е.А., Костерин В.В. Гибридная технология оценки рисков и прогнозирования в кардиологии. *Врач и информационные технологии*. 2022,3:24–35. https://doi.org/10.25881/18110193_2022_3_24
 - Gribova V.V., Geltser B.I., Shakhgelyan K.I., Petryaeva M.V., Shalfeeva E.A., Kosterin V.V. Hybrid technology of risk assessment and prognosis in cardiology. *Medical doctor and information technology*. 2022,3:24–35. (In Russ.). https://doi.org/10.25881/18110193_2022_3_24
 34. Грибова В.В., Петряева М.В., Шалфеева Е.А. Облачный сервис поддержки принятия решений в кардиологии на основе формализованных знаний *Сибирский журнал клинической и экспериментальной медицины*, 2020, №35(4), 32–38. DOI: 10.29001/2073-8552-2020-35-4-32-38.
 - Gribova V.V., Petryaeva M.V., Shalfeeva E.A. Cloud Decision Support Service in Cardiology Based on Formalized Knowledge *Siberian Journal of Clinical and Experimental Medicine*, 2020; 35-4, 32-38. (In Russ.). DOI: 10.29001/2073-8552-2020-35-4-32-38.
 35. Ковелькова М.Н. Интеллектуальная система для мониторинга риска артериальной гипертензии. *Вестник новых медицинских технологий*. 2020,27(4):92–97. <https://doi.org/10.24411/1609-2163-2020-16720>
 - Kovelkova M.N. Intelligent system for monitoring the risk of hyperten-

- sion. *Journal of New Medical Technologies*. 2020;27(4):92–97. (In Russ.). <https://doi.org/10.24411/1609-2163-2020-16720>
36. Петряева М.В. Семантическое представление базы знаний о заболеваниях для сервиса поддержки принятия решений в кардиологии. *Материалы XIV международной научной конференции «Системный анализ в медицине» (SAM 2020)*; под общ. ред. В.П. Колосова; Благовещенск, 2020:78–81. Petryaeva M.V. Semantic representation of the knowledge base about diseases for decision support service in cardiology. *Proceedings of the XIV International Scientific Conference 'System Analysis in Medicine' (SAM 2020)*, ed. by V.P.Kolosov; Blagoveshchensk, 2020:78–81. (In Russ.). https://doi.org/10.12737/conferencearticle_5fe01d9be-1fc59.34271723
37. Кобринский Б.А., Кадыков А.С., Полтавская М.Г., Благодосклон Н.А., Ковелькова М.Н. Принципы функционирования интеллектуальной системы динамического контроля факторов риска и формирования рекомендаций по здоровьесбережению. *Профилактическая медицина*. 2019;22(5):78–84. <https://doi.org/10.17116/profmed20192205178>
38. Гусев А.В., Гаврилов Д.В., Новицкий Р.Э., Кузнецова Т.Ю., Бойцов С.А. Совершенствование возможностей оценки сердечно-сосудистого риска при помощи методов машинного обучения. *Российский кардиологический журнал*. 2021;26(12):4618. <https://doi.org/10.15829/1560-4071-2021-4618>
- Gusev A. V., Gavrilov D. V., Novitsky R. E., Kuznetsova T. Yu., Boytsov S. A. Improvement of cardiovascular risk assessment using machine learning methods. *Russian Journal of Cardiology*. 2021;26(12):4618. (In Russ.). <https://doi.org/10.15829/1560-4071-2021-4618>

Информация о вкладе авторов

Ковелькова М.Н. предложила идею исследования, разработала дизайн исследования, осуществила поиск источников в базах данных «Российский индекс научного цитирования (РИНЦ)» и «КиберЛенинка» с учетом ключевых слов и критериев, участвовала в создании итогового пула исследуемых работ.

Яковлева Е.Г. провела поиск источников в базе данных Google Scholar (Академия Гугл) и осуществила отбор научных работ по ключевым словам и критериям, участвовала в создании итогового пула исследуемых работ.

Ковелькова М.Н., Яковлева Е.Г. анализировали полученные результаты и давали им интерпретацию. Оба автора внесли существенный вклад в подготовку публикации, дали окончательное согласие на подачу рукописи и согласились нести ответственность за все аспекты работы, ручаясь за их точность и безупречность.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Information on author contributions

Kovelkova M.N. proposed the idea of the research, developed the research design, searched for sources in the databases of Russian Science Citation Index (RSCI) and Cyberleninka taking into account keywords and criteria, participated in the creation of the final pool of researched.

Yakovleva E.G. searched for sources in the Google Scholar database (Google Academy) and selected scientific papers on keywords and criteria, participated in the creation of the final pool of papers studies.

Kovelkova M.N. and Yakovleva E.G. analyzed the obtained results and interpreted them.

Both authors contributed substantially to the preparation of the publication, gave final consent to the submission of the manuscript and agreed to be responsible for all aspects of the work, vouching for their accuracy and flawlessness.

Conflict of interest: the authors do not declare a conflict of interest.

Сведения об авторах

Ковелькова Маргарита Николаевна, старший преподаватель, кафедра медицинской кибернетики и информатики имени С.А. Гаспаряна, МБФ, РНИМУ им. Н.И. Пирогова Минздрава России, Москва, Россия, <http://orcid.org/0000-0002-7442-6819>.

E-mail: kovelkova_mn@rsmu.ru.

Яковлева Екатерина Геннадиевна, канд. мед. наук, доцент, кафедра медицинской кибернетики и информатики имени С.А. Гаспаряна, МБФ, РНИМУ им. Н.И. Пирогова Минздрава России, Москва, Россия, <http://orcid.org/0009-0003-2114-7546>.

E-mail: k-iakov@mail.ru.

 **Ковелькова Маргарита Николаевна**,

e-mail: kovelkova_mn@rsmu.ru.

Information about the authors

Margarita N. Kovelkova, Senior Lecturer, Department of Medical Cybernetics and Informatics S.A. Gasparyan, MBF, Pirogov Russian National Research Medical University, Moscow, Russia, <http://orcid.org/0000-0002-7442-6819>.

E-mail: kovelkova_mn@rsmu.ru.

Ekaterina G. Yakovleva, Cand. Sci. (Med.), Associate Professor, Department of Medical Cybernetics and Informatics S.A. Gasparyan, MBF, Pirogov Russian National Research Medical University, Moscow, Russia, <http://orcid.org/0009-0003-2114-7546>.

E-mail: k-iakov@mail.ru.

 **Margarita N. Kovelkova**, e-mail: kovelkova_mn@rsmu.ru.

Received 31.05.2024;
review received 30.07.2024;
accepted for publication 04.12.2024.

Поступила 31.05.2024;
рецензия получена 30.07.2024;
принята к публикации 04.12.2024.