



УДК 616.1

DOI 10.17802/2306-1278-2023-12-3-109-125

ВОЗМОЖНОСТИ ПРИМЕНЕНИЯ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ В СФЕРЕ ПЕРВИЧНОЙ ПРОФИЛАКТИКИ СЕРДЕЧНО-СОСУДИСТЫХ ЗАБОЛЕВАНИЙ

В.С. Кавешников, Д.С. Брагин, В.Х. Ваизов, А.В. Кавешников, М.А. Кузьмичкина,
И.А. Трубачева

Научно-исследовательский институт кардиологии – филиал Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», ул. Киевская, 111А, Томск, Российская Федерация, 634012

Основные положения

• В обзоре проанализированы исследования, посвященные возможности использования методов машинного обучения для прогнозирования возникновения фибрилляции предсердий, кардиоваскулярных факторов риска, каротидного атеросклероза, суммарного сердечно-сосудистого риска. Значительные перспективы имеет сочетание методов машинного обучения с мобильными, облачными и телемедицинскими технологиями. В ближайшем будущем ожидается использование таких технологий для скрининга фибрилляции предсердий, а также стратификации риска с использованием данных кардиовизуализации. На основе методов машинного обучения развиваются мобильные профилактические технологии, направленные в частности на управление пищевым поведением.

Резюме

В статье рассмотрены основные направления применения технологий машинного обучения (МО) в сфере первичной профилактики сердечно-сосудистых заболеваний (ССЗ), показаны примеры решения с их помощью научных и практических задач. В настоящее время изучается возможность использования МО для прогнозирования суммарного сердечно-сосудистого риска, риска возникновения фибрилляции предсердий, факторов риска (ФР) ССЗ, каротидного атеросклероза и др. Кроме традиционных ФР в моделях МО применяются данные опросников, врачебного осмотра, лабораторных показателей, электрокардиографии, кардиовизуализации, сведения о принимаемом лечении, геномные и протеомные признаки. Обращает внимание разнообразие методов, применяемых при МО. Наиболее часто прибегают к таким классификаторам, как Random Forest, метод опорных векторов, искусственные нейронные сети. Многие алгоритмы МО демонстрируют прирост точности прогноза по отношению к действующим шкалам риска, но на текущий момент ни одна из методик однозначно не признана. На ранних стадиях развития находятся технологии глубокого МО. Мобильные, облачные и телемедицинские технологии открывают новые возможности для сбора, хранения и полезного применения медицинских данных и могут вывести профилактику ССЗ на новый уровень. В ближайшем будущем ожидается использование таких технологий для скрининга фибрилляции предсердий, а также стратификации сердечно-сосудистого риска с использованием данных кардиовизуализации, добавление которых к традиционным ФР позволяет получить наиболее стабильные оценки риска. Есть примеры использования мобильных технологий МО для управления ФР, в частности пищевым поведением. Авторы обращают внимание на такие аспекты, как недопустимость переоценки роли искусственного интеллекта в технологиях здравоохранения, предвзятость алгоритмов, кибербезопасность, этические вопросы сбора и использования медицинских данных. Практическая применимость моделей МО и их влияние на конечные точки на текущий момент изучены недостаточно. Значительным препятствием к внедрению технологий МО в сфере здравоохранения являются недостаточный опыт и отсутствие законодательной базы.

Ключевые слова

Машинное обучение • Искусственный интеллект • Первичная профилактика • Сердечно-сосудистый риск • Фибрилляция предсердий • Факторы риска • Предикторы

Поступила в редакцию: 06.07.2023; поступила после доработки: 10.08.2023; принята к печати: 22.08.2023

Для корреспонденции: Владимир Сергеевич Кавешников, kave@ngs.ru; адрес: ул. Киевская, 111А, Томск, Российская Федерация, 634012

Corresponding author: Vladimir S. Kaveshnikov, kave@ngs.ru; address: 111A, Kievskaya St., Tomsk, Russian Federation, 634012

POSSIBILITIES OF APPLYING MACHINE LEARNING TECHNOLOGIES IN THE SPHERE OF PRIMARY PREVENTION OF CARDIOVASCULAR DISEASES

V.S. Kaveshnikov, D.S. Bragin, V.Kh. Vaizov, A.V. Kaveshnikov, M.A. Kuzmichkina,
I.A. Trubacheva

Federal State Budgetary Scientific Institution "Tomsk National Research Medical Center of the Russian Academy of Sciences", 111A, Kievskaya St., Tomsk, Russian Federation, 634012

Highlights

- The review analyzes the studies devoted to the possibility of using machine learning methods to predict the occurrence of atrial fibrillation, cardiovascular risk factors, carotid atherosclerosis, and total cardiovascular risk. The combinations of machine learning methods with mobile, cloud and telemedicine technologies have significant prospects. In the near future, such technologies are expected to be used for atrial fibrillation screening and risk stratification using cardiac imaging data. Based on machine learning methods, mobile preventive technologies are being developed, particularly for nutritional behavior management.

Abstract

The article reviews the main directions of machine learning (ML) application in the primary prevention of cardiovascular diseases (CVD) and highlights examples of scientific and practical problems solved with its help. Currently, the possibility of using ML to predict cardiovascular risk, occurrence of atrial fibrillation (AF), cardiovascular risk factors, carotid atherosclerosis, etc. has been studied. The data of questionnaires, medical examination, laboratory indices, electrocardiography, cardio visualization, medications, genomics and proteomics are used in ML models. The most common classifiers are Random Forest, Support Vector, Neural Networks. As compared to traditional risk calculators many ML algorithms show improvement in prediction accuracy, but no evident leader has been defined yet. Deep ML technologies are at the very early stages of development. Mobile, cloud and telemedicine technologies open new possibilities for collection, storage and the use of medical data and can improve CVD prevention. In the near future, such technologies are expected to be used for atrial fibrillation screening as well as cardiovascular risk stratification using cardiac imaging data. Moreover, the addition of them to traditional risk factors provides the most stable risk estimates. There are examples of mobile ML technologies use to manage risk factors, particularly eating behavior. Attention is paid to such problems, as need to avoid overestimating the role of artificial intelligence in healthcare, algorithms' bias, cybersecurity, ethical issues of medical data collection and use. Practical applicability of ML models and their impact on endpoints are currently understudied. A significant obstacle to implementation of ML technologies in healthcare is the lack of experience and regulation.

Keywords

Machine learning • Artificial intelligence • Primary prevention • Cardiovascular risk • Atrial fibrillation • Risk factors • Predictors

Received: 06.07.2023; received in revised form: 10.08.2023; accepted: 22.08.2023

Список сокращений

АГ	– артериальная гипертензия	ССЗ	– сердечно-сосудистые заболевания
АД	– артериальное давление	ССР	– сердечно-сосудистый риск
ИИ	– искусственный интеллект	ФП	– фибрилляция предсердий
ИНС	– искусственная нейронная сеть	ФР	– факторы риска
МО	– машинное обучение	ЭКГ	– электрокардиография

Введение

В настоящее время сердечно-сосудистые заболевания (ССЗ) остаются одной из наиболее приоритетных проблем общественного здоровья в России и мире. Наряду с современными достижениями в диагностике и лечении ССЗ важнейшей задачей являются меры, направленные на предупреждение данной группы заболеваний на популяционном

уровне [1]. В крупных эпидемиологических исследованиях выявлены основные факторы риска (ФР) ССЗ: артериальная гипертензия (АГ), курение, гиперхолестеринемия, избыточная масса тела и сахарный диабет. Результаты данных исследований показали, что риск развития ССЗ увеличивается пропорционально количеству действующих ФР. Эти и другие факты позволили сформулировать

основные задачи первичной профилактики ССЗ – выявление и коррекция основных ФР в раннем периоде их возникновения, что дает возможность минимизировать подверженность данным факторам и снизить риск развития ССЗ.

В текущее десятилетие наблюдается стремительное развитие цифровых и телекоммуникационных технологий в медицине, в том числе технологий искусственного интеллекта (ИИ). Анализ литературы показывает, что разработка информационных систем на основе ИИ охватывает в настоящее время многие аспекты здравоохранения, включая профилактику, скрининг, диагностику и лечение заболеваний. Можно выделить две основные цели использования ИИ для решения клинических задач. Первая – это оптимизация работы человека путем автоматического обнаружения аномальных данных и помощи в диагностике. Отмечен стремительный рост объема поступающей биомедицинской информации, и ее обработка становится все более трудной задачей. Искусственный интеллект можно использовать для первичной интерпретации и сортировки биомедицинских данных, что влечет за собой улучшение эргономики, эффективности и рентабельности медицинской деятельности. С помощью ИИ возможна обработка больших массивов данных, поступающих с медицинских приборов, что может снизить нагрузку на врача и высвободить время на другие задачи. Вторая цель применения ИИ – диагностика и прогнозирование развития заболеваний, которые были невозможны ранее. Это более сложная задача, но она может открыть новую область медицины. Предполагается возможность эффективного использования ИИ для оказания специализированной медицинской помощи в условиях дефицита медицинских ресурсов. Такую возможность связывают с отсутствием пространственных и временных ограничений при использовании автоматизированной диагностики, что создает условия для бесперебойной работы медицинской службы [2].

Задачи, решаемые с помощью технологий ИИ, меняются по мере научно-технического прогресса. Во второй половине XX в. цель создания ИИ формулировалась как «разработка машинных алгоритмов для решения когнитивных задач, которые человек на текущий момент выполняет лучше» [3]. Большинство алгоритмов данного типа основано на наборе правил и инструкций, сформулированных человеком. Типичным примером такого подхода можно считать автоматическую интерпретацию электрокардиограммы (ЭКГ), давно применяемую в клинической практике. Для использования растущих объемов биомедицинской информации все чаще требуются специальные методы анализа больших данных [4]. В последние годы благодаря повышению производительности компьютеров наблюдается значительный прогресс в применении технологий машинного обучения (МО) во многих областях, в том числе в практическом здра-

воохранении и медицинских исследованиях [5]. Машинное обучение представляет собой крупный раздел технологий ИИ и характеризуется способностью автоматического обнаружения закономерностей в данных [6] без явных предварительных инструкций [4], а также способностью компьютерных алгоритмов самосовершенствоваться на основе опыта [7].

С момента появления компьютеров в середине XX в. сформировалось три основных направления МО: статистические методы, символьное обучение и искусственные нейронные сети (ИНС) [8]. По способу обучения методы МО принципиально делятся на два больших класса: при обучении «с учителем» алгоритм обучается путем сопоставления входных данных и эталонных образов, в то время как обучение «без учителя» происходит только на основании входных данных и внутренней логики алгоритма [3]. Обобщенно процесс МО состоит из четырех последовательных этапов. На первом этапе осуществляются предобработка и оптимизация входных данных. На втором этапе происходит обучение системы на обучающей выборке, цель которого состоит в выборе информативных признаков и создании модели на основе классификатора, выбранных признаков и прогнозируемых классов. Третий этап включает применение обученной модели на тестовом наборе данных, в ходе которого на основании значений выбранных признаков вычисляются прогнозируемые классы. Четвертый этап состоит из оценки эффективности МО, которая осуществляется путем сопоставления вычисленной и фактической информации [9].

Искусственные нейронные сети относятся к широкому классу гибких нелинейных регрессионных и дискриминантных моделей, моделей снижения размерности данных и нелинейных динамических систем. С помощью ИНС возможно создание высокоточных моделей прогнозирования на основе накопленных данных [4]. Использование ИНС способствует трансформации научных исследований и развитию совершенно новых областей знаний, таких как обработка естественного языка, распознавание объектов и прогнозная аналитика [6]. Есть примеры успешного использования ИНС для решения сложных научных проблем в области физических наук [4]. Продемонстрировано, что ИНС превосходят другие технологии МО во многих областях, особенно в анализе медицинских изображений [10]. Перспективной технологией является глубокое МО (deep learning) [8], в основе которой лежит использование ИНС со сложной архитектурой, позволяющей выявлять нелинейные взаимосвязи, сложные паттерны и образы, что успешно применяется в частности для анализа изображений [7].

Значительный интерес представляют возможности использования технологий ИИ в сфере первичной профилактики ССЗ. По данным литературы, в прошедшие 5–7 лет наблюдается значительный рост

интереса к таким технологиям в сфере профилактики и скрининга хронических заболеваний [2]. Целью данной работы является анализ литературы, освещающей возможности использования технологий МО в сфере первичной профилактики ССЗ. Поиск литературы проведен в реферативных базах данных eLibrary и PubMed. В системе eLibrary были сформированы поисковые запросы с использованием выражений: «искусственный интеллект», «машинное обучение», «нейронные сети» в сочетании с «профилактика» и «сердечно-сосудистые». Поиск осуществлен в заглавии, аннотации, ключевых словах журнальных статей и книг с учетом морфологии. В системе PubMed поисковый запрос основывался на поиске выражений “neural network” или “artificial intelligence” или “machine learning” в заглавии статей в сочетании с “cardiovascular prevention” в любой части библиографической записи. Было найдено 28 публикаций в eLibrary и 396 в PubMed, из которых отобрано 15 и 104 соответственно, в содержании которых непосредственно отражены рассматриваемые вопросы. Из них в свою очередь отобраны наиболее информативные работы с точки зрения целей, методов исследования, размерности данных, используемых технологий, полученных результатов. Ниже мы рассмотрим примеры использования технологий МО для решения различных задач первичной профилактики ССЗ, таких как стратификация риска, прогнозирование возникновения ФР ССЗ, субклинического атеросклероза и фибрилляции предсердий (ФП), управление ФР.

Стратификация сердечно-сосудистого риска

Необходимым шагом первичной профилактики ССЗ является определение суммарного сердечно-сосудистого риска (ССР). В современных руководствах по первичной профилактике настоятельно рекомендовано использовать с этой целью специально разработанные шкалы, в частности SCORE (Systemic Coronary Risk Evaluation) и FRS (Framingham Risk Score), позволяющие определять интенсивность лечебно-профилактических вмешательств в зависимости от величины риска [4]. В основе таких инструментов лежит возможность прогнозирования сердечно-сосудистых событий на относительно длительные периоды времени – десять лет или более. В нашей стране используется шкала SCORE, базовая версия которой основана на пяти показателях: возраст, пол, общий холестерин, систолическое артериальное давление (АД) и курение. Такой подход позволяет определить активность основных субклинических процессов, ведущих к развитию заболевания, и выделить ключевые факторы, коррекция которых (к примеру, путем отказа от курения, нормализации АД, терапии статинами) позволяет снизить риск до наиболее благоприятного уровня. Вместе с тем такой подход несет в себе

и ограничения. Известно, что большими ФР ССЗ объясняется лишь около 50% смертности от сердечно-сосудистых причин [11]. Даже с учетом неоспоримой практической пользы эффективность традиционных подходов к оценке ССР все чаще оказывается недостаточной по сравнению с быстро развивающимися технологиями ИИ [7, 9]. По данным показателя AUC (area under the curve – «площадь под кривой»), точность современных моделей риска составляет от 0,65 до 0,85 [4]. К их основным недостаткам относят неспособность учитывать нелинейный характер связи между ФР и прогнозируемыми событиями, непринятие в расчет информации о состоянии сосудов, использование произвольных критериев для градации риска и неспособность учитывать особенности популяции [9].

Много работ адресовано проблеме оптимизации прогнозирования ССР с помощью технологий МО. Одна из часто обсуждаемых идей состоит в том, что добавление к традиционным ФР достаточно широкого круга дополнительной информации, хранящейся в электронных историях болезни, может повысить эффективность прогнозирования риска [7]. Это особенно вероятно в тех случаях, когда инструмент разрабатывается для внедрения в конкретную медицинскую экосистему [7]. Интеграция ИИ в электронные системы первичного звена здравоохранения может облегчить выявление пациентов с высоким риском и способствовать развитию персонифицированной профилактики ССЗ [12].

В 2022 г. J. Suri и соавт. опубликовали данные систематического обзора 265 исследований, посвященных проблеме стратификации ССР с использованием технологий МО. Авторы пытались выявить архитектуру применяемых моделей, их сильные и слабые стороны, научную и клиническую применимость, риск необъективных прогнозных оценок. Как показало исследование, в настоящее время с помощью МО осуществляется моделирование градиента риска для событий как одного, так и нескольких типов. В качестве входной информации используются данные офисных измерений, лабораторных показателей, каротидной ультрасонографии, электрокардиографии, плетизмографии, акселерационной плетизмографии, стресс-тестов, а также коронарный кальций. Чаще всего применялись офисные и лабораторные показатели, данные кардиовизуализации и лекарственная терапия [9].

Подчеркивается важная роль мобильных, облачных и телемедицинских технологий. Архитектуры мобильных и облачных систем могут быть основаны как на МО, так и других принципах ИИ. Наиболее часто используемыми классификаторами, по данным исследования, были: метод ближайших соседей (k-nearest neighbor), опорных векторов (support vector machine), сверточные НС (convolutional neural network), алгоритмы Naïve Bayes и Random Forest,

«дерево решений» (decision tree). Нередко для построения прогнозных моделей применяется сочетание алгоритмов («ансамбль»). Оценка эффективности мобильных и облачных систем анализируется с помощью таких параметров, как чувствительность, специфичность, точность, критерий F1, статистическая значимость, шкала Зилберга, AUC. Для минимизации риска необъективных прогнозных оценок ключевое значение имеет оптимальный выбор вычисляемых классов. В целом авторы находят интеллектуальные методы оценки ССР успешными и связывают будущее с мобильными и облачными ИИ-технологиями. Сочетание изображений визуализирующих методов с традиционными ФР обеспечивает наибольшую стабильность при оценке ССР в необлачных и облачных интеллектуальных системах [9].

Остановимся на работах, демонстрирующих возможность применения ИИ для стратификации ССР. Е.В. Жданова и Е.В. Рубцова сообщают об интересном опыте внедрения интеллектуальной системы в работу участкового терапевта [13]. На основе данных 1 778 электронных амбулаторных карт с помощью методов МО система обучена выявлению ФР ССЗ с использованием входных данных, сформированных ранее при любом обращении человека в медицинское учреждение (профилактические и периодические медицинские осмотры, плановая диспансеризация, обращение к узким специалистам и т. д.). В результате система выявила дополнительные, ранее неучтенные ФР у 11,5% пациентов очень высокого и 12,7% лиц высокого ССР. Впервые высокий риск ССЗ обнаружен у 29 человек. Полученный опыт демонстрирует возможность практического применения интеллектуальных систем для дополнительного выявления среди населения групп высокого риска ССЗ в условиях реальной медицинской практики.

В.В. Грибова с коллегами обсуждают вопросы внедрения в систему здравоохранения технологии гибридного ИИ, разрабатываемой на основе облачной платформы IASPaas, позволяющей использовать информацию из различных источников и форматов для прогнозирования индивидуальных рисков развития ССЗ. Методы МО включают ИНС, Weibull-регрессию и логистическую регрессию. Результатом является гибридная технология оценки рисков, ключевая особенность которой заключается в ее масштабируемости за счет возможности подключения новых микросервисов. Система может применяться для решения научных и практических задач [14].

А.М. Алаа и соавт. разработали интеллектуальную систему прогнозирования ССР AutoPrognosis, в которой из множества алгоритмов автоматически выбираются оптимальные [15]. Исследованы данные 423 604 пациентов из UK Biobank, не имевших ССЗ на начало проспективного наблюдения. Использованы семь методов ввода пропущенных значений, девять алгоритмов отбора информативных признаков, 20

классификаторов. При применении тех же исходных данных, что и FRS, созданная модель демонстрировала более высокую способность к дискриминации ($AUC = 0,744$) по сравнению с FRS (0,724) и моделью пропорциональных рисков Кокса (0,734). Добавление 104 лабораторных и 369 прочих клинических признаков сопровождалось повышением AUC до 0,774 по сравнению с моделью Кокса с теми же переменными (0,758). Ведущими предикторами сердечно-сосудистых событий в полной модели были возраст, курение и привычный темп ходьбы.

S.F. Weng и соавт. исследовали возможность четырех различных алгоритмов МО (Random Forest, логистическая регрессия, Gradient Boosting Machine, ИНС) в прогнозировании 10-летнего инцидента сердечно-сосудистых событий и провели сравнение со шкалой риска ACC/АНА (Американская коллегия кардиологов/Американская ассоциация сердца) [16]. Основу исследования составили данные проспективного когортного наблюдения 378 256 пациентов семейной врачебной практики. Проанализированы стандартные клинические данные. Вычисляемым классом был ССР 7,5% (критерий начала приема статинов). Инцидент сердечно-сосудистых событий в течение 10 лет составил 6,6%. По сравнению со шкалой ACC/АНА ($AUC = 0,728$) алгоритмы МО были более точными: Random Forest +1,7%, логистическая регрессия +3,2%, Gradient Boosting Machine +3,3%, ИНС +3,6%. Прирост показателя корректной классификации методом ИНС составил 7,6%. Данные исследования указывают на то, что использование технологий МО значительно повышает точность вычисления ССР и увеличивает показатели корректной классификации. В результате применения технологии больше лиц могло бы получить пользу от профилактического вмешательства и избежать ненужного лечения.

М.В. Matheson с коллегами использовали алгоритм Random Survival Forest для выявления предикторов 6-летнего инцидента ССЗ среди 155 108 жителей Японии в возрасте >40 лет [17]. С использованием 20 наиболее информативных признаков исследуемый алгоритм продемонстрировал хорошую эффективность ($AUC > 82\%$). Наличие ССЗ в анамнезе, возраст, гипотензивная терапия, HbA1c, глюкоза крови натощак и липопротеиды высокой плотности были наиболее влиятельными предикторами.

М. Schrempf с соавт. разработали модели на основе МО для прогнозирования 5-летнего риска больших коронарных событий [18]. Анализировались данные электронных медицинских карт более 128 тыс. пациентов. В результате процедуры отбора получено 826 информативных признаков. Наилучшие характеристики на тестовом наборе данных показал алгоритм Random Forest с $AUC = 0,88$.

Группа авторов во главе с J.A. Quesada сравнили 15 моделей МО со шкалами SCORE и REGICOR в

отношении эффективности прогнозирования 5-летнего ССР, используя данные 38 527 участников испанской когорты ESCARVAL RISK [19]. Величина AUC при применении REGICOR и SCORE составила 0,63. По сравнению с ними семь методов МО показали более высокие прогностическую способность, чувствительность и специфичность. Наиболее эффективными оказались алгоритмы «квадратичный дискриминантный анализ» ($AUC = 0,7086$), Naive Bayes ($AUC = 0,7084$) и ИНС ($AUC = 0,7042$).

В рамках когортного исследования MESA (Multi-Ethnic Study of Atherosclerosis) I.A. Kakadiaris и соавт., используя данные 13-летнего наблюдения 6 459 респондентов и метод опорных векторов, разработали прогнозную модель, включающую те же входные данные, что и шкала ССР ACC/АНА. Созданная модель демонстрировала AUC 0,94 против 0,72 (ACC/АНА), при ее применении было бы назначено меньше статинов и пропущено меньше сердечно-сосудистых событий, чем при использовании калькулятора ACC/АНА [20].

К. Mehrabani-Zeinabad и коллеги разработали и сравнили классификационные модели для прогнозирования инцидента ССЗ на основе данных 16-летнего наблюдения 5 432 участников исследования Isfahan Cohort Study (Иран) [21]. Построение моделей осуществлялось на основе 385 переменных с использованием технологий Bayes additive regression trees, BARTm, «квадратичный дискриминантный анализ». Все классификаторы справились со своей задачей: основные различия между ними касались соотношения чувствительности и специфичности. Делается вывод о том, что прогностическая модель, разработанная на специфических данных отдельного региона, является ценным инструментом для скрининга и первичной профилактики ССЗ в данном конкретном регионе.

Д.В. Гаврилов и соавт. на основе данных 4 363 участников Фремингемского исследования и ИНС разработали и исследовали свойства прогнозной модели 10-летнего ССР WML.CVD.Score [22]. Входящие признаки включали пол, возраст, систолическое АД, холестерин, курение, индекс массы тела, частоту сердечных сокращений. Модель протестирована на внешнем наборе данных, включающем информацию о 411 представителях российской популяции. На тестовой выборке разработанная модель демонстрировала точность 79,07% и AUC 0,86 по сравнению с 0,81 для шкалы SCORE.

К. Tsarapatsani с коллегами использовали клинические ФР ССЗ и биохимические данные 2 943 респондентов для прогнозирования 10-летнего риска смерти от ССЗ с помощью моделей МО: логистическая регрессия, метод опорных векторов, Random Forest, Naive Bayes, Extreme Grading Boosting и AdaBoost [23]. Логистическая регрессия оказалась наиболее надежным алгоритмом – с точностью 72,2%.

Исследовательская группа под руководством В.А. Невзоровой разработала и изучила точность моделей прогнозирования 5-летнего ССР по данным исследования ЭССЕ-РФ. Использовались данные 2 131 респондента, социально-демографические, биометрические, лабораторные показатели. Применяемые алгоритмы включали логистическую и Weibull-регрессию, стохастический градиентный бустинг. При использовании возраста, пола, факта курения, систолического АД, уровня общего холестерина разработанные модели были более эффективными, чем SCORE. Включение в состав предикторов С-реактивного белка, глюкозы, NT-proBNP и частоты сердечных сокращений повышало точность прогноза методом логистической регрессии. Ведущими предикторами были возраст, общий холестерин, NT-proBNP, С-реактивный белок и глюкоза [24].

Использование для стратификации риска генетической информации может способствовать переходу к более эффективной диагностике и персонализированной профилактике. Исследования показывают, что ишемическая болезнь сердца имеет значительную наследственную обусловленность с полигенной архитектурой [25]. В настоящее время для прогнозирования инцидента ССЗ могут успешно применяться полигенные шкалы риска (Polygenic Risk Score, PRS). Ценную информацию можно получить также при анализе экспрессии генов и протеинов, серьезное влияние на которые оказывают окружающая среда и образ жизни человека. Значительные перспективы имеют «омиксные» технологии. Такие функциональные данные дополняют информацию о генотипе и позволяют более детально определить причинные гены заболевания [26].

J. Stainfeldt с группой авторов исследовали модель 10-летнего ССР NeuralCVD, разработанную на основе ИНС, полигенной и клинической информации [27]. Анализировались данные 395 713 лиц с ССЗ из когорты UK Biobank. Эффективность модели сравнивалась со шкалами SCORE, ASCVD, QRISK3 и моделью пропорционального риска Кокса. Полученная модель демонстрировала улучшение в отношении показателей дискриминации и классификации риска. Авторы делают вывод о возможности использования полученной модели для оценки траектории ССР в рамках первичной профилактики.

D. Gola с соавт. сравнили PRS, логистическую регрессию, метод опорных векторов, алгоритмы Naive Bayes, Random Forest и Gradient Boost в отношении эффективности прогнозирования статуса ишемической болезни сердца [25]. Проанализированы данные 7 736 случаев ишемической болезни сердца и 6 774 контрольных случаев. Выявлено, что более эффективно поставленные задачи осуществляла PRS ($AUC = 0,92$, 50 633 локуса) по сравнению с методом опорных векторов и алгоритмом Naive Bayes ($AUC \sim 0,81$), а также методами

Random Forest и Gradient Boost (AUC ~0,75). Авторы пришли к выводу, что на текущий момент по эффективности прогнозирования ишемической болезни сердца PRS превосходит методы МО.

J. Rigdon и S. Basu провели ретроспективное исследование, целью которого было определить, влияют ли крайне ограниченные сведения о питании населения на прогнозирование риска смертности от ССЗ [28]. Использованы данные опроса более 40 тыс. участников исследования NHANES, собранные с 1999 по 2011 г., алгоритмы Gradient Boosting Machines и Random Forest. Установлено, что стандартная модель Кокса без учета диетических факторов переоценивала риск смерти от ССЗ почти в два раза, тогда как исследуемые модели в сочетании с диетическими данными улучшали дискриминацию (AUC = 0,93 против 0,87).

Прогнозирование субклинического атеросклероза

Добавление информации о субклиническом атеросклерозе к существующим моделям ССР становится все более привлекательной идеей. На текущий момент не разработаны единые подходы к формированию целевой группы населения, в которой целенаправленно проводились бы такие обследования. Д.В. Гаврилов с коллегами при помощи методов МО разработали модель прогнозирования субклинического каротидного атеросклероза среди лиц с избыточным весом и ожирением. Для осуществления МО использована информация базы данных Webiomed, включающая в конечном варианте 447 записей, 28 информативных признаков. Применены алгоритмы МО Random Forest, AdaBoostClassifier и k-NN. Получена серия моделей с предсказательной способностью 75–97%, чувствительностью 77–92%, специфичностью 80–98%, AUC 0,88–0,97. Лучшие результаты показал алгоритм Random Forest (95, 92, 98% и 0,95, соответственно). Внедрение в практику таких алгоритмов может повысить качество прогнозирования ССР и оптимизировать систему профилактических мероприятий [29].

Группа авторов во главе с F. Sanchez-Cabo разработали модель, целью которой было прогнозирование наличия и степени субклинического атеросклероза среди лиц молодого возраста на основе рутинных, легко измеряемых параметров [30]. Использованы данные когортного исследования Progression of Early Subclinical Atherosclerosis, включавшие демографические данные, систолическое АД, общеклинические анализы крови, мочи, диетические факторы (всего 115 переменных). С помощью алгоритма Elastic Net был смоделирован композитный показатель субклинического атеросклероза, основанный на данных измерения коронарного кальция и двумерного ультразвукового исследования сонных артерий. Ведущими предикторами за-

болевания были возраст, HbA1C, отношение общего холестерина к липопротеидам высокой плотности, объем лейкоцитов и гемоглобин. Алгоритм помогает формировать целевую группу, в которой имеет смысл проведение визуализирующих исследований и лечебно-профилактических вмешательств.

J. Fan и соавт., используя данные 18 441 электронной медицинской записи, изучили эффективность различных технологии МО для прогнозирования субклинического каротидного атеросклероза. Применены рутинные клинические данные и алгоритмы: логистическая регрессия, Random Forest, «дерево решений», eXtreme Gradient Boosting, Naïve Bayes и K-Nearest Neighbour. Наибольшую эффективность показала модель логистической регрессии (чувствительность 53,2%, специфичность 86,6%) [31].

Прогнозирование возникновения кардиоваскулярных факторов риска

R. Poplin с коллегами на основе данных 284 335 пациентов и методов глубокого МО разработали модели, позволяющие прогнозировать наличие ФР и ССР по изображению сетчатки глаза. Получены относительно точные прогнозные оценки таких факторов, как возраст (с точностью до 3 лет), пол (AUC = 0,97), курение (AUC = 0,71), систолическое АД (с точностью до 11 мм рт. ст.), неблагоприятные сердечно-сосудистые события (AUC = 0,70). Замечено, что обученными моделями принимались в расчет изображения таких анатомических ориентиров, как диск зрительного нерва и кровеносные сосуды [32].

Артериальная гипертензия

На текущий момент много работ адресовано проблеме АГ. Возможность предвидеть риск развития гипертонии может способствовать разработке эффективных профилактических стратегий [33]. С. Ye с группой авторов разработали и исследовали проспективную модель инцидента эссенциальной АГ в течение года [34]. Использованы данные электронных медицинских карт, на основе которых сформирована ретроспективная (n = 823 627) и проспективная (n = 680 810) когорты. Для отбора информативных признаков и построения модели применен алгоритм XGBoost. Прогностическая мощность моделей по данным AUC составила 0,917 и 0,870 в ретроспективной и проспективной когортах соответственно. Сахарный диабет 2-го типа, дислипидемия, ССЗ, психические заболевания и социально-экономические детерминанты были ведущими факторами возникновения эссенциальной АГ. Прогностическая модель доступна для использования в режиме реального времени.

Н. Kanegae и соавт. на основе МО разработали и исследовали модель прогнозирования развития АГ [33]. Использованы данные медицинского осмотра 18 258 нормотензивных жителей Японии за 2005–2016 гг.,

записанные в момент постановки диагноза АГ и двух предыдущих ежегодных визитов. Проведено сравнение алгоритмов XGBoost и Ensemble с логистической регрессией. Обучающая и тестируемая выборки составили 75 и 25% соответственно. AUC в тестируемой когорте составил 0,877, 0,881 и 0,859 для моделей XGBoost, Ensemble и «логистическая регрессия» соответственно. Ведущими предикторами АГ были систолическое АД за год до постановки диагноза, индекс массы тела, возраст, вес, уровень аланинаминотрансферазы и глюкозы до постановки диагноза. Полученные данные могут быть использованы для выявления группы риска и проведения немедикаментозной профилактики гипертонии.

Sakr S. и соавт. провели исследование по сравнению эффективности различных методов МО в прогнозировании 10-летнего инцидента АГ на основе данных тредмил-теста [35]. Использованы данные 23 095 пациентов, прошедших по направлению врача обследование на беговой дорожке Henry Ford Health Systems в период с 1991 по 2009 г. Проанализированы гемодинамические показатели, диагноз, клинические и лабораторные данные. Тестируемые технологии МО включали алгоритмы LogitBoost, Bayesian Network classifier, Locally Weighted Naive Bayes, Random Tree Forest, ИНС и метод опорных векторов. Отобраны наиболее информативные признаки: возраст, число MET, систолическое АД в покое, пиковое диастолическое АД, диастолическое АД в покое, ишемическая болезнь сердца. Алгоритм Random Tree Forest показал наилучшую производительность (AUC = 0,93), превосходя остальные методы МО. Авторы подчеркивают важность сравнительной оценки производительности разных алгоритмов МО.

S. Huang с коллегами изучили факторы риска и разработали модель прогнозирования АГ для сельских жителей старше 35 лет на основе ИНС [36]. Использованы данные перекрестного исследования 3 054 респондентов (2 438 – обучающая, 616 – тестируемая выборки). При сравнении с логистической регрессией прогностическая мощность ИНС была выше (AUC = 0,90 против 0,73).

Значительные перспективы связывают с применением технологий МО для анализа генетических причин АГ. E. Held и соавт. исследовали возможность применения метода опорных векторов для прогнозирования риска АГ на основе генотипа, данных экспрессии генов и редких вариантов. При сравнении алгоритма с логистической регрессией не выявлено радикальных различий в производительности. По мере увеличения количества генов прогностическая способность моделей значительно снижалась. Линейный метод опорных векторов показал более устойчивую производительность при включении дополнительных генов [37].

Z. Pei и соавт. построили модель прогнозирования риска АГ на основе метода опорных векторов

с включением группы экологических и генетических факторов [38]. Использованы данные эпидемиологического исследования, состоящие из 1 200 наблюдений. На этапе предобработки отобрано 9 экологических и 12 генетических информативных признаков. Метод опорных векторов с функцией Лапласа прогнозировал риск гипертонии наиболее точно, при этом модель, учитывающая обе группы факторов, была более эффективной по сравнению с учетом каждой группы по отдельности.

Li C. с группой авторов на основе МО разработали модели для выявления лиц с высоким риском развития АГ [39]. Использованы данные 965 респондентов, включающие клинические параметры и генетическую информацию (однонуклеотидные полиморфизмы). С помощью метода опорных векторов построены две модели для прогнозирования систолического и диастолического АД (AUC = 0,673 и 0,817 соответственно). Предикторами систолического АД были возраст, индекс массы тела, окружность талии, физические нагрузки (раз в неделю), гипертония в анамнезе у родителей и полиморфизм rs7305099. Предикторами диастолического АД, в свою очередь, были вес, употребление алкоголя, физические упражнения (раз в неделю), триглицериды, гипертония в анамнезе у родителей и полиморфизмы rs5193, rs7305099 и rs3889728.

Семейная гиперхолестеринемия

Значительный интерес представляет возможность выявления среди больших групп населения лиц с семейной гиперхолестеринемией. По данным, полученным в США, в 90% случаев заболевание остается не выявленным. Улучшение прогноза при семейной гиперхолестеринемии возможно при своевременных диагностике и лечении. K.D. Myers с соавт. на основе данных 939 пациентов с семейной гиперхолестеринемией и 83 136 контрольных случаев разработали модель FIND FH и опробовали ее на больших наборах данных – 170 млн и 174 тыс. человек [40]. Используя модель с точностью AUC = 0,89, авторы выявили 1 331 759 случаев из 170 416 201 в национальной базе данных и 866 случаев из 173 733 в базе данных системы здравоохранения, подозрительных на наличие семейной гиперхолестеринемии. Среди отмеченных случаев экспертами рассмотрены случайные выборки (45 и 103 из двух баз данных соответственно) и применены клинические критерии диагностики семейной гиперхолестеринемии. Из них 87% из национальной базы данных и 77% из базы данных системы здравоохранения были отнесены к категории лиц с достаточно высокой вероятностью данного заболевания, предполагающей проведение дальнейших диагностики и лечения. Результаты исследования показали, что модель FIND FH успешно применима к большим и разрозненным базам данных из разных медицинских учреждений.

Избыточный вес

S. Zhang и соавт. исследовали возможность прогнозирования избыточного веса в возрасте трех лет с помощью технологий МО на основе 16 253 записей осмотров педиатра в возрасте 6 нед., 8 мес. и 2 лет. Метод опорных векторов и Байесовские методы МО справились с поставленной задачей более эффективно, чем логистическая регрессия, демонстрируя показатель корректной классификации 55–60%. Субоптимальные результаты авторы объясняют сложностью причин, приводящих к избыточному весу и ожирению, включающих не только данные врачебного осмотра, но и генетические, социологические, психологические факторы. Для получения более производительных моделей необходимо, по-видимому, принимать в расчет большее число признаков [41].

Интересные результаты получены Т.М. Dugan с коллегами, которые исследовали возможность прогнозирования детского ожирения на основе данных, регистрируемых в рамках действующей педиатрической системы поддержки принятия врачебных решений. Использованы 167 признаков, собранных во время нескольких плановых визитов до 2-летнего возраста, включающие данные опроса родителей, физикального осмотра, социально-демографические переменные. Применен широкий ряд технологий МО, из которых наибольшую точность (~85%) показали Random Tree, Random Forest и ID3. Ведущим предиктором ожирения был избыточный вес в возрасте до двух лет. Исследование продемонстрировало возможность использования информации, обрабатываемой действующей системой поддержки принятия врачебных решений, для построения достаточно точной модели прогнозирования ожирения у детей [42].

R. Hammond и соавт. использовали данные 25 945 электронных записей и в общей сложности 19 290 входных признаков для разработки прогностической модели ожирения в возрасте 5 лет. Применяемые алгоритмы включали Random Forest, Gradient Boosting, логистическая регрессия (L1-LR) и LASSO-регрессия. Установлено, что индекс массы тела в возрасте 19–24 мес. и ~2 лет был наиболее важной характеристикой для прогнозирования. Наилучшим алгоритмом признана LASSO-регрессия с AUC = 0,817 в модели для девочек и 0,761 для мальчиков [43].

Метаболический синдром

Группа авторов во главе с Н. Shin на основе алгоритмов логистической регрессии, CART («дерево решений»), Random Forest, Extreme Gradient Boosting и TabNet, а также данных 70 370 человек разработали модели для прогнозирования метаболического синдрома (MetS) [44]. Из 17 кандидатов с помощью моделей выбрано четыре ключевых признака: пол, окружность талии, систолическое и диастолическое АД. Синтетические признаки, рас-

считанные на основе АД и окружности талии, были ведущими предикторами MetS независимо от классификатора. «Дерево решений» признано лучшей моделью MetS: для нее требовалось наименьшее количество признаков, при этом точность прогнозирования не слишком уступала другим моделям.

F. Hosseini-Esfahani и коллеги использовали модель Random Forest для изучения наиболее значимых предикторов 3-летнего инцидента MetS в Тегеране, включая диетические факторы. Проанализирована когорта, состоящая из 3 048 респондентов старше 20 лет [45]. По данным использованного алгоритма и логистической регрессии, ведущими предикторами инцидента MetS были диабет в анамнезе, высокий индекс массы тела, пожилой возраст, мужской пол и низкое потребление мононенасыщенных жирных кислот.

Использование электрокардиографических данных

В настоящее время становится ясным, что ЭКГ содержит в себе намного больше информации, чем предполагалось ранее. Значительный интерес связан с возможностью использования электрокардиографической информации, не относящейся к электрической активности сердца и обычно не распознаваемой в рамках традиционных подходов к интерпретации ЭКГ [2]. С помощью технологий МО активно развиваются два направления: прогнозирование риска заболеваний на основе «нормальной» ЭКГ и выявление специфических, клинически значимых ЭКГ-фенотипов.

Определенные успехи достигнуты при использовании технологий МО для выявления лиц с повышенным риском ФП [2]. Разработаны интеллектуальные ЭКГ-системы, способные с приемлемой точностью определять высокий риск развития ФП на основе анализа синусового ритма [2], что открывает возможности для целенаправленной профилактики данного заболевания. Продемонстрирована более высокая точность обнаружения ФП при использовании методов глубокого МО по сравнению с сертифицированными кардиологами. Важно отметить, что нейронные сети могут помочь в скрининге ФП, даже если она отсутствует на момент обследования [6].

Ю.А. Челебаева сообщает о разработке нейросетевой модели определения признаков ФП, действующей на основе обработки сигналов кардиоритмограммы. Разработанная модель отличается высокой достоверностью, незначительными аппаратными затратами и может применяться в составе систем мониторинга сердечного ритма как в госпитальных условиях, так и для профилактики и ранней диагностики ФП [46].

Z.I. Attia с группой авторов на основе 650 тыс. записей ЭКГ (180 тыс. пациентов) разработали глубокую НС, способную выявлять лиц с риском ФП при анализе синусового ритма [47]. Такой подход был эффективным, если ФП регистрировалась в те-

чение 31 дня после анализа синусового ритма. Глубокая НС показала чувствительность 79% и специфичность 79,5% с дальнейшим увеличением до 82,3 и 83,4% соответственно при анализе нескольких кардиограмм одного и того же пациента. Показана возможность прогнозирования инцидента ФП в течение года после анализа синусового ритма [48].

Значительный интерес представляют возможности анализа ЭКГ-сигнала с носимых устройств. На текущий момент разработано множество ЭКГ-систем на базе смартфонов. В недавней публикации В.Р. Yan и соавт. показано, что фотоплетизмографический метод регистрации ЭКГ со встроенной камеры смартфона является достаточно чувствительным и специфичным для выявления ФП [49]. Наиболее изучен алгоритм выявления ФП Kardia (AliveCor), демонстрирующий высокую негативную предсказательную ценность [6]. В рамках исследования Apple Heart Study проведено проспективное наблюдение 419 тыс. участниками, использующими смарт-часы Apple [50]. Информация о сердечном ритме регистрировалась с помощью фотоплетизмографического датчика, и если запись интерпретировалась алгоритмом как вероятная ФП, проводился 7-дневный скрининг ЭКГ с помощью присланного по почте ЭКГ-пластыря. Из 2 161 участника (0,52%), получившего уведомление о неправильном сердечном ритме, 450 участников (21%) вернули свои ЭКГ-пластыри для анализа, при этом ФП присутствовала на 34% возвращенных записей. В аналогичном исследовании Huawei Heart Study у 190 тыс. респондентов сердечный ритм отслеживался с помощью фотоплетизмографического датчика смарт-часов Huawei [51]. Из 424 участников (0,23%), у которых на основе автоматической интерпретации возникло подозрение на ФП, 262 человека (62%) были эффективно прослежены с помощью 12 отведений или холтеровской ЭКГ. Из них у 227 (87%) подтвердилось наличие ФП. J. Ramesh и коллеги сообщают о разработке глубокой НС, способной выявлять ФП с высокой диагностической точностью как по данным ЭКГ, так и фотоплетизмографическим записям [52].

Примеры данных исследований демонстрируют значительный потенциал, но также и ограничения использования смарт-технологий в популяционных скрининговых программах. Одним из серьезных недостатков такого подхода является потеря контакта со значительным числом участников проспективного наблюдения. По способности интерпретации плетизмографических ЭКГ-сигналов глубокие НС превосходят стандартные методы МО. Тем не менее существует ряд проблем при анализе ЭКГ методом глубокого МО [6]. Поскольку большинство алгоритмов выявления ФП основано на распознавании абсолютно нерегулярных интервалов R–R, современные системы могут с достаточно высокой

вероятностью пропускать случаи трепетания предсердий. Несмотря на то что трепетание предсердий зачастую проявляется клинически и поэтому чаще диагностируется стандартными методами, оба нарушения ритма сопряжены с одинаковым риском тромбоэмболических осложнений, и гиподиагностика может подрывать доверие к надежности таких алгоритмов. Так, в недавней статье S. Sager с группой авторов сообщено о возможности обучения глубокой НС правильному определению как ФП, так и истмус-зависимой (типичной) формы трепетания предсердий [53]. На текущий момент влияние данных технологий на жесткие конечные точки мало изучено в проспективных исследованиях.

Проводятся исследования по использованию электрокардиографических данных для выявления бессимптомной дисфункции левого желудочка. В частности, такие модели уже разработаны на основе традиционных и сверточных ИНС [54], а также алгоритма Random Forest [55]. Исследование EAGLE показало принципиальную возможность выявления низкой фракции выброса при внедрении интеллектуальных систем интерпретации ЭКГ в учреждения первичного звена здравоохранения [2]. Продемонстрирована возможность использования МО для диагностики и фенотипирования синдрома удлиненного интервала QT [56], прогнозирования источника желудочковых аритмий [57], выявления гипертрофической кардиомиопатии [58], гипокалиемии [59] и даже возраста и пола [60].

Y.S. Baek с коллегами разработали алгоритм глубокого МО, позволяющий измерять «ЭКГ-возраст» на основе стандартной ЭКГ (12 отведений) и данных проспективного наблюдения [61]. Использованы данные 425 051 ЭКГ, записанные в период 2006–2021 гг. Тестирование глубокой НС проведено на отдельной выборке 97 058 ЭКГ. После поправок на факторы коморбидности у пациентов с «ЭКГ-возрастом», превышающим паспортный возраст на 6 и более лет, наблюдалась более высокая смертность от всех причин (ОР = 1,60), чаще отмечены конечные точки (ОР = 1,91). Среди лиц с «ЭКГ-возрастом» на 6 и более лет ниже паспортного выявлена обратная зависимость (ОР = 0,82 и 0,78, соответственно). Выявлены заметные изменения интервала PQ, длительности комплекса QRS, интервала QT и QTc, происходящие по мере увеличения ЭКГ-возраста. Разработанный метод может способствовать повышению эффективности первичной профилактики и медицинского обслуживания.

Управление факторами риска

Г.Г. Рапаков с группой авторов применили технологии МО (CRT) для анализа взаимосвязей психосоциальных и поведенческих ФР ССЗ [62]. С помощью использованных алгоритмов формируются решающие правила и определяется целевая группа населения для

адресной коррекции факторов, связанных с повышенным АД. В настоящее время развиваются технологии МО, помогающие управлять пищевым поведением. Так, А. Myers с коллегами на основе сверточной НС создали google-приложение Im2Calories, позволяющее получить информацию о составе и калорийности пищевого продукта по его изображению [10].

I. Weber и P. Achananuparp использовали находящиеся в свободном доступе дневники питания более 4 тыс. пользователей мобильного приложения MyFitnessPal для обучения алгоритма (метод опорных векторов) различать успешную и неуспешную диету (ниже и выше указанных пользователем ежедневных целевых калорий соответственно), и проанализировали диетические факторы, влияющие на два данных класса [63]. Выявлено, что употребление растительного и сливочного масла, фастфуда, десертов и свинины вместо птицы было связано с превышением цели по калориям. Более того, в выходные дни наблюдалось сокращение числа пользовательских записей о питании, когда пользователи чаще всего «превышали» цель по калориям.

G. Spanakis и коллеги использовали данные приложения для фитнеса ThinkSlim и алгоритм «дерево решений» для анализа связей между отдельными состояниями здоровых лиц с лишним весом (местоположение, активность, бодрость, расслабленность, грусть, скука, стресс, гнев, беспокойство) и диетическими предпочтениями, реализуемыми в то же самое время. Алгоритм классифицирует группы лиц с похожим пищевым поведением и использует полученную информацию для предупреждения пользователей о наступлении отдельных состояний, которые могут привести к нездоровому пищевому поведению [10].

Проблемы применения искусственного интеллекта

Осознание траекторий и пределов развития технологий ИИ является одной из наиболее острых проблем нашего времени. Концептуальные вопросы взаимодействия человека и ИИ обсуждаются в монографии под редакцией академика РАН В.А. Лекторского [64]. В работе подчеркивается, что научное определение ИИ на текущий момент недостаточно разработано и понимается по-разному даже внутри профессионального сообщества [64]. В 2021 г. Всемирная организация здравоохранения выпустила руководство, в котором обсуждаются этические и правовые вопросы разработки, внедрения и использования ИИ. В частности, обращается внимание на недопустимость переоценки пользы ИИ для здоровья, этические проблемы сбора и использования медицинских данных, предвзятость алгоритмов, кибербезопасность [2].

Существуют барьеры, затрудняющие внедрение технологий ИИ в сфере здравоохранения. Для успешного практического применения модель, ос-

нованная на ИИ, должна быть способна производить точные результаты на основе новых данных. Другой проблемой является «закрытость» внутренних алгоритмов (например, ИНС), при использовании которых ни пользователь, ни разработчик не имеют достаточного представления о том, почему система делает тот или иной «правильный» вывод. В случае, когда искусственная интеллектуальная система рекомендует человеку определенные действия, и он не может понять, на основании чего дается такого рода рекомендация, он перестает воспринимать себя в качестве самостоятельной личности, не понимает смысла своих действий, не осознает ответственности за результат [64]. Для преодоления этой проблемы быстро развиваются технологии объяснимого ИИ (eXplainable artificial intelligence, XAI), например, GradCAM и SHAP [2].

Другая задача состоит в том, что модель, основанная на ИИ, должна быть способна производить правильное решение в ответ на широкий спектр входных данных, записанных в различных ситуациях, отличных от обучающей выборки. На текущий момент не существует общепринятого способа безопасной интеграции больших данных между различными учреждениями, что затрудняет выяснение того, обладает ли интеллектуальная система такими свойствами. Для преодоления данной проблемы рассматривается возможность использования блокчейн-технологий. Поднимается вопрос и защиты конфиденциальности персональных данных. Использование ИИ может способствовать идентификации личности. К примеру, человек не может идентифицировать личность по ЭКГ, в то время как хорошо обученная модель, вероятно, способна извлечь такую информацию, как возраст и пол. Данные особенности требуют тщательной проработки с точки зрения безопасности. Несмотря на в целом оптимистичное отношение к технологиям ИИ, значительным препятствием к внедрению таких систем в сфере здравоохранения, по мнению экспертов, на сегодня остаются недостаточный опыт и отсутствие законодательной базы [2].

Заключение

В статье рассмотрены основные направления применения технологий МО в сфере первичной профилактики ССЗ, показаны примеры решения с их помощью научных и практических задач. В настоящее время изучается возможность использования МО для прогнозирования как суммарного ССР, так и риска возникновения ССЗ, в том числе каротидного атеросклероза и др. Кроме традиционных ФР в модели МО интегрируются данные опросников, врачебного осмотра, лабораторных показателей, ЭКГ, кардиовизуализации, сведений о принимаемом лечении, геномные и протеомные признаки. Обращает внимание разнообразие применяемых методов МО. Наиболее часто прибегают к таким классификаторам,

как Random Forest, метод опорных векторов, ИНС. Проводятся сравнения с традиционными статистическими методами (логистическая регрессия, модель Кокса). Нередко применяется ансамбль методов МО, позволяющий использовать лучшие черты каждого алгоритма. Часто применяется процедура отбора информативных признаков. Многие алгоритмы МО демонстрируют прирост точности прогноза по отношению к действующим шкалам, но однозначного лидера на текущий момент не прослеживается. На ранних стадиях развития находятся технологии глубокого МО. Много внимания уделяется мобильным, облачным и телемедицинским технологиям. Они открывают новые возможности для сбора, хранения и полезного применения медицинских данных и могут вывести профилактику ССЗ на новый уровень. Есть примеры использования мобильных технологий МО для управления ФР, в частности пищевым поведением. Ожидается существенное влияние таких технологий на практику скрининга ФП уже в ближайшем будущем. С их помощью станет возможным использование для стратификации риска данных кардиовизуализации, добавление которых к традиционным ФР позволяет получить наиболее оптимальные оценки риска. Вместе с тем обращается внимание на такие

проблемы, как недопустимость переоценки роли ИИ в технологиях здравоохранения, предвзятость алгоритмов, этические аспекты сбора и использования медицинских данных. Серьезной задачей является обеспечение кибербезопасности.

Практическая применимость моделей МО и их влияние на конечные точки на текущий момент изучены недостаточно. Значительным препятствием к внедрению технологий МО в сфере здравоохранения, по мнению экспертов, являются недостаточный опыт их применения и отсутствие законодательной базы.

Конфликт интересов

В.С. Кавешников заявляет об отсутствии конфликта интересов. Д.С. Брагин заявляет об отсутствии конфликта интересов. В.Х. Ваизов заявляет об отсутствии конфликта интересов. А.В. Кавешников заявляет об отсутствии конфликта интересов. М.А. Кузьмичкина заявляет об отсутствии конфликта интересов. И.А. Трубачева заявляет об отсутствии конфликта интересов.

Финансирование

Авторы заявляют об отсутствии финансирования исследования.

Информация об авторах

Кавешников Владимир Сергеевич, кандидат медицинских наук ведущий научный сотрудник лаборатории регистров сердечно-сосудистых заболеваний, высокотехнологичных вмешательств и телемедицины Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0002-0211-4525

Брагин Дмитрий Сергеевич, младший научный сотрудник лаборатории регистров сердечно-сосудистых заболеваний, высокотехнологичных вмешательств и телемедицины Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0002-0875-3301

Ваизов Валерий Харисович, кандидат медицинских наук младший научный сотрудник лаборатории регистров сердечно-сосудистых заболеваний, высокотехнологичных вмешательств и телемедицины Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0003-0004-7717

Кавешников Артём Владимирович, младший научный сотрудник лаборатории регистров сердечно-сосудистых заболеваний, высокотехнологичных вмешательств и телемедицины Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0002-4743-1989

Кузьмичкина Мария Анатольевна, кандидат медицинских наук научный сотрудник лаборатории регистров

Author Information Form

Kaveshnikov Vladimir S., PhD, Leading Researcher, Laboratory of Cardiovascular Diseases Registries, High-Tech Interventions and Telemedicine, Research Institute of Cardiology – Branch of the Federal State Budgetary Scientific Institution “Tomsk National Research Medical Center of the Russian Academy of Sciences”, Tomsk, Russian Federation; **ORCID** 0000-0002-0211-4525

Bragin Dmitry S., Junior Researcher, Laboratory of Cardiovascular Diseases Registries, High-Tech Interventions and Telemedicine, Research Institute of Cardiology – Branch of the Federal State Budgetary Scientific Institution “Tomsk National Research Medical Center of the Russian Academy of Sciences”, Tomsk, Russian Federation; **ORCID** 0000-0002-0875-3301

Vaizov Valeriy Kh., PhD, Junior Researcher, Laboratory of Cardiovascular Diseases Registries, High-Tech Interventions and Telemedicine, Research Institute of Cardiology – Branch of the Federal State Budgetary Scientific Institution “Tomsk National Research Medical Center of the Russian Academy of Sciences”, Tomsk, Russian Federation; **ORCID** 0000-0003-0004-7717

Kaveshnikov Artyom V., Junior Researcher, Laboratory of Cardiovascular Diseases Registries, High-Tech Interventions and Telemedicine, Research Institute of Cardiology – Branch of the Federal State Budgetary Scientific Institution “Tomsk National Research Medical Center of the Russian Academy of Sciences”, Tomsk, Russian Federation; **ORCID** 0000-0002-4743-1989

Kuzmichkina Maria A., PhD, Research Associate, Laboratory of Cardiovascular Diseases Registries, High-Tech

сердечно-сосудистых заболеваний, высокотехнологичных вмешательств и телемедицины Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0002-5587-3947

Трубачева Ирина Анатольевна, доктор медицинских наук заместитель директора по научно-организационной работе, руководитель отдела популяционной кардиологии Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0003-1063-7382

Interventions and Telemedicine, Research Institute of Cardiology – Branch of Federal State Budgetary Scientific Institution “Tomsk National Research Medical Center of the Russian Academy of Sciences”, Tomsk, Russian Federation; **ORCID** 0000-0002-5587-3947

Trubacheva Irina A., PhD, Deputy Director for Scientific and Organizational Work, Head of Population Cardiology Department, Research Institute of Cardiology – Branch of the Federal State Budgetary Scientific Institution “Tomsk National Research Medical Center of the Russian Academy of Sciences”, Tomsk, Russian Federation; **ORCID** 0000-0003-1063-7382

Вклад авторов в статью

KBC – вклад в концепцию и дизайн исследования, написание статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

BDC – вклад в концепцию и дизайн исследования, написание статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

BBX – вклад в концепцию и дизайн исследования, написание статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

KAB – вклад в концепцию и дизайн исследования, написание статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

KMA – вклад в концепцию и дизайн исследования, написание статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

TIA – вклад в концепцию и дизайн исследования, написание статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

Author Contribution Statement

KVS – contribution to the concept and design of the study, manuscript writing, approval of the final version, fully responsible for the content

BDS – contribution to the concept and design of the study, manuscript writing, approval of the final version, fully responsible for the content

VVKh – contribution to the concept and design of the study, manuscript writing, approval of the final version, fully responsible for the content

KAV – contribution to the concept and design of the study, manuscript writing, approval of the final version, fully responsible for the content

KMA – contribution to the concept and design of the study, manuscript writing, approval of the final version, fully responsible for the content

TIA – contribution to the concept and design of the study, manuscript writing, approval of the final version, fully responsible for the content

СПИСОК ЛИТЕРАТУРЫ

1. Концевая А.В., Драпкина О.М., Баланова Ю.А., Имаева А.Э., Суворова Е.И., Худяков М.Б. . Экономический ущерб сердечно-сосудистых заболеваний в Российской Федерации в 2016 году. Рациональная фармакотерапия в кардиологии. 2018; 14(2): 156–166. doi: 10.20996/1819-6446-201814-2-156-166.
2. Nakamura T., Sasano T. Artificial intelligence and cardiology: Current status and perspective. J. Cardiol. 2022; 79(3): 326–333. doi: 10.1016/j.jcc.2021.11.017.
3. Hykin S.S. Neural Networks: A Comprehensive Foundation, 2nd Ed. USA: Prentice Hall; 1999. P. 842. ISBN: 0132733501.
4. Cho S.Y., Kim S.H., Kang S.H., Lee K.J., Choi D., Kang S., Park S.J., Kim T., Yoon C.H., Youn T.J., Chae I.H. Pre-existing and machine learning-based models for cardiovascular risk prediction. Sci. Rep. 2021; 11(1): 8886. doi: 10.1038/s41598-021-88257-w.
5. Char D.S., Shah N.H., Magnus D. Implementing Machine Learning in Health Care – Addressing Ethical Challenges. N. Engl. J. Med. 2018; 378(11): 981–983. doi: 10.1056/NEJMp1714229.
6. Wegner F.K., Plagwitz L., Doldi F., Ellermann C., et al. Machine learning in the detection and management of atrial fibrillation. Clin. Res. Cardiol. 2022; 111(9): 1010–1017. doi: 10.1007/s00392-022-02012-3.
7. Javaid A., Zghyer F., Kim C., Spaulding E.M., Isakadze N., Ding J., Kargillis D., Gao Y., Rahman F., Brown D.E., Saria S., Martin S.S., Kramer C.M., Blumenthal R.S., Marvel F.A. Medicine 2032: The future of cardiovascular disease prevention with machine learning and digital health technology. Am. J. Prev. Cardiol. 2022; 12: 100379. doi: 10.1016/j.ajpc.2022.100379.
8. Kononenko I. Machine learning for medical diagnosis: history, state of the art and perspective. Artif. Intell. Med. 2001; 23(1): 89–109. doi: 10.1016/s0933-3657(01)00077-x.
9. Suri J.S., Bhagawati M., Paul S., Protogerou A.D., Sfrikakis P.P., Kitas G.D., Khanna N.N., Ruzsa Z., Sharma A.M., Saxena S., Faa G., Laird J.R., Johri A.M., Kalra M.K., Paraskevas K.I., Saba L. A Powerful Paradigm for Cardiovascular Risk Stratification Using Multiclass, Multi-Label, and Ensemble-Based Machine Learning Paradigms: A Narrative Review. Diagnostics. (Basel). 2022; 12(3): 722. doi: 10.3390/diagnostics12030722.
10. Vilne B., Kibilds J., Siksnā I., Lazda I., Valciņa O., Krūmiņa A. Could Artificial Intelligence/Machine Learning and Inclusion of Diet-Gut Microbiome Interactions Improve Disease Risk Prediction? Case Study: Coronary Artery Disease. Front. Microbiol. 2022; 13: 627892. doi: 10.3389/fmicb.2022.627892.
11. Patel S.A., Winkel M., Ali M.K., Narayan K.M. Cardiovascular mortality associated with 5 leading risk factors: national and state preventable fractions estimated from survey data. Ann. Intern. Med. 2015; 163(4): 245–53. doi: 10.7326/M14-1753.
12. Liu W., Laranjo L., Klimis H., Chiang J., Yue J., Marschner S., Quiroz J.C., Jorm L., Chow C.K. Machine-learning versus traditional approaches for atherosclerotic cardiovascular risk prognostication in primary prevention cohorts: a systematic review and meta-analysis. Eur. Heart. J. Qual. Care Machine-learning versus traditional approaches for atherosclerotic cardiovascular risk prognostication in primary prevention cohorts: a systematic review and meta-analysis. Eur. Heart. J. Qual. Care. Clin. Outcomes. 2023; 9(4): 310–322. doi: 10.1093/ehjqcco/qcad017.
13. Жданова Е.В., Рубцова Е.В. Опыт внедрения пилотного проекта "искусственный интеллект" в работе участкового терапевта на территории ямало-ненецкого автономного округа: пилотное одномоментное скрининговое observationalное ис-

следование. Кубанский научный медицинский вестник. 2022; 29(4): 14–31. doi: 10.25207/1608-6228-2022-29-4-14-31.

14. Грибова В.В., Гельцер Б.И., Шахгельдян К.И., Петряева М.В., 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. doi: 10.25881/18110193_2022_3_24.

15. Alaa A.M., Bolton T., Di Angelantonio E., Rudd J.H.F. Cardiovascular disease risk prediction using automated machine learning: A prospective study of 423,604 UK Biobank participants. PLoS. One. 2019; 14(5): e0213653. doi: 10.1371/journal.pone.0213653.

16. Weng S.F., Reps J., Kai J., Garibaldi J.M. Can machine-learning improve cardiovascular risk prediction using routine clinical data? PLoS. One. 2017; 12(4): e0174944. doi: 10.1371/journal.pone.0174944.

17. Matheson M.B., Kato Y., Baba S., Cox C., Lima J.A.C., Ambale-Venkatesh B. Cardiovascular Risk Prediction Using Machine Learning in a Large Japanese Cohort. Circ. Rep. 2022; 4(12): 595–603. doi: 10.1253/circrep.CR-22-0101.

18. Schrempf M., Kramer D., Jauk S., Veeranki S.P.K., Leodolter W., Rainer P.P. Machine Learning Based Risk Prediction for Major Adverse Cardiovascular Events. Stud. Health. Technol. Inform. 2021; 279: 136–143. doi: 10.3233/SHTI210100.

19. Quesada J.A., Lopez-Pineda A., Gil-Guillén V.F., Durazo-Arvizu R., Orozco-Beltrán D., López-Domenech A., Carratalá-Munuera C. Machine learning to predict cardiovascular risk. Int. J. Clin. Pract. 2019; 73(10): e13389. doi: 10.1111/ijcp.13389.

20. Kakadiaris I.A., Vrigkas M., Yen A.A., Kuznetsova T., Budoff M., Naghavi M. Machine Learning Outperforms ACC / AHA CVD Risk Calculator in MESA. J. Am. Heart. Assoc. 2018; 7(22): e009476. doi: 10.1161/JAHA.118.009476.

21. Mehrabani-Zeinabad K., Feizi A., Sadeghi M., Roohafza H., Talaei M., Sarrafzadegan N. Cardiovascular disease incidence prediction by machine learning and statistical techniques: a 16-year cohort study from eastern Mediterranean region. BMC. Med. Inform. Decis. Mak. 2023; 23(1): 72. doi: 10.1186/s12911-023-02169-5.

22. Гаврилов Д.В., Серова Л.М., Корсаков И.Н., Гусев А.В., Новицкий Р.Э., Кузнецова Т.Ю. Предсказание сердечно-сосудистых событий при помощи комплексной оценки факторов риска с использованием методов машинного обучения. Врач. 2020; 31(5): 41–46. doi: 10.29296/25877305-2020-08.

23. Tsarapatsani K., Sakellarios A.I., Pezoulas V.C., Tsakanikas V.D., Kleber M.E., Marz W., Michalis L.K., Fotiadis D.I. Machine Learning Models for Cardiovascular Disease Events Prediction. Annu. Int. Conf. IEEE. Eng. Med. Biol. Soc. 2022; 2022: 1066–1069. doi: 10.1109/EMBC48229.2022.9871121.

24. 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. doi: 10.15829/1728-8800-2022-2908.

25. Gola D., Erdmann J., Müller-Myhsok B., Schunkert H. Polygenic risk scores outperform machine learning methods in predicting coronary artery disease status. Genet. Epidemiol. 2020; 44(2): 125–138. doi: 10.1002/gepi.22279.

26. Westerlund A.M., Hawe J.S., Heinig M., Schunkert H. Risk Prediction of Cardiovascular Events by Exploration of Molecular Data with Explainable Artificial Intelligence. Int. J. Mol. Sci. 2021; 22(19): 10291. doi: 10.3390/ijms221910291.

27. Steinfeldt J., Buergel T., Looek L., Kittner P., Ruyoga G., Zu Belzen J.U., Sasse S., Strangalies H., Christmann L., Hollmann N., Wolf B., Ference B., Deanfield J., Landmesser U., Eils R. Neural network-based integration of polygenic and clinical information: development and validation of a prediction model for 10-year risk of major adverse cardiac events in the UK Biobank cohort. Lancet Digit Health. 2022; 4(2): e84-e94. doi: 10.1016/S2589-7500(21)00249-1.

28. Rigdon J., Basu S. Machine learning with sparse nutrition data to improve cardiovascular mortality risk prediction in the USA using nationally randomly sampled data. BMJ. Open. 2019; 9(11): e032703. doi: 10.1136/bmjopen-2019-032703.

29. Гаврилов Д.В., Кузнецова Т.Ю., Дружилов М.А., Корсаков И.Н. Прогнозирование наличия субклинического каротидного атеросклероза у пациентов с избыточным весом и ожирением при помощи модели машинного обучения. Российский кардиологический журнал. 2022; 27(4): 40–47. doi:

10.15829/1560-4071-2022-4871.

30. Sánchez-Cabo F., Rossello X., Fuster V., Benito F., Manzano J.P., Silla J.C., Fernández-Alvira J.M., Oliva B., Fernández-Friera L., López-Melgar B., Mendiguren J.M., Sanz J., Ordovás J.M., Andrés V., Fernández-Ortiz A., Bueno H., Ibáñez B., García-Ruiz J.M., Lara-Pezzi E. Machine Learning Improves Cardiovascular Risk Definition for Young, Asymptomatic Individuals. J. Am. Coll. Cardiol. 2020; 76(14): 1674–1685. doi: 10.1016/j.jacc.2020.08.017.

31. Fan J., Chen M., Luo J., Yang S., Shi J., Yao Q., Zhang X., Du S., Qu H., Cheng Y., Ma S., Zhang M., Xu X., Wang Q., Zhan S. The prediction of asymptomatic carotid atherosclerosis with electronic health records: a comparative study of six machine learning models. BMC. Med. Inform. Decis. Mak. 2021; 21(1): 115. doi: 10.1186/s12911-021-01480-3.

32. Poplin R., Varadarajan A.V., Blumer K., Liu Y., McConnell M.V., Corrado G.S., Peng L., Webster D.R. Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning. Nat. Biomed. Eng. 2018; 2(3): 158–164. doi: 10.1038/s41551-018-0195-0.

33. Kanegae H., Suzuki K., Fukatani K., Ito T., Harada N., Kario K. Highly precise risk prediction model for new-onset hypertension using artificial intelligence techniques. J. Clin. Hypertens. (Greenwich). 2020; 22(3): 445–450. doi: 10.1111/jch.13759.

34. Ye C., Fu T., Hao S., Zhang Y., Wang O., Jin B., Xia M., Liu M., Zhou X., Wu Q., Guo Y., Zhu C., Li Y.M., Culver D.S., Alfreds S.T., Stearns F., Sylvester K.G., Widen E., McElhinney D., Ling X. Prediction of Incident Hypertension Within the Next Year: Prospective Study Using Statewide Electronic Health Records and Machine Learning. J. Med. Internet. Res. 2018; 20(1): e22. doi: 10.2196/jmir.9268.

35. Sakr S., Elshawi R., Ahmed A., Qureshi W.T., Brawner C., Keteyian S., Blaha M.J., Al-Mallah M.H. Using machine learning on cardiorespiratory fitness data for predicting hypertension: The Henry Ford Exercise Testing (FIT) Project. PLoS. One. 2018; 13(4): e0195344. doi: 10.1371/journal.pone.0195344.

36. Huang S., Xu Y., Yue L., Wei S., Liu L., Gan X., Zhou S., Nie S. Evaluating the risk of hypertension using an artificial neural network method in rural residents over the age of 35 years in a Chinese area. Hypertens. Res. 2010; 33(7): 722–6. doi: 10.1038/hr.2010.73.

37. Held E., Cape J., Tintle N. Comparing machine learning and logistic regression methods for predicting hypertension using a combination of gene expression and next-generation sequencing data. BMC. Proc. 2016; 10(Suppl 7): 141–145. doi: 10.1186/s12919-016-0020-2.

38. Pei Z., Liu J., Liu M., Zhou W., Yan P., Wen S., Chen Y. Risk-Predicting Model for Incident of Essential Hypertension Based on Environmental and Genetic Factors with Support Vector Machine. Interdiscip. Sci. 2018; 10(1): 126–130. doi: 10.1007/s12539-017-0271-2.

39. Li C., Sun D., Liu J., Li M., Zhang B., Liu Y., Wang Z., Wen S., Zhou J. A Prediction Model of Essential Hypertension Based on Genetic and Environmental Risk Factors in Northern Han Chinese. Int. J. Med. Sci. 2019; 16(6): 793–799. doi: 10.7150/ijms.33967.

40. Myers K.D., Knowles J.W., Staszak D., Shapiro M.D., Howard W., Yadava M., Zuzick D., Williamson L., Shah N.H., Banda J.M., Leader J., Cromwell W.C., Trautman E., Murray M.F., Baum S.J., Myers S., Gidding S.S., Wilemon K., Rader D.J. Precision screening for familial hypercholesterolaemia: a machine learning study applied to electronic health encounter data. Lancet. Digit. Health. 2019; 1(8): e393-e402. doi: 10.1016/S2589-7500(19)30150-5.

41. Zhang S., Tjortjjs C., Zeng X., Qiao H., Buchan I., Keane J. Comparing data mining methods with logistic regression in childhood obesity prediction. Inf Syst Front 11, 449–460 (2009). doi:10.1007/s10796-009-9157-0

42. Dugan T.M., Mukhopadhyay S., Carroll A., Downs S. Machine Learning Techniques for Prediction of Early Childhood Obesity. Appl. Clin. Inform. 2015; 6(3): 506–20. doi: 10.4338/ACI-2015-03-RA-0036.

43. Hammond R., Athanasiadou R., Curado S., Aphinyanaphongs Y., Abrams C., Messito M.J., Gross R., Katzow M., Jay M., Razavian N., Elbel B. Predicting childhood obesity using electronic health records and publicly available data. PLoS. One. 2019; 14(4): e0215571. doi: 10.1371/journal.pone.0215571.

44. Shin H., Shim S., Oh S. Machine learning-based predictive model for prevention of metabolic syndrome. PLoS. One. 2023; 18(6): e0286635. doi: 10.1371/journal.pone.0286635.

45. Hosseini-Esfahani F., Alafchi B., Cheraghi Z., Doosti-Irani A., Mirmiran P., Khalili D., Azizi F. Using Machine Learning Techniques to Predict Factors Contributing to the Incidence of Metabolic Syndrome in Tehran: Cohort Study. JMIR. Public.

Health. *Surveill.* 2021; 7(9): e27304. doi: 10.2196/27304.

46. Челебаева Ю.А. Разработка нейросетевой модели определения признаков мерцательной аритмии для подсистемы обработки сигналов кардиоритмограммы. *Биомедицинская радиоэлектроника.* 2021; 24(4): 97–106. doi: 10.18127/j15604136–202104–13.

47. Attia Z.I., Noseworthy P.A., Lopez-Jimenez F., Asirvatham S.J., Deshmukh A.J., Gersh B.J., Carter R.E., Yao X., Rabinstein A.A., Erickson B.J., Kapa S., Friedman P.A. An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction. *Lancet.* 2019; 394(10201): 861–867. doi: 10.1016/S0140–6736(19)31721–0.

48. Raghunath S., Pfeifer J.M., Ulloa-Cerna A.E., Nemani A., Carbonati T., Jing L., vanMaanen D.P., Hartzel D.N., Ruhl J.A., Lagerman B.F., Rocha D.B., Stoudt N.J., Schneider G., Johnson K.W., Zimmerman N., Leader J.B., Kirchner H.L., Griessenauer C.J., Hafez A., Good C.W., Fornwalt B.K., Haggerty C.M. Deep Neural Networks Can Predict New-Onset Atrial Fibrillation From the 12-Lead ECG and Help Identify Those at Risk of Atrial Fibrillation-Related Stroke. *Circulation.* 2021; 143(13): 1287–1298. doi: 10.1161/CIRCULATIONAHA.120.047829.

49. Yan B.P., Lai W.H.S., Chan C.K.Y., Chan S.C., Chan L.H., Lam K.M., Lau H.W., Ng C.M., Tai L.Y., Yip K.W., To O.T.L., Freedman B., Poh Y.C., Poh M.Z. Contact-Free Screening of Atrial Fibrillation by a Smartphone Using Facial Pulsatile Photoplethysmographic Signals. *J. Am. Heart. Assoc.* 2018; 7(8): e008585. doi: 10.1161/JAHA.118.008585.

50. Perez M.V., Mahaffey K.W., Hedlin H., Rumsfeld J.S., Garcia A., Ferris T., Balasubramanian V., Russo A.M., Rajmane A., Cheung L., Hung G., Lee J., Kowey P., Talati N., Nag D., Gummidipundi S.E., Beatty A., Hills M.T., Desai S., Granger C.B., Desai M., Turakhia M.P.; Apple Heart Study Investigators. Large-Scale Assessment of a Smartwatch to Identify Atrial Fibrillation. *N. Engl. J. Med.* 2019; 381(20): 1909–1917. doi: 10.1056/NEJMoa1901183.

51. Guo Y., Wang H., Zhang H., Liu T., Liang Z., Xia Y., Yan L., Xing Y., Shi H., Li S., Liu Y., Liu F., Feng M., Chen Y., Lip G.Y.H.; MAFA II Investigators. Mobile Photoplethysmographic Technology to Detect Atrial Fibrillation. *J. Am. Coll. Cardiol.* 2019; 74(19): 2365–2375. doi: 10.1016/j.jacc.2019.08.019.

52. Ramesh J., Solatidehkordi Z., Aburukba R., Sagahyoon A. Atrial Fibrillation Classification with Smart Wearables Using Short-Term Heart Rate Variability and Deep Convolutional Neural Networks. *Sensors. (Basel).* 2021; 21(21): 7233. doi: 10.3390/s21217233.

53. Sager S., Bernhardt F., Kehrle F., Merkert M., Potschka A., Meder B., Katus H., Scholz E. Expert-enhanced machine learning for cardiac arrhythmia classification. *PLoS. One.* 2021; 16(12): e0261571. doi: 10.1371/journal.pone.0261571.

54. Yao X., Rushlow D.R., Inselman J.W., McCoy R.G., Thacher T.D., Behnken E.M., Bernard M.E., Rosas S.L., Akfaly A., Misra A., Molling P.E., Krien J.S., Foss R.M., Barry B.A., Siontis K.C., Kapa S., Pellikka P.A., Lopez-Jimenez F., Attia Z.I., Shah N.D., Friedman P.A., Noseworthy P.A. Artificial intelligence-enabled electrocardiograms for identification of patients with low ejection fraction: a pragmatic, randomized clinical trial. *Nat. Med.* 2021; 27(5): 815–819. doi: 10.1038/s41591–021–01335–4.

55. Potter E.L., Rodrigues C.H.M., Ascher D.B., Abhayaratna W.P., Sengupta P.P., Marwick T.H. Machine Learning of ECG Waveforms to Improve Selection for Testing for Asymptomatic Left Ventricular Dysfunction. *JACC. Cardiovasc. Imaging.* 2021; 14(10): 1904–1915. doi: 10.1016/j.jcmg.2021.04.020.

56. Bos J.M., Attia Z.I., Albert D.E., Noseworthy P.A., Friedman P.A., Ackerman M.J. Use of Artificial Intelligence and Deep Neural Networks in Evaluation of Patients With Electrocardiographically Concealed Long QT Syndrome From the Surface 12-Lead Electrocardiogram. *JAMA. Cardiol.* 2021; 6(5): 532–538. doi: 10.1001/jamacardio.2020.7422.

57. Nakamura T., Nagata Y., Nitta G., Okata S., Nagase M., Mitsui K., Watanabe K., Miyazaki R., Kaneko M., Nagamine S., Hara N., Lee T., Nozato T., Ashikaga T., Goya M., Sasano T. Prediction of premature ventricular complex origins using artificial intelligence-enabled algorithms. *Cardiovasc. Digit. Health. J.* 2021; 2(1): 76–83. doi: 10.1016/j.cvdhj.2020.11.006.

58. Ko W.Y., Siontis K.C., Attia Z.I., Carter R.E., Kapa S., Ommen S.R., Demuth S.J., Ackerman M.J., Gersh B.J., Arruda-Olson A.M., Geske J.B., Asirvatham S.J., Lopez-Jimenez F., Nishimura R.A., Friedman P.A., Noseworthy P.A. Detection of Hypertrophic Cardiomyopathy Using a Convolutional Neural Network-Enabled Electrocardiogram. *J. Am. Coll. Cardiol.* 2020; 75(7): 722–733. doi: 10.1016/j.jacc.2019.12.030.

59. Attia Z.I., DeSimone C.V., Dillon J.J., Sapir Y., Somers V.K., Dugan J.L., Bruce C.J., Ackerman M.J., Asirvatham S.J., Striemer B.L., Bukartyk J., Scott C.G., Bennet K.E., Ladewig D.J., Gilles E.J., Sadot D., Geva A.B., Friedman P.A. Novel Bloodless Potassium Determination Using a Signal-Processed Single-Lead ECG. *J. Am. Heart. Assoc.* 2016; 5(1): e002746. doi: 10.1161/JAHA.115.002746.

60. Attia Z.I., Friedman P.A., Noseworthy P.A., Lopez-Jimenez F., Ladewig D.J., Satam G., Pellikka P.A., Munger T.M., Asirvatham S.J., Scott C.G., Carter R.E., Kapa S. Age and Sex Estimation Using Artificial Intelligence From Standard 12-Lead ECGs. *Circ. Arrhythm. Electrophysiol.* 2019; 12(9): e007284. doi: 10.1161/CIRCEP.119.007284.

61. Baek Y.S., Lee D.H., Jo Y., Lee S.C., Choi W., Kim D.H. Artificial intelligence-estimated biological heart age using a 12-lead electrocardiogram predicts mortality and cardiovascular outcomes. *Front. Cardiovasc. Med.* 2023; 10: 1137892. doi: 10.3389/fcvm.2023.1137892.

62. Рапаков Г.Г., Банщиков Г.Т., Горбунов В.А., Удартин А.В. Использование методов машинного обучения при коррекции поведенческих факторов риска в профилактике сердечно-сосудистых заболеваний. *Вестник череповецкого государственного университета.* 2020; 4 (97): 54–68. doi: 10.23859/1994–0637–2020–4–97–5.

63. Weber I., Achananuparp P. Insights from machine-learned diet success prediction. *Proc. Symp. Biocomput.* 2016; 21: 540–51.

64. Лекторский В.А., Васильев С.Н., Макаров В.Л., Хабриева Т.Я., Кокошин А.А., Ушаков Д.В., Валуева Е.А., Дубровский Д.И., Черниговская Т.В., Семёнов А.Л., Зискин К.Е., Любимов А.П., Целищев В.В., Алексеев А.Ю. Человек и системы искусственного интеллекта / Под ред. акад. РАН В.А. Лекторского. СПб.: Издательство «Юридический центр»; 2022. 328 с. ISBN: 978-5-94201-835-1.

REFERENCES

1. Kontsevaya A.V., Drapkina O.M., Balanova Y.A., Imaeva A.E., Suvorova E.I., Khudyakov M.B. Economic burden of cardiovascular diseases in the Russian Federation in 2016. *Rational Pharmacotherapy in Cardiology.* 2018; 14(2): 156–166. doi: 10.20996/1819–6446–201814–2–156–166. (In Russian)

2. Nakamura T., Sasano T. Artificial intelligence and cardiology: Current status and perspective. *J. Cardiol.* 2022; 79(3): 326–333. doi: 10.1016/j.jcc.2021.11.017.

3. Hykin S.S. *Neural Networks: A Comprehensive Foundation*, 2nd Ed. USA: Prentice Hall; 1999. P. 842. ISBN: 0132733501.

4. Cho S.Y., Kim S.H., Kang S.H., Lee K.J., Choi D., Kang S., Park S.J., Kim T., Yoon C.H., Yoon T.J., Chae I.H. Pre-existing and machine learning-based models for cardiovascular risk prediction. *Sci. Rep.* 2021; 11(1): 8886. doi: 10.1038/s41598–021–88257-w.

5. Char D.S., Shah N.H., Magnus D. Implementing Machine Learning in Health Care – Addressing Ethical Challenges. *N. Engl.*

J. Med. 2018; 378(11): 981–983. doi: 10.1056/NEJMp1714229.

6. Wegner F.K., Plagwitz L., Doldi F., Ellermann C., et al. Machine learning in the detection and management of atrial fibrillation. *Clin. Res. Cardiol.* 2022; 111(9): 1010–1017. doi: 10.1007/s00392–022–02012–3.

7. Javadi A., Zghyer F., Kim C., Spaulding E.M., Isakadze N., Ding J., Kargillis D., Gao Y., Rahman F., Brown D.E., Saria S., Martin S.S., Kramer C.M., Blumenthal R.S., Marvel F.A. *Medicine* 2032: The future of cardiovascular disease prevention with machine learning and digital health technology. *Am. J. Prev. Cardiol.* 2022; 12: 100379. doi: 10.1016/j.ajpc.2022.100379.

8. Kononenko I. Machine learning for medical diagnosis: history, state of the art and perspective. *Artif. Intell. Med.* 2001; 23(1): 89–109. doi: 10.1016/s0933–3657(01)00077-x.

9. Suri J.S., Bhagawati M., Paul S., Protogerou A.D., Sfakakis P.P., Kitaz G.D., Khanna N.N., Ruzsa Z., Sharma A.M., Saxena S., Faa G., Laird J.R., Johri A.M., Kalra M.K., Paraskevas K.I., Saba L.

A Powerful Paradigm for Cardiovascular Risk Stratification Using Multiclass, Multi-Label, and Ensemble-Based Machine Learning Paradigms: A Narrative Review. *Diagnostics*. (Basel). 2022; 12(3): 722. doi: 10.3390/diagnostics12030722.

10. Vilne B., Kibilds J., Siksnia I., Lazda I., Valciņa O., Krūmiņa A. Could Artificial Intelligence/Machine Learning and Inclusion of Diet-Gut Microbiome Interactions Improve Disease Risk Prediction? Case Study: Coronary Artery Disease. *Front. Microbiol.* 2022; 13: 627892. doi: 10.3389/fmicb.2022.627892.

11. Patel S.A., Winkel M., Ali M.K., Narayan K.M. Cardiovascular mortality associated with 5 leading risk factors: national and state preventable fractions estimated from survey data. *Ann. Intern. Med.* 2015; 163(4): 245–53. doi: 10.7326/M14-1753.

12. Liu W., Laranjo L., Klimis H., Chiang J., Yue J., Marschner S., Quiroz J.C., Jorm L., Chow C.K. Machine-learning versus traditional approaches for atherosclerotic cardiovascular risk prognostication in primary prevention cohorts: a systematic review and meta-analysis. *Eur. Heart. J. Qual. Care Machine-learning versus traditional approaches for atherosclerotic cardiovascular risk prognostication in primary prevention cohorts: a systematic review and meta-analysis.* *Eur. Heart. J. Qual. Care. Clin. Outcomes.* 2023; 9(4): 310–322. doi: 10.1093/ehjqcco/qcad017.

13. Zhdanova E.V., Rubtsova E.V. Implementing an artificial intelligence system in the work of general practitioner in the yamalo-nenets autonomous okrug: pilot cross-sectional screening observational study. *Kuban Scientific Medical Bulletin.* 2022; 29(4): 14–31. doi: 10.25207/1608-6228-2022-29-4-14-31. (In Russian)

14. Gribova V.V., Geltser B.I., Shakhgeldyan K.I., Petryaeva M.V., Shalfeeva E.A., Kosterin V.V. Hybrid technology of risk assessment and prognosis in cardiology. *Information technologies for the Physician.* 2022; 3: 24–35. doi: 10.25881/18110193_2022_3_24. (In Russian)

15. Alaa A.M., Bolton T., Di Angelantonio E., Rudd J.H.F. Cardiovascular disease risk prediction using automated machine learning: A prospective study of 423,604 UK Biobank participants. *PLoS. One.* 2019; 14(5): e0213653. doi: 10.1371/journal.pone.0213653.

16. Weng S.F., Reys J., Kai J., Garibaldi J.M. Can machine-learning improve cardiovascular risk prediction using routine clinical data? *PLoS. One.* 2017; 12(4): e0174944. doi: 10.1371/journal.pone.0174944.

17. Matheson M.B., Kato Y., Baba S., Cox C., Lima J.A.C., Ambale-Venkatesh B. Cardiovascular Risk Prediction Using Machine Learning in a Large Japanese Cohort. *Circ. Rep.* 2022; 4(12): 595–603. doi: 10.1253/circrep.CR-22-0101.

18. Schrempf M., Kramer D., Jauk S., Veeranki S.P.K., Leodolter W., Rainer P.P. Machine Learning Based Risk Prediction for Major Adverse Cardiovascular Events. *Stud. Health. Technol. Inform.* 2021; 279: 136–143. doi: 10.3233/SHIT210100.

19. Quesada J.A., Lopez-Pineda A., Gil-Guillén V.F., Durazo-Arvizu R., Orozco-Beltrán D., López-Domenech A., Carratalá-Munuera C. Machine learning to predict cardiovascular risk. *Int. J. Clin. Pract.* 2019; 73(10): e13389. doi: 10.1111/ijcp.13389.

20. Kakadiaris I.A., Vrigkas M., Yen A.A., Kuznetsova T., Budoff M., Naghavi M. Machine Learning Outperforms ACC / AHA CVD Risk Calculator in MESA. *J. Am. Heart. Assoc.* 2018; 7(22): e009476. doi: 10.1161/JAHA.118.009476.

21. Mehrabani-Zeinabad K., Feizi A., Sadeghi M., Roohafza H., Talaei M., Sarrafzadegan N. Cardiovascular disease incidence prediction by machine learning and statistical techniques: a 16-year cohort study from eastern Mediterranean region. *BMC. Med. Inform. Decis. Mak.* 2023; 23(1): 72. doi: 10.1186/s12911-023-02169-5.

22. Gavrillov D., Serova L., Korsakov I., Gusev A., Novitskij R.E., Kuznetsova T.Ju. Cardiovascular diseases prediction by integrated risk factors assessment by means of machine learning. *Vrach.* 2020; 31(5): 41–46. doi: 10.29296/25877305-2020-08. (In Russian)

23. Tsarapatsani K., Sakellarios A.I., Pezoulas V.C., Tsakanikas V.D., Kleber M.E., Marz W., Michalis L.K., Fotiadis D.I. Machine Learning Models for Cardiovascular Disease Events Prediction. *Annu. Int. Conf. IEEE. Eng. Med. Biol. Soc.* 2022; 2022: 1066–1069. doi: 10.1109/EMBC48229.2022.9871121.

24. Nevzorova V.A., Brodskaya T.A., Shakhgeldyan K.I., Geltser B.I., Kosterin V.V., Priskeo 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): 34–42. doi: 10.15829/1728-8800-2022-2908. (In Russian)

25. Gola D., Erdmann J., Müller-Myhsok B., Schunkert H. Polygenic risk scores outperform machine learning methods in

predicting coronary artery disease status. *Genet. Epidemiol.* 2020; 44(2): 125–138. doi: 10.1002/gepi.22279.

26. Westerlund A.M., Hawe J.S., Heinig M., Schunkert H. Risk Prediction of Cardiovascular Events by Exploration of Molecular Data with Explainable Artificial Intelligence. *Int. J. Mol. Sci.* 2021; 22(19): 10291. doi: 10.3390/ijms221910291.

27. Steinfeldt J., Buerger T., Loock L., Kittner P., Ruyoga G., Zu Belzen J.U., Sasse S., Strangalies H., Christmann L., Hollmann N., Wolf B., Ference B., Deanfield J., Landmesser U., Eils R. Neural network-based integration of polygenic and clinical information: development and validation of a prediction model for 10-year risk of major adverse cardiac events in the UK Biobank cohort. *Lancet Digit Health.* 2022; 4(2): e84–e94. doi: 10.1016/S2589-7500(21)00249-1.

28. Rigdon J., Basu S. Machine learning with sparse nutrition data to improve cardiovascular mortality risk prediction in the USA using nationally randomly sampled data. *BMJ. Open.* 2019; 9(11): e032703. doi: 10.1136/bmjopen-2019-032703.

29. Gavrillov D.V., Kuznetsova T.YU., Druzhilov M.A., Korsakov I.N. Predicting the subclinical carotid atherosclerosis in overweight and obese patients using a machine learning model. *Russian Journal of Cardiology.* 2022; 27(4): 40–47. doi: 10.15829/1560-4071-2022-4871. (In Russian)

30. Sánchez-Cabo F., Rossello X., Fuster V., Benito F., Manzano J.P., Silla J.C., Fernández-Alvira J.M., Oliva B., Fernández-Friera L., López-Melgar B., Mendiguren J.M., Sanz J., Ordovás J.M., Andrés V., Fernández-Ortiz A., Bueno H., Ibáñez B., García-Ruiz J.M., Lara-Pezzi E. Machine Learning Improves Cardiovascular Risk Definition for Young, Asymptomatic Individuals. *J. Am. Coll. Cardiol.* 2020; 76(14): 1674–1685. doi: 10.1016/j.jacc.2020.08.017.

31. Fan J., Chen M., Luo J., Yang S., Shi J., Yao Q., Zhang X., Du S., Qu H., Cheng Y., Ma S., Zhang M., Xu X., Wang Q., Zhan S. The prediction of asymptomatic carotid atherosclerosis with electronic health records: a comparative study of six machine learning models. *BMC. Med. Inform. Decis. Mak.* 2021; 21(1): 115. doi: 10.1186/s12911-021-01480-3.

32. Poplin R., Varadarajan A.V., Blumer K., Liu Y., McConnell M.V., Corrado G.S., Peng L., Webster D.R. Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning. *Nat. Biomed. Eng.* 2018; 2(3): 158–164. doi: 10.1038/s41551-018-0195-0.

33. Kanegae H., Suzuki K., Fukatani K., Ito T., Harada N., Kario K. Highly precise risk prediction model for new-onset hypertension using artificial intelligence techniques. *J. Clin. Hypertens. (Greenwich).* 2020; 22(3): 445–450. doi: 10.1111/jch.13759.

34. Ye C., Fu T., Hao S., Zhang Y., Wang O., Jin B., Xia M., Liu M., Zhou X., Wu Q., Guo Y., Zhu C., Li Y.M., Culver D.S., Alfreds S.T., Stearns F., Sylvester K.G., Widen E., McElhinney D., Ling X. Prediction of Incident Hypertension Within the Next Year: Prospective Study Using Statewide Electronic Health Records and Machine Learning. *J. Med. Internet. Res.* 2018; 20(1): e22. doi: 10.2196/jmir.9268.

35. Sakr S., Elshawi R., Ahmed A., Qureshi W.T., Brawner C., Keteyian S., Blaha M.J., Al-Mallah M.H. Using machine learning on cardiorespiratory fitness data for predicting hypertension: The Henry Ford Exercise Testing (FIT) Project. *PLoS. One.* 2018; 13(4): e0195344. doi: 10.1371/journal.pone.0195344.

36. Huang S., Xu Y., Yue L., Wei S., Liu L., Gan X., Zhou S., Nie S. Evaluating the risk of hypertension using an artificial neural network method in rural residents over the age of 35 years in a Chinese area. *Hypertens. Res.* 2010; 33(7): 722–6. doi: 10.1038/hr.2010.73.

37. Held E., Cape J., Tintle N. Comparing machine learning and logistic regression methods for predicting hypertension using a combination of gene expression and next-generation sequencing data. *BMC. Proc.* 2016; 10(Suppl 7): 141–145. doi: 10.1186/s12919-016-0020-2.

38. Pei Z., Liu J., Liu M., Zhou W., Yan P., Wen S., Chen Y. Risk-Predicting Model for Incident of Essential Hypertension Based on Environmental and Genetic Factors with Support Vector Machine. *Interdiscip. Sci.* 2018; 10(1): 126–130. doi: 10.1007/s12539-017-0271-2.

39. Li C., Sun D., Liu J., Li M., Zhang B., Liu Y., Wang Z., Wen S., Zhou J. A Prediction Model of Essential Hypertension Based on Genetic and Environmental Risk Factors in Northern Han Chinese. *Int. J. Med. Sci.* 2019; 16(6): 793–799. doi: 10.7150/ijms.33967.

40. Myers K.D., Knowles J.W., Staszak D., Shapiro M.D., Howard W., Yadava M., Zuzick D., Williamson L., Shah N.H., Banda J.M., Leader J., Cromwell W.C., Trautman E., Murray M.F., Baum S.J., Myers S., Gidding S.S., Wilemon K., Rader D.J. Precision screening

for familial hypercholesterolaemia: a machine learning study applied to electronic health encounter data. *Lancet. Digit. Health.* 2019; 1(8): e393–e402. doi: 10.1016/S2589–7500(19)30150–5.

41. Zhang S., Tjortjij C., Zeng X., Qiao H., Buchan I., Keane J. Comparing data mining methods with logistic regression in childhood obesity prediction. *Inf Syst Front* 11, 449–460 (2009). doi:10.1007/s10796-009-9157-0

42. Dugan T.M., Mukhopadhyay S., Carroll A., Downs S. Machine Learning Techniques for Prediction of Early Childhood Obesity. *Appl. Clin. Inform.* 2015; 6(3): 506–20. doi: 10.4338/ACI-2015-03-RA-0036.

43. Hammond R., Athanasiadou R., Curado S., Aphinyanaphongs Y., Abrams C., Messito M.J., Gross R., Katzow M., Jay M., Razavian N., Elbel B. Predicting childhood obesity using electronic health records and publicly available data. *PLoS. One.* 2019; 14(4): e0215571. doi: 10.1371/journal.pone.0215571.

44. Shin H., Shim S., Oh S. Machine learning-based predictive model for prevention of metabolic syndrome. *PLoS. One.* 2023; 18(6): e0286635. doi: 10.1371/journal.pone.0286635.

45. Hosseini-Esfahani F., Alafchi B., Cheraghi Z., Doosti-Irani A., Mirmiran P., Khalili D., Azizi F. Using Machine Learning Techniques to Predict Factors Contributing to the Incidence of Metabolic Syndrome in Tehran: Cohort Study. *JMIR. Public. Health. Surveill.* 2021; 7(9): e27304. doi: 10.2196/27304.

46. Chelebaeva YU.A. Development of neural network model for signs determination of atrial fibrillation for subsystem of cardiorythmogram signals processing. *Journal Biomedical Radioelectronics.* 2021; 24(4): 97–106. doi: 10.18127/j15604136–202104–13. (In Russian)

47. Attia Z.I., Noseworthy P.A., Lopez-Jimenez F., Asirvatham S.J., Deshmukh A.J., Gersh B.J., Carter R.E., Yao X., Rabinstein A.A., Erickson B.J., Kapa S., Friedman P.A. An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction. *Lancet.* 2019; 394(10201): 861–867. doi: 10.1016/S0140–6736(19)31721–0.

48. Raghunath S., Pfeifer J.M., Ulloa-Cerna A.E., Nemani A., Carbonati T., Jing L., vanMaanen D.P., Hartzel D.N., Ruhl J.A., Lagerman B.F., Rocha D.B., Stoudt N.J., Schneider G., Johnson K.W., Zimmerman N., Leader J.B., Kirchner H.L., Griessenauer C.J., Hafez A., Good C.W., Fornwalt B.K., Haggerty C.M. Deep Neural Networks Can Predict New-Onset Atrial Fibrillation From the 12-Lead ECG and Help Identify Those at Risk of Atrial Fibrillation-Related Stroke. *Circulation.* 2021; 143(13): 1287–1298. doi: 10.1161/CIRCULATIONAHA.120.047829.

49. Yan B.P., Lai W.H.S., Chan C.K.Y., Chan S.C., Chan L.H., Lam K.M., Lau H.W., Ng C.M., Tai L.Y., Yip K.W., To O.T.L., Freedman B., Poh Y.C., Poh M.Z. Contact-Free Screening of Atrial Fibrillation by a Smartphone Using Facial Pulsatile Photoplethysmographic Signals. *J. Am. Heart. Assoc.* 2018; 7(8): e008585. doi: 10.1161/JAHA.118.008585.

50. Perez M.V., Mahaffey K.W., Hedlin H., Rumsfeld J.S., Garcia A., Ferris T., Balasubramanian V., Russo A.M., Rajmane A., Cheung L., Hung G., Lee J., Kowey P., Talati N., Nag D., Gummidipundi S.E., Beatty A., Hills M.T., Desai S., Granger C.B., Desai M., Turakhia M.P.; Apple Heart Study Investigators. Large-Scale Assessment of a Smartwatch to Identify Atrial Fibrillation. *N. Engl. J. Med.* 2019; 381(20): 1909–1917. doi: 10.1056/NEJMoa1901183.

51. Guo Y., Wang H., Zhang H., Liu T., Liang Z., Xia Y., Yan L., Xing Y., Shi H., Li S., Liu Y., Liu F., Feng M., Chen Y., Lip G.Y.H.; MAFA II Investigators. Mobile Photoplethysmographic Technology to Detect Atrial Fibrillation. *J. Am. Coll. Cardiol.* 2019; 74(19): 2365–2375. doi: 10.1016/j.jacc.2019.08.019.

52. Ramesh J., Solatidehkordi Z., Aburukba R., Sagahyoon A. Atrial Fibrillation Classification with Smart Wearables Using Short-

Term Heart Rate Variability and Deep Convolutional Neural Networks. *Sensors. (Basel).* 2021; 21(21): 7233. doi: 10.3390/s21217233.

53. Sager S., Bernhardt F., Kehrle F., Merkert M., Potschka A., Meder B., Katus H., Scholz E. Expert-enhanced machine learning for cardiac arrhythmia classification. *PLoS. One.* 2021; 16(12): e0261571. doi: 10.1371/journal.pone.0261571.

54. Yao X., Rushlow D.R., Inselman J.W., McCoy R.G., Thacher T.D., Behnken E.M., Bernard M.E., Rosas S.L., Akfaly A., Misra A., Molling P.E., Krien J.S., Foss R.M., Barry B.A., Siontis K.C., Kapa S., Pellicka P.A., Lopez-Jimenez F., Attia Z.I., Shah N.D., Friedman P.A., Noseworthy P.A. Artificial intelligence-enabled electrocardiograms for identification of patients with low ejection fraction: a pragmatic, randomized clinical trial. *Nat. Med.* 2021; 27(5): 815–819. doi: 10.1038/s41591–021–01335–4.

55. Potter E.L., Rodrigues C.H.M., Ascher D.B., Abhayaratna W.P., Sengupta P.P., Marwick T.H. Machine Learning of ECG Waveforms to Improve Selection for Testing for Asymptomatic Left Ventricular Dysfunction. *JACC. Cardiovasc. Imaging.* 2021; 14(10): 1904–1915. doi: 10.1016/j.jcmg.2021.04.020.

56. Bos J.M., Attia Z.I., Albert D.E., Noseworthy P.A., Friedman P.A., Ackerman M.J. Use of Artificial Intelligence and Deep Neural Networks in Evaluation of Patients With Electrocardiographically Concealed Long QT Syndrome From the Surface 12-Lead Electrocardiogram. *JAMA. Cardiol.* 2021; 6(5): 532–538. doi: 10.1001/jamacardio.2020.7422.

57. Nakamura T., Nagata Y., Nitta G., Okata S., Nagase M., Mitsui K., Watanabe K., Miyazaki R., Kaneko M., Nagamine S., Hara N., Lee T., Nozato T., Ashikaga T., Goya M., Sasano T. Prediction of premature ventricular complex origins using artificial intelligence-enabled algorithms. *Cardiovasc. Digit. Health. J.* 2021; 2(1): 76–83. doi: 10.1016/j.cvdhj.2020.11.006.

58. Ko W.Y., Siontis K.C., Attia Z.I., Carter R.E., Kapa S., Ommen S.R., Demuth S.J., Ackerman M.J., Gersh B.J., Arruda-Olson A.M., Geske J.B., Asirvatham S.J., Lopez-Jimenez F., Nishimura R.A., Friedman P.A., Noseworthy P.A. Detection of Hypertrophic Cardiomyopathy Using a Convolutional Neural Network-Enabled Electrocardiogram. *J. Am. Coll. Cardiol.* 2020; 75(7): 722–733. doi: 10.1016/j.jacc.2019.12.030.

59. Attia Z.I., DeSimone C.V., Dillon J.J., Sapir Y., Somers V.K., Dugan J.L., Bruce C.J., Ackerman M.J., Asirvatham S.J., Striemer B.L., Bukartyk J., Scott C.G., Bennet K.E., Ladewig D.J., Gilles E.J., Sadot D., Geva A.B., Friedman P.A. Novel Bloodless Potassium Determination Using a Signal-Processed Single-Lead ECG. *J. Am. Heart. Assoc.* 2016; 5(1): e002746. doi: 10.1161/JAHA.115.002746.

60. Attia Z.I., Friedman P.A., Noseworthy P.A., Lopez-Jimenez F., Ladewig D.J., Satam G., Pellicka P.A., Munger T.M., Asirvatham S.J., Scott C.G., Carter R.E., Kapa S. Age and Sex Estimation Using Artificial Intelligence From Standard 12-Lead ECGs. *Circ. Arrhythm. Electrophysiol.* 2019; 12(9): e007284. doi: 10.1161/CIRCEP.119.007284.

61. Baek Y.S., Lee D.H., Jo Y., Lee S.C., Choi W., Kim D.H. Artificial intelligence-estimated biological heart age using a 12-lead electrocardiogram predicts mortality and cardiovascular outcomes. *Front. Cardiovasc. Med.* 2023; 10: 1137892. doi: 10.3389/fcvm.2023.1137892.

62. Rapakov G.G., Bانشchikov G.T., Gorbunov V.A., Udaratin A.V. Using machine learning methods for the correction of behavioral risk factors for prevention of cardiovascular diseases. *Cherepovets State University Bulletin.* 2020; 4 (97): 54–68. doi: 10.23859/1994–0637–2020–4–97–5. (In Russian)

63. Weber I., Achananuparp P. Insights from machine-learned diet success prediction. *Pac. Symp. Biocomput.* 2016; 21: 540–51.

64. Lektorsky V.A., Vassilyev S.N., Makarov V.L., Khabrieva T.Y., et al. Chelovek i sistemy' iskusstvennogo intellekta / Ed. acad. RAS V.A. Lektorsky. Saint Petersburg: Izdatel'stvo «Yuridicheskij tsentr»; 2022. 328 c. (In Russian). ISBN: 978-5-94201-835-1.

Для цитирования: Кавешников В.С., Брагин Д.С., Ваизов В.Х., Кавешников А.В., Кузьмичкина М.А., Трубачева И.А. Возможности применения технологий машинного обучения в сфере первичной профилактики сердечно-сосудистых заболеваний. *Комплексные проблемы сердечно-сосудистых заболеваний.* 2023;12(3): 109–125. DOI: 10.17802/2306-1278-2023-12-3-109-125

To cite: Kaveshnikov V.S., Bragin D.S., Vaizov V.Kh., Kaveshnikov A.V., Kuzmichkina M.A., Trubacheva I.A. Possibilities of applying machine learning technologies in the sphere of primary prevention of cardiovascular diseases. *Complex Issues of Cardiovascular Diseases.* 2023;12(3): 109–125. DOI: 10.17802/2306-1278-2023-12-3-109-125