

¹ Российская медицинская академия непрерывного профессионального образования, Москва

² Клинико-диагностический центр № 4 Департамента здравоохранения города Москвы

Персонализированная оценка сердечно-сосудистого риска на основе методов машинного обучения у пациентов пожилого и старческого возраста с артериальной гипертензией: ретроспективное исследование (первый этап)

А.С. Рязанов, д.м.н., проф.¹, И.М. Хапохов^{1, 2}, М.В. Макаровская, к.м.н.^{1, 2}, И.А. Гордеева^{1, 2}, Н.А. Анисимов^{1, 2}

Адрес для переписки: Мария Владимировна Макаровская, marja.makarovska@mail.ru

Для цитирования: Рязанов А.С., Хапохов И.М., Макаровская М.В. и др. Персонализированная оценка сердечно-сосудистого риска на основе методов машинного обучения у пациентов пожилого и старческого возраста с артериальной гипертензией: ретроспективное исследование (первый этап). Эффективная фармакотерапия. 2026; 22 (11): 24–33.

DOI 10.33978/2307-3586-2026-22-11-24-33

Цель. Разработка и первичная оценка прогностической модели тотального сердечно-сосудистого риска у амбулаторных пациентов пожилого и старческого возраста с артериальной гипертензией на основе методов машинного обучения.

Материал и методы. Исследование выполнено в дизайне «ретроспективная когорта – проспективное наблюдение» и состояло из двух этапов. На первом (ретроспективном) этапе в анализ включены 1028 пациентов (527 женщин, 501 мужчина) в возрасте от 60 до 90 лет (медиана 72 года) с артериальной гипертензией. Критерии исключения: инфаркт миокарда, инсульт, операции на сосудах и сердце, хроническая сердечная недостаточность в анамнезе, тяжелые сопутствующие заболевания. Первичная конечная точка включала смерть от сердечно-сосудистых причин, нефатальный инфаркт миокарда, нефатальный инсульт, реваскуляризацию миокарда и госпитализацию по поводу декомпенсации сердечной недостаточности. Для построения прогностической модели использована многофакторная логистическая регрессия. Дискриминационная способность модели оценена с помощью ROC-анализа. На втором (проспективном) этапе проведен набор независимой когорты ($n = 300$) для последующей внешней валидации модели.

Результаты. За период наблюдения (медиана 328 дней) первичные конечные точки зарегистрированы у 186 пациентов (18,1%). Построенная модель логистической регрессии продемонстрировала хорошую дискриминационную способность: площадь под ROC-кривой (AUC) 0,791 (95% доверительный интервал (ДИ) 0,721–0,862). Независимыми предикторами развития сердечно-сосудистых событий выступили: наличие аритмий (отношение шансов (ОШ) 1,75; 95% ДИ 1,24–2,48; $p = 0,002$), уровень гликированного гемоглобина ($p < 0,001$), холестерина липопротеидов низкой плотности ($p = 0,022$), триглицеридов ($p < 0,001$), систолического артериального давления ($p < 0,001$), а также факт приема антигипертензивной терапии ($p = 0,071$, включен для клинической значимости). При оптимальном пороге отсечения чувствительность модели составила 87,5%, специфичность – 57,2%, отрицательная прогностическая ценность – 95,4%.

Заключение. Разработанная прогностическая модель обладает хорошей дискриминационной способностью и высокой отрицательной прогностической ценностью, что позволяет использовать ее для исключения высокого риска сердечно-сосудистых событий у пожилых пациентов с артериальной гипертензией в амбулаторной практике. Для подтверждения применимости результатов в реальной клинической практике необходима внешняя валидация модели на независимой проспективной когорте (второй этап исследования).

Ключевые слова: искусственный интеллект, машинное обучение, логистическая регрессия, прогностическая модель, сердечно-сосудистый риск, артериальная гипертензия, пожилой возраст



Введение

Сердечно-сосудистые заболевания представляют собой глобальную проблему здравоохранения, являясь основной причиной инвалидизации и смертности населения [1]. Современная кардиология характеризуется экспоненциальным ростом объема и сложности данных, получаемых из электронных медицинских карт (ЭМК), результатов визуализации, геномных исследований и носимых устройств [2]. Традиционные методы анализа зачастую не справляются с обработкой таких массивов информации, что создает предпосылки для внедрения технологий искусственного интеллекта (ИИ).

Исторически кардиология была одной из самых технологически ориентированных медицинских дисциплин, начиная с изобретения электрокардиографии в конце XIX в. [3]. Эта открытость к инновациям подготовила почву для новой эры – эры прецизионной кардиологии, где решения основываются на данных. ИИ, и в частности машинное обучение (МО), предлагает инструменты для автоматизации рутинных задач, выявления сложных, неочевидных для человеческого восприятия паттернов и создания точных прогностических моделей [4]. Без когнитивных вычислений кардиология сталкивается с практическими проблемами, связанными с избыточным использованием ресурсов и неадекватной помощью пациентам, что влияет на показатели повторной госпитализации и смертности [5].

Цель данной работы – разработка и первичная оценка прогностической модели тотального сердечно-сосудистого риска у амбулаторных пациентов пожилого и старческого возраста с артериальной гипертензией (АГ) на основе методов машинного обучения.

Основные технологии искусственного интеллекта

Для корректного понимания терминов отметим, что понятия «искусственный интеллект», «машинное обучение» и «глубокое обучение» часто используются как синонимы, но они образуют иерархическую структуру [3, 6].

Искусственный интеллект и машинное обучение

ИИ – это общая концепция, обозначающая способность машин выполнять задачи, требующие человеческого интеллекта: распознавание образов, принятие решений и решение проблем [7]. МО – это подраздел ИИ, который использует статистические методы, позволяющие компьютерам «учиться» на данных, выявлять в них закономерности и принимать решения без явного программирования на выполнение конкретной задачи [3, 8]. Основные направления технологий ИИ, включая типы МО, представлены на рис. 1.

Можно выделить три основных типа обучения.

1. Обучение с учителем (Supervised Learning). Применяется для классификации и регрессии на размеченных данных. Пример – диагностика инфаркта миокарда по электрокардиограмме (ЭКГ) [9].

2. Обучение без учителя (Unsupervised Learning). Выявляет скрытые структуры в данных без меток. Используется для открытия новых фенотипов заболеваний, например, стратификации пациентов с сердечной недостаточностью с сохраненной фракцией выброса [10].

3. Обучение с подкреплением (Reinforcement Learning). Модель учится методом проб и ошибок, получая «вознаграждение» за правильные действия. Перспективно для подбора оптимальной лекарственной терапии [11].

Глубокое обучение

Глубокое обучение (ГО) является подразделом МО, основанным на использовании искусственных нейронных сетей со множеством слоев (отсюда и «глубокое»), которые имитируют работу человеческого мозга [12]. Благодаря развитию вычислительных мощностей и доступности больших данных ГО стало двигателем современных прорывов в развитии ИИ [3]. Его ключевые преимущества – возможность работать с необработанными данными (например, пикселями изображения) и высокая точность в задачах распознавания образов.

Сверточные нейронные сети (Convolutional Neural Networks, CNN) – это класс алгоритмов ГО, оптимизированный для анализа визуальных образов. Они нашли широкое применение в интерпретации эхокардиограмм, ангиограмм, компьютерных томограмм и других видов медицинской визуализации [13, 14].

Несмотря на мощь, ГО не является универсальным средством в решении сложных задач. Для хорошо структурированных данных традиционные алгоритмы МО, такие как логистическая регрессия или случайные леса, могут быть более эффективными и менее требовательными к ресурсам [15]. Главным вызовом остается «черный ящик» – сложность интерпретации решений, принимаемых многослойными нейронными сетями [16].

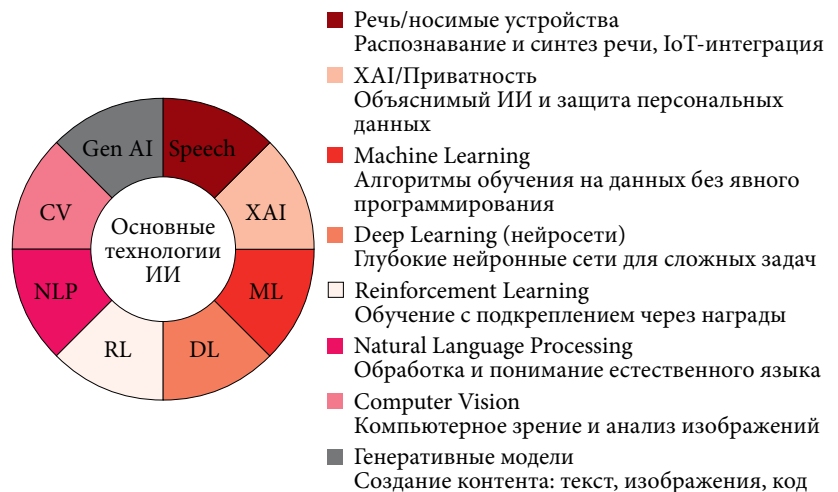


Рис. 1. Технологии искусственного интеллекта



Обработка естественного языка и когнитивные вычисления
Обработка естественного языка (Natural Language Processing, NLP) позволяет машинам понимать и генерировать речь. В кардиологии NLP извлекает структурированную информацию из текстов ЭМК (врачебные записи, протоколы), обогащая данные для моделей МО [17]. NLP успешно применяется для выявления аневризм из радиологических отчетов и оценки качества помощи при сердечной недостаточности [18, 19].

Когнитивные вычисления – более широкая концепция, описывающая ИИ-системы, синтезирующие информацию из разных источников. Пример – IBM Watson, помогающий в диагностике и выборе лечения [5, 20].

Клиническое применение искусственного интеллекта в кардиологии

Анализ электрокардиограммы

Электрокардиография – краеугольный камень диагностики в кардиологии, а анализ ЭКГ стал одной из самых развитых областей применения ИИ.

В своем исследовании 2025 г. A.I. Reshad и соавт. показали, что алгоритм глубокого обучения может обнаруживать и классифицировать широкий спектр аритмий (в первую очередь фибрилляции предсердий) по данным амбулаторных ЭКГ с точностью, не уступающей кардиологам-экспертам [21]. А врачи из Стэнфордского университета и программисты компании iRhythm разработали 34-слойную сверточную нейросеть (CNN), которая превзошла кардиологов по точности и полноте распознавания ЭКГ [22]. В скрининге бессимптомной дисфункции миокарда прорывным направлением является использование ИИ для выявления скрытых патологий. Модели, анализируя стандартную 12-канальную ЭКГ, демонстрируют способность предсказывать бессимптомную дисфункцию левого желудочка [23], фибрилляцию предсердий во время синусового ритма [24] и другие состояния, что открывает возможности для популяционного скрининга.

Интеграция алгоритмов МО в носимые устройства, такие как Apple Watch и AliveCor KardiaMobile, позволяет осуществлять непрерывный мониторинг ЭКГ и автоматическое выявление фибрилляции предсердий в реальном времени, перенося точку оказания помощи из клиники в дом пациента [25].

Визуализация сердца

Визуализация – это область, где ИИ демонстрирует особо впечатляющие результаты, автоматизируя трудоемкие процессы измерения и снижая субъективность интерпретации. Алгоритмы искусственного интеллекта способны автоматически определять границы камер сердца, рассчитывать фракцию выброса левого желудочка, его объемы и оценивать деформацию миокарда (strain).

В исследовании G. Holste и соавт. (2025) когнитивная вычислительная система успешно выполнила 18 задач диагностической классификации с медианой

AUC 0,91 (0,88–0,93) и оценила 21 эхокардиографический параметр со средней нормализованной абсолютной ошибкой 0,13 (0,10–0,18) при внутренней валидации [26, 27]. C.D. Reddy и соавт. (2023) в исследовании, включавшем более 4467 эхокардиограмм, представили EchoNet-Peds, алгоритм глубокого обучения на основе видеоданных, который соответствует уровню экспертной оценки функции левого желудочка и фракции выброса у детей [28].

ИИ революционизирует анализ коронарного кальция и компьютерной томографии – ангиографии. Алгоритмы позволяют автоматически количественно определять кальциевый индекс, оценивать характеристики атеросклеротических бляшек (включая «уязвимые») и бесконтактно оценивать фракционный резерв кровотока (Fractional Flow Reserve from Anatomic CT, FFR-CT) [29, 30]. Модели ГО демонстрируют высокую точность в диагностике обструктивного поражения коронарных артерий [31].

В магнитно-резонансной томографии сердца ИИ применяют для автоматической сегментации камер сердца, количественной оценки функции правого желудочка, выявления фиброза миокарда и характеристики тканей при различных заболеваниях [32].

Предиктивная аналитика и поддержка клинических решений
Одной из самых значимых перспектив ИИ является переход от реактивной к проактивной, предиктивной медицине. Алгоритмы МО, анализируя данные ЭМК, визуализации и результаты лабораторных исследований, создают более точные модели индивидуального риска развития инфаркта, инсульта или смерти, чем традиционные шкалы (например, SCORE, Framingham Risk Score), которые учитывают лишь ограниченный набор факторов [33, 34]. В исследовании A.J. Steele и соавт. (2018) показано, что модель МО превзошла стандартные прогностические модели в предсказании смертности пациентов с ишемической болезнью сердца (ИБС) [35]. В отделениях реанимации и неотложной помощи модели ИИ в режиме реального времени анализируют поток данных для прогнозирования клинического ухудшения, например, развития кардиогенного шока, острого повреждения почек или сепсиса [36].

В интервенционной кардиологии алгоритмы помогают при планировании чрескожных коронарных вмешательств и транскатетерных процедур (например, транскатетерной имплантации аортального клапана – Transcatheter Aortic Valve Implantation, TAVI). В исследовании CEREBRIA-1 продемонстрировано, что алгоритм МО не уступал команде интервенционных кардиологов в принятии решений о стратегии реваскуляризации на основе данных о коронарном кровотоке [37].

Персонализированная (прецизионная) кардиология

ИИ позволяет перейти от подхода «один размер для всех» к полноценному персонализированному



лечению. Путем интегрирования геномных, протеомных, метаболомных данных и данных ЭМК алгоритмы МО могут идентифицировать уникальные подтипы заболеваний (фенотипы) с различными патогенетическими механизмами и ответом на терапию [10, 38]. Это открывает путь к разработке целевых методов лечения для конкретных подгрупп пациентов, например, с определенным молекулярным профилем сердечной недостаточности или легочной гипертензии [5].

В качестве практической реализации принципов предиктивной аналитики нами проведена разработка и первичная валидация прогностической модели тотальных сердечно-сосудистых событий (ССС) для амбулаторных пациентов пожилого и старческого возраста с АГ.

Материал и методы

Дизайн исследования

Исследование выполнено в дизайне «ретроспективная когорта – проспективное наблюдение» и состояло из двух последовательных этапов.

1. Ретроспективный этап (разработка модели) – период с 01.01.2021 по 01.01.2023 г. На данном этапе сформирована обучающая выборка из 1028 пациентов, проведен анализ предикторов и построена прогностическая модель.

2. Проспективный этап (валидация модели) – период с 02.01.2023 по 31.12.2025 г. На данном этапе произведен набор независимой контрольной когорты из 300 пациентов для последующей внешней валидации разработанной модели. Результаты валидации планируется опубликовать отдельно.

Критерии включения:

- установленный диагноз АГ любой степени тяжести;
- возраст от 60 до 90 лет (пожилой и старческий возраст);
- наличие полных клинических, лабораторных и инструментальных данных за период наблюдения;
- подписанное информированное согласие на участие в исследовании (для проспективной фазы).

Критерии исключения:

- инфаркт миокарда, острое нарушение мозгового кровообращения, операции на сосудах и сердце в анамнезе;
- хроническая сердечная недостаточность в анамнезе;
- тяжелые сопутствующие заболевания (онкологические заболевания в активной фазе, декомпенсированные заболевания печени и почек, терминальная почечная недостаточность);
- отказ от участия в исследовании.

Конечные точки (исходы). Первичной конечной точкой являлась комбинация следующих ССС, наступивших в период наблюдения:

- смерть от сердечно-сосудистых причин;
- нефатальный инфаркт миокарда;
- нефатальное острое нарушение мозгового кровообращения (инсульт);
- реваскуляризация миокарда (стентирование или коронарное шунтирование);

- госпитализация по поводу декомпенсации хронической сердечной недостаточности.

Регистрация событий проводилась на основании данных электронных медицинских карт, выписных эпикризов и результатов инструментальных исследований. Вторичные конечные точки в рамках данного анализа не оценивались.

Статистический анализ


Статистический анализ проводился с использованием программы StatTech v. 4.12.5 (ООО «Статтех», Россия). Количественные показатели оценивались на предмет соответствия нормальному распределению с помощью критерия Шапиро – Уилка (при числе исследуемых менее 50) или критерия Колмогорова – Смирнова (при числе исследуемых более 50). В случае отсутствия нормального распределения количественные данные описывались с помощью медианы (Me) и нижнего и верхнего квартилей (Q_1 – Q_3). Категориальные данные описывались с указанием абсолютных значений и процентных долей. 95% доверительные интервалы (ДИ) для процентных долей рассчитывались по методу Клоппера – Пирсона. Сравнение двух групп по количественному показателю, распределение которого отличалось от нормального, при условии равенства дисперсий выполнялось с помощью U-критерия Манна – Уитни. Сравнение двух групп по количественному показателю, распределение которого отличалось от нормального, при отсутствии равенства дисперсий выполнялось с помощью W-критерия Бруннера – Мюнцеля. Сравнение процентных долей при анализе четырехпольных таблиц сопряженности выполнялось с помощью критерия хи-квадрат Пирсона (при значениях ожидаемого явления более 10).

Для построения прогностической модели вероятности развития ССС использован метод многофакторной логистической регрессии с пошаговым включением переменных (метод Вальда). В модель включались переменные, показавшие статистически значимые различия при однофакторном анализе ($p < 0,10$). Мерой определенности, указывающей на ту часть дисперсии, которая может быть объяснена с помощью логистической регрессии, служил коэффициент R^2 Найджелкерка. Дискриминационная способность модели (способность различать пациентов с наступлением и без наступления исхода) оценена с помощью ROC-анализа с расчетом площади под ROC-кривой (AUC) и 95% ДИ. Различия считались статистически значимыми при $p < 0,05$.

Результаты

Характеристика пациентов (ретроспективная когорта)

Общие характеристики всей когорты 1028 пациентов представлены в табл. 1. Пациенты, у которых за период наблюдения развились исследуемые исходы ($n = 186$ (18,1%)), были старше и имели более



выраженные кардиометаболические нарушения по сравнению с группой без исходов (табл. 2).

1. Демография и антропометрия. Медиана возраста в общей когорте составила 72 (66; 80) лет (табл. 1), при этом в группе с исходами пациенты

были достоверно старше (74,5 (67; 81) года против 72 (66; 80) лет; $p = 0,028$). В группе с исходами была выше доля мужчин (57,5% против 46,8%; $p = 0,008$; относительный риск (ОР) для женщин 0,649; 95% ДИ 0,471–0,895). Артериальное давление (АД) превышало целевые уровни, особенно в группе с исходами: систолическое АД (САД) – 150 (136; 162) мм рт. ст. против 140 (130; 151) мм рт. ст., $p < 0,001$; диастолическое АД (ДАД) – 90 (85; 94) мм рт. ст. против 85 (78; 91) мм рт. ст., $p < 0,001$. Индекс массы тела (ИМТ) был выше у пациентов с исходами (28,6 (25,52; 32,00) кг/м² против 27,2 (24,80; 29,77) кг/м²; $p < 0,001$) (табл. 2).

2. Биохимические показатели. У пациентов с исходами отмечался более неблагоприятный липидный профиль: выше уровни общего холестерина (ОХС) (5,50 (4,62; 6,40) против 5,10 (4,50; 5,80) ммоль/л; $p < 0,001$), холестерина липопротеидов низкой плотности (ХС ЛНП) (3,40 (2,40; 4,10) против 3,10 (2,40; 3,70) ммоль/л; $p = 0,022$), триглицеридов (ТГ) (1,70 (1,50; 1,90) против 1,50 (1,30; 1,70) ммоль/л; $p < 0,001$) и ниже уровень холестерина липопротеидов высокой плотности (ХС ЛВП) (1,00 (0,80; 1,20) против 1,10 (0,90; 1,20) ммоль/л; $p = 0,007$). Сахарный диабет 2 типа (СД 2) у таких пациентов встречался чаще (35,5% против 22,8%; $p < 0,001$; ОР 1,862; 95% ДИ 1,324–2,618), как и уровень гликированного гемоглобина (HbA1c) (8,00 (7,40; 8,60)% против 7,50 (7,05; 8,00)%; $p < 0,001$). Медиана уровня С-реактивного белка (СРБ) также была выше (4,55 (2,92; 6,78) мг/л против 3,80 (2,70; 5,50) мг/л; $p = 0,001$) (табл. 2).

3. Коморбидность и терапия. Среди пациентов с исходами чаще регистрировались аритмии (32,3% против 21,4%; $p = 0,002$; ОШ 1,751; 95% ДИ 1,236–2,482) и атеросклероз периферических артерий (93,5% против 84,7%; $p = 0,001$; ОШ 2,623; 95% ДИ 1,419–4,849). В группе с исходами доля пациентов, получавших статины, была достоверно ниже (54,3% против 63,8%; $p = 0,016$). Различия частоты курения, хронической болезни почек и приема антигипертензивной терапии между группами были статистически незначимы. Медиана времени до наступления исхода составила 327,5 (172,3; 478,8) дня (табл. 2).

Интерпретация полученных данных

В построенной модели логистической регрессии независимыми предикторами наступления исхода стали наличие аритмий, уровень HbA1c, ХС ЛНП, ТГ и САД, а также факт приема антигипертензивной терапии; модель была статистически значимой ($p < 0,001$), объясняла 33,3% дисперсии (псевдо- R^2 Найджелкерка) и продемонстрировала хорошую дискриминационную способность (AUC 0,791; 95% ДИ 0,721–0,862). На рис. 2 представлена ROC-кривая, иллюстрирующая соотношение чувствительности и специфичности модели при различных порогах отсечения. При оптимальном пороге отсечения 0,214 чувствительность составила 87,5%, специфичность – 57,2%. Это означает, что модель с вероятностью около 79% правильно ранжирует пары

Таблица 1. Общая характеристика пациентов

Показатели	Me	Q ₁ –Q ₃	min	max	n
Возраст, лет	72,00	66,00–80,00	57,00	96,00	1028
САД, мм рт. ст.	141,00	131,00–154,00	96,00	190,00	1028
ДАД, мм рт. ст.	86,00	79,00–92,00	57,00	112,00	1028
ИМТ, кг/м ²	27,30	25,00–30,40	16,30	44,40	1028
ХС ЛНП, ммоль/л	3,20	2,40–3,80	1,10	7,70	1028
ХС ЛВП, ммоль/л	1,10	0,90–1,20	0,50	9,00	1028
ОХС, ммоль/л	5,20	4,50–5,90	2,20	9,30	1028
ТГ, ммоль/л	1,50	1,30–1,80	0,80	4,30	1028
HbA1c, %	7,60	7,10–8,20	5,90	9,50	251
СРБ, мг/л	3,90	2,70–5,90	0,40	84,00	1028
Пульсовое давление, мм рт. ст.	56,00	47,00–62,00	18,00	101,00	1028
Время до события, дней	328,00	173,00–481,00	36,00	678,00	185

Таблица 2. Сравнительный анализ характеристик пациентов в зависимости от наступления исхода

Показатель	Группа с исходом, n = 186	Группа без исхода, n = 842	p
<i>Количественные показатели, Me (IQR)</i>			
Возраст, лет	74,5 (67,0; 81,0)	72,0 (66,0; 80,0)	0,028
Систолическое АД, мм рт. ст.	150,0 (136,0; 162,0)	140,0 (130,0; 151,0)	< 0,001
Диастолическое АД, мм рт. ст.	90,0 (85,0; 94,0)	85,0 (78,0; 91,0)	< 0,001
Индекс массы тела, кг/м ²	28,6 (25,5; 32,0)	27,2 (24,8; 29,8)	< 0,001
Общий холестерин, ммоль/л	5,5 (4,6; 6,4)	5,1 (4,5; 5,8)	< 0,001
ХС ЛНП, ммоль/л	3,4 (2,4; 4,1)	3,1 (2,4; 3,7)	0,022
ХС ЛВП, ммоль/л	1,0 (0,8; 1,2)	1,1 (0,9; 1,2)	0,007
ТГ, ммоль/л	1,7 (1,5; 1,9)	1,5 (1,3; 1,7)	< 0,001
HbA1c, %*	8,0 (7,4; 8,6)	7,5 (7,1; 8,0)	< 0,001
СРБ, мг/л	4,6 (2,9; 6,8)	3,8 (2,7; 5,5)	0,001
Время до события, дней**	327,5 (172,3; 478,8)	–	–
<i>Категориальные показатели, n (%)</i>			
Мужской пол	107 (57,5)	394 (46,8)	0,008
СД 2	66 (35,5)	192 (22,8)	< 0,001
Аритмии	60 (32,3)	180 (21,4)	0,002
Атеросклероз периферических артерий	174 (93,5)	713 (84,7)	0,001
Курение	70 (37,6)	264 (31,4)	0,098
Хроническая болезнь почек	91 (48,9)	367 (43,6)	0,185
Антигипертензивная терапия	159 (85,5)	758 (90,0)	0,071
Терапия статинами	101 (54,3)	537 (63,8)	0,016

* Данные по HbA1c приведены для пациентов с СД, n = 251.

** Рассчитано только для группы с наступившим исходом, n = 186.

Примечание. Данные представлены в виде медианы и интерквартильного размаха (Me (IQR)) для количественных показателей и абсолютного числа (процента) для категориальных. Статистически значимые различия ($p < 0,05$) выделены полужирным шрифтом. Для категориальных переменных со значимыми различиями в тексте приведены значения отношения шансов с 95% доверительным интервалом.



пациентов «с событием» и «без события», что признается хорошим показателем для клинических прогностических моделей.

Сравнение с традиционными шкалами риска

Традиционные шкалы (SCORE, Framingham Risk Score) имеют ряд ограничений при применении к пожилым пациентам с АГ: они учитывают ограниченный набор факторов, не включают такие важные предикторы, как уровень триглицеридов, HbA1c, наличие аритмий, и хуже калиброваны для возрастной группы старше 70 лет. В нашем исследовании традиционные шкалы не применялись, однако, по данным литературы, их AUC для аналогичных когорт обычно не превышает 0,70–0,75 [5, 33, 34]. Таким образом, разработанная модель потенциально превосходит традиционные подходы, что требует подтверждения в прямом сравнительном исследовании.

Анализ выявленных предикторов

Все шесть независимых предикторов, вошедших в финальную модель, имеют убедительное патофизиологическое обоснование и согласуются с данными литературы.

1. Уровень САД. В нашей когорте медиана САД в группе с исходами составила 150 мм рт. ст. против 140 мм рт. ст. в группе без исходов ($p < 0,001$). Это подтверждает фундаментальное положение о том, что даже умеренное повышение АД у пожилых пациентов сохраняет прогностическое значение, несмотря на проводимую терапию. Обращает на себя внимание, что у 85,5% пациентов с исходами АД не достигло целевых уровней (менее 130/80 мм рт. ст. согласно современным рекомендациям), что указывает на проблему резистентной АГ и недостаточной эффективности стандартных схем лечения в этой возрастной группе.

2. Липидный профиль (ХС ЛНП, ТГ). Повышение уровня ХС ЛНП и ТГ традиционно ассоциируется с прогрессированием атеросклероза. В нашем исследовании медиана ХС ЛНП в группе с исходами составила 3,4 ммоль/л, что превышает целевые уровни для пациентов высокого риска ($< 1,8$ ммоль/л). Парадоксально, но доля пациентов, получавших статины, в группе с исходами была даже ниже (54,3% против 63,8%; $p = 0,016$). Это может указывать как на недостаточную приверженность терапии, так и на неадекватные дозы препаратов.

3. Гликированный гемоглобин (HbA1c). У пациентов с СД 2 уровень HbA1c $> 7,5\%$ ассоциировался с достоверно более высоким риском событий. СД 2 встречался в группе с исходами в 1,86 раза чаще (35,5% против 22,8%; ОШ 1,86; 95% ДИ 1,32–2,62). Это подчеркивает необходимость более строгого контроля гликемии у пожилых пациентов с АГ и СД 2, что согласуется с современными подходами к управлению кардиометаболическими рисками.

4. Наличие аритмий. Аритмии (преимущественно фибрилляция предсердий и частая экстрасистолия) увеличивали риск событий в 1,75 раза (ОШ 1,75; 95%




Рис. 2. ROC-кривая прогностической модели сердечно-сосудистого риска

ДИ 1,24–2,48). Этот фактор часто недооценивается при рутинной стратификации риска, однако наш анализ подтверждает его самостоятельную прогностическую значимость, что согласуется с результатами крупных регистров [24].

5. Антигипертензивная терапия. Включение этого фактора в модель, несмотря на пограничную статистическую значимость ($p = 0,071$), обусловлено клиническими соображениями. Отсутствие выраженного «защитного» эффекта терапии в нашей когорте может объясняться тем, что большинство пациентов с исходами (85,5%) не достигли целевых уровней АД, то есть сам факт приема препаратов не гарантирует эффективного контроля. Это важный клинический сигнал: необходим не просто прием антигипертензивных средств, а достижение целевых показателей АД.

Клиническая значимость модели

Высокая отрицательная прогностическая ценность (95,4%) при оптимальном пороге отсечения означает, что модель надежно выявляет пациентов с низким риском событий. Это особенно важно для первичного звена: врачи могут с уверенностью исключать развитие событий в ближайший год у пациентов с низким расчетным риском, фокусируя ресурсы на группе высокого риска. Напротив, относительно низкая положительная прогностическая ценность (31,5%) указывает на то, что лишь каждый третий пациент, отнесенный моделью в группу высокого риска, действительно реализует событие. Это не является недостатком модели, а отражает объективную сложность прогнозирования ССС в пожилой популяции с высокой коморбидностью.

Обсуждение

Результаты нашего исследования согласуются с данными систематического обзора С. Krittanawong и соавт. (2020), который показал, что в моделях МО AUC при прогнозировании ССС находится в диапазоне 0,8–0,9 [5]. Наша модель с AUC 0,791 обладает



умеренной прогностической способностью, что подтверждает ее конкурентоспособность.

В работе A.J. Steele и соавт. (2018) было продемонстрировано, что модели МО на основе данных ЭМК превосходят традиционные регрессионные модели Кокса в предсказании смертности пациентов с ИБС [35]. Авторы использовали случайный лес и градиентный бустинг, достигнув значения AUC, равного 0,85.

Среди работ российских ученых наиболее близким по тематике является систематический обзор М.Н. Ковельковой и Е.Г. Яковлевой (2025), в котором показано, что в отечественных исследованиях наиболее востребованными методами МО являются нейронные сети, регрессионные модели, деревья решений и градиентный бустинг [26]. Авторы отмечают, что в большинстве российских работ (22 из 29) использованы методы МО для диагностики и прогнозирования ССС, однако лишь единицы проходят этап внешней валидации и внедрения в клиническую практику. Наше исследование, предусматривающее проспективную валидацию на независимой когорте (n = 300), направлено на преодоление этого разрыва. Б.А. Кобринский и Н.А. Благосклонов (2025) разработали систему ИИ для диагностики редких заболеваний на основе онтологического моделирования, что является альтернативным подходом к представлению медицинских знаний [38]. В отличие от data-driven моделей (как наша), онтологический подход требует явного формализованного описания предметной области, что трудоемко, но обеспечивает высокую интерпретируемость. Возможно, в будущем гибридные подходы, сочетающие статистическое обучение и онтологию, позволят достичь оптимального баланса между точностью и прозрачностью.

В целом представленная модель сопоставима по прогностической точности с лучшими образцами, описанными в литературе, и обладает преимуществами с точки зрения ориентации на рутинные клинические данные, доступные в первичном звене, и их интерпретируемости.

Дальнейшие этапы работы и перспективы

Полученные результаты, включая выявленные полые различия в профиле риска и сохраняющуюся проблему недостаточного контроля АД даже на фоне проводимой терапии, предоставляют ценную доказательную базу для разработки прогностического инструмента нового поколения. На следующем этапе будет проведено сравнительное обучение и валидация нескольких классических и современных алгоритмов МО, включая логистическую регрессию, случайный лес и градиентный бустинг (например, XGBoost, LightGBM). Ключевой фокус будет сделан не только на максимизации метрик точности (AUC-ROC, F1-score), но и на обеспечении клинической интерпретируемости итоговой модели. Для этого планируется применение методов объяснимого ИИ (Explainable AI, XAI), таких как SHapley Additive exPlanations (SHAP), которые

позволят визуализировать вклад каждого предиктора (например, уровня СРБ, пульсового давления или наличия аритмий) в индивидуальный расчет риска для конкретного пациента.

Построенная модель станет основой для разработки следующих практических инструментов внедрения.

1. Интерактивный калькулятор сердечно-сосудистого риска в формате веб-приложения или мобильного приложения. Врач сможет ввести ключевые параметры пациента (демографические, клинические, лабораторные) и получить:

- индивидуальную количественную оценку вероятности события;
- визуализацию основных факторов риска, влияющих на прогноз;
- практические рекомендации по возможной коррекции модифицируемых факторов.

2. Структурированный опросник (чек-лист) для врачей первичного звена, интегрирующий ключевые предикторы из модели. Этот инструмент будет служить напоминанием о необходимости оценки важных, но часто упускаемых из виду параметров (например, пульсового давления, уровня СРБ, наличия периферического атеросклероза) при плановом осмотре пожилого пациента с АГ.

Последующая строгая валидация на независимой проспективной когорте (n = 300) станет критически важным шагом для оценки реальной воспроизводимости, калибровки и дискриминационной способности модели вне стен исследовательского центра. Особое внимание будет уделено клинической полезности – способности инструмента реально изменить тактику ведения пациентов в условиях поликлиники. В долгосрочной перспективе результатом работы должен стать не просто валидированный алгоритм, а готовый к внедрению клинически ориентированный пакет, адаптированный для рутинного использования врачами-терапевтами и кардиологами первичного звена. Пилотное внедрение калькулятора и опросника в нескольких поликлиниках позволит оценить удобство, восприятие пользователями и предварительное влияние на качество принимаемых решений. Однако для реализации этого потенциала предстоит решить сопутствующие задачи, включая интеграцию с рабочими процессами и региональными ЭМК, обучение медицинского персонала, а в будущем – оценку экономической эффективности (cost-effectiveness) такого подхода в рамках системы здравоохранения.

Вызовы и ограничения

Широкое внедрение ИИ в клиническую практику, несмотря на огромный потенциал, сталкивается с рядом взаимосвязанных барьеров, требующих системного решения.

1. Проблема «черного ящика» и необходимость интерпретируемости. Сложность интерпретации решений, принимаемых алгоритмами глубокого обучения, подрывает доверие клиницистов и затрудняет принятие на себя ответственности. Критически важным



становится развитие объяснимого ИИ (XAI). Методы post-hoc анализа, такие как Local Interpretable Model-agnostic Explanations (LIME) и SHAP, позволяют визуализировать вклад конкретных входных признаков (например, сегментов ЭКГ или областей на медицинском изображении) в итоговое решение алгоритма для каждого отдельного случая. Это трансформирует ИИ из непрозрачного «оппонента» в понятного и проверяемого ассистента, чьи выводы врач может верифицировать. Требования к интерпретируемости регуляторные агентства все чаще включают в число обязательных условий для одобрения медицинских алгоритмов [16, 39].

2. Качество данных, смещения (Bias) и воспроизводимость. Алгоритмы МО учатся на исторических данных, которые могут содержать систематические ошибки, связанные с демографическими (раса, пол, возраст), социально-экономическими факторами или особенностями сбора данных в конкретном учреждении. Принцип «мусор на входе – мусор на выходе» остается актуальным: некорректные или нерепрезентативные данные ведут к созданию несправедливых и неточных моделей, плохо обобщаемых на новых популяциях [40]. Ключевыми задачами являются стандартизация данных, применение методов выявления и коррекции смещений, а также проведение внешней валидации на независимых когортах.

3. Регуляторные, правовые и экономические барьеры. Для выхода на рынок ИИ-решения должны пройти строгий процесс регулирования (Управление по контролю качества пищевых продуктов и лекарственных средств – Food and Drug Administration (FDA), Росздравнадзор, знак соответствия европейским стандартам и директивам (CE Mark)), требующий масштабных клинических испытаний, доказывающих не только аналитическую и клиническую точность, но и реальную пользу для пациента (улучшение исходов) и безопасность [41]. Не менее сложными остаются нерешенные вопросы юридической ответственности в случае ошибки и экономической целесообразности. Необходимы прозрачные бизнес-модели и доказательства того, что внедрение ИИ приводит к оптимизации ресурсов, сокращению сроков лечения и в конечном счете к снижению общих затрат системы здравоохранения.

4. Интеграция в клинические процессы и организационные изменения. Внедрение ИИ-инструментов – это не только техническая интеграция с больничными информационными системами (ЭМК, Picture Archiving and Communication System (PACS)), но и глубокая реорганизация рабочих процессов. Успех зависит от поэтапного подхода, начинающегося с пилотных проектов, в рамках которых алгоритмы первоначально работают в «теневом» режиме. Обязательными компонентами являются: адаптация клинических протоколов с четким определением роли ИИ-подсказки, повышение цифровой грамотности персонала для осознанного взаимодействия с системами ИИ, а также создание механизмов обратной

связи от врачей для калибровки алгоритмов и минимизации «алгоритмической усталости» [42].

5. Конфиденциальность и безопасность данных. Обработка обширных массивов конфиденциальной медицинской информации требует обеспечения высочайшего уровня кибербезопасности, соответствия стандартам защиты персональных данных (Общий регламент по защите данных – General Data Protection Regulation (GDPR), Федеральный закон от 27.07.2006 № 152-ФЗ) и разработки этических интегрированных систем (frameworks), регулирующих сбор, хранение и использование данных [43].

Заключение

В ходе проведенного исследования успешно достигнута поставленная цель: разработана и прошла первичную внутреннюю валидацию прогностическая модель тотального сердечно-сосудистого риска у амбулаторных пациентов пожилого и старческого возраста с АГ на основе методов МО. Построенная модель логистической регрессии продемонстрировала хорошую дискриминационную способность (AUC = 0,791; 95% ДИ 0,721–0,862), что подтверждает принципиальную возможность использования алгоритмов машинного обучения для стратификации риска в данной клинической группе. Независимыми предикторами ССС выступили наличие аритмий (ОШ 1,75; 95% ДИ 1,24–2,48), уровень гликированного гемоглобина, ХС ЛНП, ТГ, САД, а также факт приема антигипертензивной терапии. Высокая отрицательная прогностическая ценность модели (95,4%) имеет непосредственное практическое значение для первичного звена здравоохранения, позволяя с уверенностью исключать развитие ССС в ближайший год у пациентов с низким расчетным риском. Для подтверждения применимости результатов в реальной клинической практике необходима внешняя валидация модели на независимой проспективной когорте (n = 300), набор которой уже завершен. Последующие этапы исследования включают сравнительное обучение альтернативных алгоритмов МО (случайный лес, градиентный бустинг) с применением методов объяснимого ИИ (SHAP, LIME), а также разработку клинически ориентированных инструментов внедрения – интерактивного калькулятора риска и структурированного опросника для врачей первичного звена. Таким образом, разработанная модель может стать основой для персонализированной стратификации сердечно-сосудистого риска в амбулаторной практике, а искусственный интеллект в этом процессе выступает не заменой врача, а инструментом усиления клинического мышления в рамках модели гибридного интеллекта. ☺

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Финансирование. Работа выполнена без задействования грантов и финансовой поддержки от общественных, некоммерческих и коммерческих организаций.



Литература

1. GBD 2023 Causes of Death Collaborators. Global burden of 292 causes of death in 204 countries and territories and 660 subnational locations, 1990–2023: a systematic analysis for the Global Burden of Disease Study 2023. *Lancet*. 2025; 406 (10513): 1811–1872.
2. Zargarzadeh A., Javanshir E., Ghaffari A., et al. Artificial intelligence in cardiovascular medicine: an updated review of the literature. *J. Cardiovasc. Thorac. Res.* 2023; 15 (4): 204–209.
3. Itchhaporia D. Artificial intelligence in cardiology. *Trends Cardiovasc. Med.* 2022; 32 (1): 34–41.
4. Sandeep B., Liu X., Huang X., et al. Feasibility of artificial intelligence its current status, clinical applications, and future direction in cardiovascular disease. *Curr. Probl. Cardiol.* 2024; 49 (2): 102349.
5. Krittanawong C., Virk H.U.H., Bangalore S., et al. Machine learning prediction in cardiovascular diseases: a meta-analysis. *Sci. Rep.* 2020; 10 (1): 16057.
6. Samant S., Panagopoulos A.N., Wu W., et al. Artificial intelligence in coronary artery interventions: preprocedural planning and procedural assistance. *J. Soc. Cardiovasc. Angiogr. Interv.* 2025; 4 (3 Part B): 102519.
7. Leiner T., Rueckert D., Suinesiaputra A., et al. Machine learning in cardiovascular magnetic resonance: basic concepts and applications. *J. Cardiovasc. Magn. Reson.* 2019; 21 (1): 61.
8. Kulkarni P., Mahadevappa M., Chilakamarri S. The emergence of artificial intelligence in cardiology: current and future applications. *Curr. Cardiol. Rev.* 2022; 18 (3): e191121198124.
9. Somani S., Russak A.J., Richter F., et al. Deep learning and the electrocardiogram: review of the current state-of-the-art. *Europace*. 2021; 23 (8): 1179–1191.
10. Peters A.E., Tromp J., Shah S.J., et al. Phenomapping in heart failure with preserved ejection fraction: insights, limitations, and future directions. *Cardiovasc. Res.* 2023; 118 (18): 3403–3415.
11. Anzabi Zadeh S., Street W.N., Thomas B.W. Optimizing warfarin dosing using deep reinforcement learning. *J. Biomed. Inform.* 2023; 137: 104267.
12. Litjens G., Ciompi F., Wolterink J.M., et al. State-of-the-art deep learning in cardiovascular image analysis. *JACC Cardiovasc. Imaging*. 2019; 12 (8 Pt 1): 1549–1565.
13. Dilsizian M.E., Siegel E.L. Machine meets biology: a primer on artificial intelligence in cardiology and cardiac imaging. *Curr. Cardiol. Rep.* 2018; 20 (12): 139.
14. Abdolmanafi A., Duong L., Ibrahim R., Dahdah N. A deep learning-based model for characterization of atherosclerotic plaque in coronary arteries using optical coherence tomography images. *Med. Phys.* 2021; 48 (7): 3511–3524.
15. Shafqat S., Fayyaz M., Khattak H.A., et al. Leveraging deep learning for designing healthcare analytics heuristic for diagnostics. *Neural. Process. Lett.* 2023; 55 (1): 53–79.
16. Xiao H., Ali S., Zhang Z., et al. Big data, extracting insights, comprehension, and analytics in cardiology: an overview. *J. Healthc. Eng.* 2021; 2021: 6635463.
17. Garvin J.H., Kim Y., Gobbel G.T., et al. Automating quality measures for heart failure using natural language processing: a descriptive study in the department of veterans affairs. *JMIR Med. Inform.* 2018; 6 (1): e5.
18. Gaviria-Valencia S., Murphy S.P., Kaggal V.C., et al. Near real-time natural language processing for the extraction of abdominal aortic aneurysm diagnoses from radiology reports: algorithm development and validation study. *JMIR Med. Inform.* 2023; 11: e40964.
19. Chen R., Stewart W.F., Sun J., et al. Recurrent neural networks for early detection of heart failure from longitudinal electronic health record data: implications for temporal modeling with respect to time before diagnosis, data density, data quantity, and data type. *Circ. Cardiovasc. Qual. Outcomes*. 2019; 12 (10): e005114.
20. Srivani M., Murugappan A., Mala T. Cognitive computing technological trends and future research directions in healthcare – a systematic literature review. *Artif. Intell. Med.* 2023; 138: 102513.
21. Reshad A.I., Nino V., Valero M. Deep learning-based detection of arrhythmia using ECG signals – a comprehensive review. *Vasc. Health Risk Manag.* 2025; 21: 685–703.
22. Rajpurkar P., Hannun A.Y., Haghpanahi M., et al. Cardiologist-level arrhythmia detection with convolutional neural networks. *arXiv (preprint)*. 2017: 1707.01836.
23. Croon P.M., Boonstra M.J., Allaart C.P., et al. Artificial intelligence-enhanced electrocardiogram models for detection of left ventricular dysfunction: a comparison study. *JACC. Adv.* 2026; 5 (2): 102572.
24. Hygrel T., Viberg F., Dahlberg E., et al. An artificial intelligence-based model for prediction of atrial fibrillation from single-lead sinus rhythm electrocardiograms facilitating screening. *Europace*. 2023; 25 (4): 1332–1338.
25. Turakhia M.P., Desai M., Hedlin H., et al. Rationale and design of a large-scale, app-based study to identify cardiac arrhythmias using a smartwatch: The Apple Heart Study. *Am. Heart J.* 2019; 207: 66–75.
26. Ковелькова М.Н., Яковлева Е.Г. Системы искусственного интеллекта в профилактике и диагностике сердечно-сосудистой патологии в России (систематический обзор). *Сибирский журнал клинической и экспериментальной медицины*. 2025; 40 (1): 28–41.
27. Holste G., Oikonomou E.K., Tokodi M., et al. Complete AI-enabled echocardiography interpretation with multitask deep learning. *JAMA*. 2025; 334 (4): 306–318.
28. Reddy C.D., Lopez L., Ouyang D., et al. Video-based deep learning for automated assessment of left ventricular ejection fraction in pediatric patients. *J. Am. Soc. Echocardiogr.* 2023; 36 (5): 482–489.
29. Commandeur F., Slomka P.J., Goeller M., et al. Machine learning to predict the long-term risk of myocardial infarction and cardiac death based on clinical risk, coronary calcium, and epicardial adipose tissue: a prospective study. *Cardiovasc. Res.* 2020; 116 (14): 2216–2225.



30. Zreik M., van Hamersvelt R.W., Wolterink J.M., et al. A recurrent CNN for automatic detection and classification of coronary artery plaque and stenosis in coronary CT angiography. *IEEE Trans. Med. Imaging*. 2019; 38 (7): 1588–1598.
31. Betancur J., Commandeur F., Motlagh M., et al. Deep learning for prediction of obstructive disease from a myocardial perfusion SPECT: a multicenter study. *JACC Cardiovasc. Imaging*. 2018; 11 (11): 1654–1663.
32. Ahmad F., Hou W., Xiong J., Xia Z. Fully automated cardiac MRI segmentation using dilated residual network. *Med. Phys.* 2023; 50 (4): 2162–2175.
33. Pal M., Parija S., Panda G., et al. Risk prediction of cardiovascular disease using machine learning classifiers. *Open Med. (Wars.)*. 2022; 17 (1): 1100–1113.
34. Raheem A., Waheed S., Karim M., et al. Prediction of major adverse cardiac events in the emergency department using an artificial neural network with a systematic grid search. *Int. J. Emerg. Med.* 2024; 17 (1): 4.
35. Steele A.J., Denaxas S.C., Shah A.D., et al. Machine learning models in electronic health records can outperform conventional survival models for predicting patient mortality in coronary artery disease. *PLoS One*. 2018; 13 (8): e0202344.
36. Zhang Y., Xu W., Yang P., Zhang A. Machine learning for the prediction of sepsis-related death: a systematic review and meta-analysis. *BMC Med. Inform. Decis. Mak.* 2023; 23 (1): 283.
37. Davies J. CEREBRIA-1: Machine learning vs expert human opinion to determine physiologically optimized coronary revascularization strategies. At: Transcatheter Cardiovascular Therapeutics Symposium (TCT). San Diego, CA, 24.09.2018.
38. Кобринский Б.А., Благосклонов Н.А. Система искусственного интеллекта для диагностики редких заболеваний: принципы построения и результаты клинической апробации. *Сибирский журнал клинической и экспериментальной медицины*. 2025; 40 (2): 218–225.
39. Ghassemi M., Oakden-Rayner L., Beam A.L. The false hope of current approaches to explainable artificial intelligence in health care. *Lancet Digit. Health*. 2021; 3 (11): e745–e750.
40. Nazer L.H., Zatarah R., Waldrip S., et al. Bias in artificial intelligence algorithms and recommendations for mitigation. *PLOS Digit. Health*. 2023; 2 (6): e0000278.
41. Olaye I.M., Seixas A.A. The gap between AI and bedside: participatory workshop on the barriers to the integration, translation, and adoption of digital health care and AI startup technology into clinical practice. *J. Med. Internet Res.* 2023; 25: e32962.
42. Siala H., Wang Y. SHIFTing artificial intelligence to be responsible in healthcare: A systematic review. *Soc. Sci. Med.* 2022; 296: 114782.
43. Khalid N., Qayyum A., Bilal M., et al. Privacy-preserving artificial intelligence in healthcare: techniques and applications. *Comput. Biol. Med.* 2023; 158: 106848.

Personalized Assessment of Cardiovascular Risk Based on Machine Learning Methods in Elderly and Senile Patients with Arterial Hypertension: A Retrospective Study (Phase I)

A.S. Ryazanov, PhD, Prof.¹, I.M. Khapokhov^{1,2}, M.V. Makarovskaya, PhD^{1,2}, I.A. Gordeeva^{1,2}, N.A. Anisimov^{1,2}

¹ Russian Medical Academy of Continuous Professional Education, Moscow

² Clinical and Diagnostic Center No. 4 of the Moscow Department of Health

Contact person: Maria V. Makarovskaya, marja.makarovska@mail.ru

Aim. To develop and initially evaluate a predictive model for total cardiovascular risk in elderly and senile outpatients with arterial hypertension based on machine learning methods.

Material and methods. The study had a 'retrospective cohort – prospective follow-up' design and consisted of two stages. At the first (retrospective) stage, the analysis included 1,028 patients (527 women, 501 men) aged 60 to 90 years (median 72 years) with arterial hypertension. Exclusion criteria were a history of myocardial infarction, stroke, vascular or cardiac surgery, chronic heart failure, and severe comorbidities. The primary endpoint included cardiovascular death, non-fatal myocardial infarction, non-fatal stroke, myocardial revascularization, and hospitalization for decompensated heart failure. A multivariate logistic regression model was constructed. Discriminatory ability was assessed using ROC analysis. At the second (prospective) stage, an independent cohort (n = 300) was enrolled for subsequent external validation of the model.

Results. During the follow-up period (median 328 days), primary endpoints were recorded in 186 patients (18.1%). The logistic regression model demonstrated good discriminatory ability: AUC = 0.791 (95% CI 0.721–0.862). Independent predictors of cardiovascular events were the presence of arrhythmias (OR = 1.75; 95% CI 1.24–2.48; p = 0.002), HbA1c levels (p < 0.001), low-density lipoprotein cholesterol (p = 0.022), triglycerides (p < 0.001), systolic blood pressure (p < 0.001), and the fact of receiving antihypertensive therapy (p = 0.071, included for clinical significance). At the optimal cutoff, the model demonstrated a sensitivity of 87.5%, a specificity of 57.2%, and a negative predictive value of 95.4%.

Conclusion. The developed predictive model has good discriminatory ability and a high negative predictive value, making it suitable for ruling out high cardiovascular risk in elderly outpatients with arterial hypertension. To confirm the applicability of the results in real clinical practice, external validation of the model in an independent prospective cohort (the second stage of the study) is required.

Keywords: artificial intelligence, machine learning, logistic regression, predictive model, cardiovascular risk, arterial hypertension, elderly age