



Ансамблевые машинные предикторы: новый подход к оценке риска госпитальной летальности у пациентов с острым коронарным синдромом

Торопов В. Н.¹, Богомолов А. Н.^{2,3}, Курочкина О. Н.^{1,4}, Ветошкин Р. Е.¹, Соловьёв И. А.¹

Цель. Оценить эффективность современных ансамблевых моделей машинного обучения (МО) в прогнозировании госпитальной летальности у пациентов с острым коронарным синдромом (ОКС) в сравнении с традиционной клинической шкалой GRACE.

Материал и методы. В ретроспективное исследование включены анонимизированные данные 14420 пациентов с ОКС, госпитализированных в кардиологический стационар. Для каждого клинического случая анализировалось 28 предикторов. На основе этих данных обучены алгоритмы МО: логистическая регрессия, деревья решений, случайный лес (Random Forest), градиентный бустинг (XGBoost, CatBoost). Для оценки качества моделей использовались площадь под ROC-кривой (AUC-ROC), полнота (Recall) и F1-мера. Результаты лучшей модели сопоставлялись с оценкой риска по шкале GRACE. Для интерпретации логики алгоритма применялся SHAP-анализ.

Результаты. Госпитальная летальность составила 6,03% (804 пациента). Алгоритмы на основе градиентного бустинга продемонстрировали наилучшую предсказательную способность. Лидером стала модель CatBoost, показавшая значение AUC-ROC 0,961, статистически значимо превзойдя шкалу GRACE (AUC-ROC 0,919) на тестовой выборке. SHAP-анализ выявил, что наибольший вклад в прогноз модели вносят: наличие дислипидемии в анамнезе, фракция выброса левого желудочка, класс острой сердечной недостаточности по Killip, возраст и уровень систолического артериального давления. Модель успешно выявила скрытые нелинейные клинические паттерны, включая парадоксальный защитный эффект диагностированной ранее дислипидемии и критическую прогностическую значимость отсутствия анамнестических данных при поступлении.

Заключение. Методы МО, в частности алгоритм CatBoost, обеспечивают более высокую точность прогнозирования госпитальной летальности при ОКС по сравнению с классическими шкалами. Способность алгоритмов учитывать сложные нелинейные взаимосвязи между клиническими показателями делает их перспективной основой для создания точных систем поддержки принятия врачебных решений.

Ключевые слова: острый коронарный синдром, машинное обучение, прогнозирование, госпитальная летальность, шкала GRACE, стратификация риска, CatBoost, SHAP, искусственный интеллект.

Отношения и деятельность: нет.

¹ФГБОУ ВО Сыктывкарский государственный университет им. Питирима Сорокина, Сыктывкар, Россия; ²СПб ГБУЗ Александровская больница, Санкт-

Петербург, Россия; ³АННО ВО НИЦ Санкт-Петербургский институт биорегуляции и геронтологии, Санкт-Петербург, Россия; ⁴ГУ РК Клинический кардиологический диспансер, Сыктывкар, Россия.

Торопов В. Н. — магистрант, практикант научно-исследовательской лаборатории "Трансляционная биоинформатика и системная биология" медицинского института, ORCID: нет, Богомолов А. Н. — к.м.н., с.н.с. лаборатории возрастной патологии сердечно-сосудистой системы; врач эндоваскулярный хирург, ORCID: 0000-0003-0019-0820, Курочкина О. Н. — д.м.н., зав. кафедрой терапии медицинского института; зав. научным отделом, ORCID: 0000-0003-1595-7692, Ветошкин Р. Е. — инженер научно-исследовательской лаборатории "Трансляционная биоинформатика и системная биология" медицинского института, ORCID: нет, Соловьёв И. А. — к.б.н., с.н.с. (заведующий) научно-исследовательской лаборатории "Трансляционная биоинформатика и системная биология" медицинского института, ORCID: 0000-0002-1038-2271.

*Автор, ответственный за переписку (Corresponding author):
i@ilyasolovlev.ru

МО — машинное обучение, ОКС — острый коронарный синдром, САД — систолическое артериальное давление, ФВ — фракция выброса, AUC-ROC (Area Under the Receiver Operating Characteristic Curve) — площадь под кривой рабочей характеристики приемника, GRACE (Global Registry of Acute Coronary Events) — глобальный регистр острых коронарных событий, SHAP (SHapley Additive exPlanations) — метод аддитивных объяснений Шепли.

Рукопись получена 05.03.2026

Рецензия получена 20.03.2026

Принята к публикации 24.03.2026



Для цитирования: Торопов В. Н., Богомолов А. Н., Курочкина О. Н., Ветошкин Р. Е., Соловьёв И. А. Ансамблевые машинные предикторы: новый подход к оценке риска госпитальной летальности у пациентов с острым коронарным синдромом. *Российский кардиологический журнал*. 2026;31(2S):6885. doi: 10.15829/1560-4071-2026-6885. EDN: PFQTXI

Ensemble machine learning predictors: a novel approach to assessing the risk of in-hospital mortality in patients with acute coronary syndrome

Toropov V. N.¹, Bogomolov A. N.^{2,3}, Kurochkina O. N.^{1,4}, Vetoshkin R. E.¹, Solovoyov I. A.¹

Aim. To evaluate the effectiveness of modern ensemble machine learning (ML) models in predicting in-hospital mortality in patients with acute coronary syndrome (ACS) compared to the traditional GRACE clinical score.

Material and methods. This retrospective study included anonymized data from 14420 patients with ACS admitted to a cardiology hospital. For each case, 28 predictors were analyzed. Following machine learning algorithms were trained using this data: logistic regression, decision trees, random forest, and gradient boosting (XGBoost, CatBoost). The area under the receiver operating characteristic (AUC-ROC), recall, and F1 score were used to assess the model quality. The results of the best model were compared with the GRACE risk score. SHAP analysis was used to interpret the algorithm logic.

Results. In-hospital mortality was 6,03% (n=804). Gradient boosting algorithms demonstrated the highest predictive capability. The CatBoost model emerged as the top performer, achieving an AUC-ROC of 0,961, significantly outperforming the GRACE

score (AUC-ROC 0,919) on the test set. SHAP analysis revealed that the greatest contributors to the model's prediction were history of dyslipidemia, left ventricular ejection fraction, Killip class of acute heart failure, age, and systolic blood pressure levels. The model successfully identified hidden nonlinear clinical patterns, including the paradoxical protective effect of previously diagnosed dyslipidemia and the critical prognostic significance of missing medical history data upon admission.

Conclusion. ML methods, particularly the CatBoost algorithm, provide higher accuracy in predicting in-hospital mortality in ACS compared to conventional scores. The ability of these algorithms to account for complex nonlinear relationships between clinical indicators makes them a promising foundation for developing accurate clinical decision support systems.

Keywords: acute coronary syndrome, machine learning, prediction, in-hospital mortality, GRACE score, risk stratification, CatBoost, SHAP, artificial intelligence.

Relationships and Activities: none.

*Corresponding author:
i@ilyasolovlev.ru

¹Pitirim Sorokin Syktyvkar State University, Syktyvkar, Russia; ²Alexandrovskaya Hospital, St. Petersburg, Russia; ³St. Petersburg Institute of Bioregulation and Gerontology, St. Petersburg, Russia; ⁴Clinical Cardiology Dispensary, Syktyvkar, Russia.

Toropov V.N. ORCID: none, Bogomolov A.N. ORCID: 0000-0003-0019-0820, Kurochkina O.N. ORCID: 0000-0003-1595-7692, Vetoshkin R.E. ORCID: none, Solovyov I.A. * ORCID: 0000-0002-1038-2271.

Received: 05.03.2026 **Revision Received:** 20.03.2026 **Accepted:** 24.03.2026

For citation: Toropov V.N., Bogomolov A.N., Kurochkina O.N., Vetoshkin R.E., Solovyov I.A. Ensemble machine learning predictors: a novel approach to assessing the risk of inhospital mortality in patients with acute coronary syndrome. *Russian Journal of Cardiology*. 2026;31(2S):6885. doi: 10.15829/1560-4071-2026-6885. EDN: PFQTXI

Ключевые моменты

- Классические шкалы риска при остром коронарном синдроме (в частности, GRACE) ограничены узким набором переменных и не учитывают сложные нелинейные взаимосвязи клинических показателей.
- Модель CatBoost превзошла шкалу GRACE по точности прогноза госпитальной летальности. Применение SHAP-анализа решило проблему "черного ящика", визуализировав логику работы алгоритма и выявив неочевидные маркеры риска (например, парадокс дислипидемии).
- Интеграция таких алгоритмов в медицинские информационные системы обеспечит высокоточную автоматизированную стратификацию рисков при поступлении, помогая врачам быстрее оптимизировать лечение и снижать летальность.

Key messages

- Conventional acute coronary syndrome risk scores (in particular, GRACE) rely on limited variables and ignore complex nonlinear relationships between clinical parameters.
- The CatBoost model outperformed the GRACE score in predicting inhospital mortality. SHAP analysis resolved the "black box" problem by visualizing the algorithm's logic and revealing hidden risk markers (e.g., the dyslipidemia paradox).
- Integrating these algorithms into hospital information systems ensures highly accurate automated risk stratification upon admission, helping physicians optimize treatment faster and reduce mortality.

Острый коронарный синдром (ОКС) остается ведущей причиной смертности в развитых и развивающихся странах, несмотря на значительный прогресс в медицине [1]. Своевременная стратификация риска неблагоприятных исходов является краеугольным камнем в выборе тактики ведения пациентов: от нее зависит своевременность перевода больного в отделение интенсивной терапии и выбор стратегии инвазивного вмешательства.

Исторически для этих целей кардиологами используются валидированные балльные системы, наиболее авторитетной из которых является шкала GRACE (Global Registry of Acute Coronary Events, глобальный регистр острых коронарных событий) [2]. Однако традиционные шкалы имеют ряд ограничений. Они базируются на методах линейной регрессии и используют строго ограниченный набор признаков (для GRACE это 8 предикторов). Человеческий организм — сложная система, и связь между клиническими показателями и риском смерти редко бывает строго линейной (например, как чрезмерно высокое, так и критически низкое артериальное давление связано с неблагоприятным прогнозом) [3]. Кроме того, классические шка-

лы не способны в полной мере использовать огромный массив данных, накапливаемый сегодня в электронных медицинских картах.

В последние годы в кардиологии активно внедряются методы искусственного интеллекта и машинного обучения (МО). В отличие от классической статистики, МО способно анализировать многомерные массивы данных, выявляя скрытые нелинейные паттерны [4, 5]. Ряд исследований демонстрирует превосходство МО над традиционными шкалами в предсказании крупных кардиоваскулярных событий [6, 7]. Однако внедрение таких моделей требует их обучения и валидации на локальных популяциях, а также преодоления проблемы недостаточной прозрачности алгоритмов для врачей-клиницистов и клинических биоинформатиков.

Цель исследования: разработать и сравнить модели МО для прогнозирования госпитальной смертности пациентов с ОКС на основе крупной выборки, сопоставить их эффективность с традиционной шкалой GRACE, а также интерпретировать логику принятия решений алгоритмом с клинической точки зрения.

Материал и методы

Клинические данные. Исследование носит ретроспективный характер. Использовалась уникальная анонимизированная выборка из 14420 историй

Таблица 1

Сравнение предсказательной способности обученных на клинических данных моделей

Модель	AUC-ROC	F1-мера (баланс)	Полнота (Recall)	Точность (Precision)
Логистическая регрессия	0,936	0,44	0,850	0,30
Random Forest (Случайный лес)	0,941	0,53	0,860	0,38
XGBoost	0,951	0,50	0,880	0,35
CatBoost	0,961	0,55	0,880	0,40

Сокращение: AUC-ROC (Area Under the Receiver Operating Characteristic Curve) — площадь под кривой рабочей характеристики приемника.

болезни пациентов с подтвержденным диагнозом ОКС, проходивших лечение в СПб ГБУЗ "Городская Александровская больница".

Для исключения статистических погрешностей пациенты с неизвестным клиническим исходом (1088 случаев), а также признаки, имеющие >50% пропущенных значений, были исключены. Итоговая выборка составила 13332 пациента. За период госпитализации летальный исход зафиксирован у 804 пациентов (6,03%). В финальный анализ были включены 28 показателей: демографические данные, жизненные показатели при поступлении (артериальное давление, частота сердечных сокращений), данные лабораторных (креатинин, тропонины, глюкоза) и инструментальных исследований (фракция выброса (ФВ) левого желудочка, зоны гипокинеза по эхокардиографии, класс по Killip и др.).

Методы МО. В традиционных шкалах формула расчета риска создается исследователями на основе классической статистики: каждому симптому заранее присваивается фиксированный "вес" (балл). Алгоритмы МО работают принципиально иначе, так компьютерная программа получает массив данных с известными исходами (выжил/летальный исход) и *самостоятельно* выявляет скрытые математические закономерности [8, 9].

В настоящей работе по показателям эффективности были оценены следующие алгоритмы:

1. Логистическая регрессия: базовый статистический метод, оценивающий линейный вклад каждого фактора в вероятность события. Метод прозрачен, но плохо справляется с нелинейными связями.

2. Дерево решений (Decision Tree): алгоритм, автоматически ищущий параметры, которые лучше всего разделяют пациентов на выживших и умерших, задавая последовательность бинарных вопросов. Напоминает клинический алгоритм сортировки.

3. Случайный лес (Random Forest): ансамблевый метод. Алгоритм строит сотни независимых деревьев решений. Каждому дереву показывают только случайную часть пациентов и случайную часть их показателей. Итоговое решение принимается путем "голосования" деревьев.

4. Градиентный бустинг (XGBoost, CatBoost): наиболее мощная форма ансамблевого обучения. В отличие от Случайного леса, деревья строятся *последо-*

вательно. Каждое новое короткое дерево прицельно учится исправлять ошибки классификации сложных пациентов, допущенные предыдущим алгоритмом. В нашем исследовании в качестве основной модели применялась библиотека CatBoost, разработанная для эффективной работы со смешанными табличными данными. Ее преимущество заключается в способности легко усваивать качественные медицинские показатели (наличие заболеваний, пол) и высокой устойчивости к пропускам в клинических данных [10].

5. Метод SHAP (SHapley Additive exPlanations, метод аддитивных объяснений Шепли), позволяющий оценить влияние каждого клинического признака на итоговый прогноз, по сути интерпретатор слабого искусственного интеллекта [11].

Проблема дисбаланса классов и валидация. Поскольку абсолютное большинство пациентов (94%) выжили, базовая модель могла бы всем ставить прогноз "выживет" и формально иметь точность 94%, при этом пропуская все смерти. Для решения проблемы дисбаланса классов мы применили метод *взвешивания классов* (Class Weighting), искусственно увеличив "штраф" алгоритму за ошибку на пациенте с летальным исходом.

Вся выборка была случайным образом, но с сохранением пропорции умерших, разделена на две части: обучающую (80%) и тестовую (20%). Алгоритмы обучались только на обучающей выборке, а оценка качества проводилась на тестовой. Качество оценивали по площади под ROC-кривой (AUC-ROC), метрикам точности (Precision) и полноты (Recall). Для сравнения для каждого пациента из тестовой выборки был высчитан риск смерти по шкале GRACE с использованием оригинальной регрессионной формулы.

Результаты

Сравнение производительности моделей

При тестировании на отложенной выборке современные ансамблевые модели МО продемонстрировали существенное превосходство над базовой логистической регрессией (табл. 1).

Лучшей моделью по интегральной способности дифференцировать риски стала модель CatBoost (AUC-ROC=0,961). Модель продемонстрировала высокий показатель полноты (0,880) — это означает, что она способна успешно выявить 88% пациентов, ко-




Рис. 1. Сравнение ROC-кривых модели CatBoost и клинической шкалы GRACE на тестовой выборке.

торым угрожает летальный исход, минимизируя критически опасные ложноотрицательные результаты.

Сравнение CatBoost со шкалой GRACE

ROC-анализ показал, что предсказательная способность модели МО статистически значимо превосходит традиционную шкалу (рис. 1). AUC-ROC для CatBoost составила 0,961 против 0,919 для шкалы GRACE.

Визуально на всем протяжении графика кривая модели CatBoost располагается выше и левее кривой шкалы GRACE. На индивидуальном уровне анализ показал, что CatBoost точнее ранжирует риски у нестандартных пациентов, где классическая 8-факторная шкала недооценивала угрозу.

Интерпретируемость модели: оценка вклада предикторов (SHAP-анализ)

Для преодоления проблемы "черного ящика" нейросетевых алгоритмов был применен метод SHAP, позволяющий оценить влияние каждого клинического признака на итоговый прогноз [11].

На рисунке 2 представлена сводная диаграмма SHAP. По вертикальной оси предикторы ранжированы по степени их убывающей значимости. Каждая точка — один пациент. Цвет отражает исходное значение показателя (красный — высокие значения, синий — низкие, серый — нет данных). Положение точки по горизонтальной оси показывает влияние признака на прогноз: смещение вправо увеличивает риск летального исхода, влево — снижает риск.

Анализ графика продемонстрировал, что алгоритм успешно усвоил фундаментальные законы патофизиологии ОКС, т.е. знания необходимые для прогнозирования госпитальной летальности из набора данных:

1. Состояние миокарда и тяжесть острой сердечной недостаточности. ФВ и класс по Killip высту-

пили мощнейшими предикторами. Низкие значения ФВ (синие точки) формируют длинный "хвост" в правой части графика, критически повышая вероятность смерти. Сохранная ФВ (красные точки) смещает прогноз в безопасную зону. Аналогично, высокие классы Killip (III-IV, красные точки) резко сдвигают прогноз в зону летального исхода.

2. Системная гемодинамика. Высокие цифры систолического артериального давления (САД) при поступлении (красные точки) ассоциированы с благоприятным прогнозом, в то время как низкое САД (синие точки) выступает машинным маркером кардиогенного шока и истощения резервов.

3. Функция почек. Снижение клиренса креатинина (синие точки) и рост уровня креатинина (красные точки) уверенно классифицируются моделью как факторы фатального прогноза.

4. Феномен "парадокса дислипидемии". Самым весомым признаком математически выступило наличие дислипидемии, однако вектор ее влияния оказался парадоксальным. Наличие установленной дислипидемии (красные точки) *снижает* риск внутрибольничной смерти, а ее отсутствие (синие точки) или отсутствие данных о ней (серые точки) — резко *повышают* риск. С клинической точки зрения этот машинный вывод описывает известное в кардиологии явление [12], пациенты с известной дислипидемией, как правило, находились под наблюдением и принимали статины до развития ОКС, что обеспечивает плеiotропный, бляшкостабилизирующий эффект. В то же время "серые точки" (нет данных по анамнезу), уходящие в экстремальную зону риска (далеко вправо), отражают когорту пациентов, поступивших в критическом состоянии (шок, искусственная вентиляция легких, клиническая смерть), у которых сбор анамнеза был физически невозможен. Модель блестяще уловила этот скрытый нюанс.

Обсуждение

Результаты исследования подтверждают актуальный тренд цифровой медицины — МО обеспечивает лучшую прогностическую точность, чем традиционные регрессионные модели [6, 8]. Шкала GRACE, обладающая неоспоримой клинической ценностью, ограничена 8 фиксированными переменными. Модель CatBoost, используя 28 доступных параметров, формирует более детальный профиль риска пациента.

Важнейшим итогом исследования является как достижение высоких значений метрик (AUC 0,961), так и клиническая прозрачность алгоритма принятия решений, показанная с помощью SHAP-анализа. Алгоритм не просто произвел слепую итерацию, а с высокой точностью симитировал врачебное мышление: выделил маркеры насосной дисфункции (ФВ левого желудочка, Killip), нарушения перфузии




Рис. 2. SHAP-анализ: распределение влияния клинических предикторов на риск внутрибольничной летальности.

Сокращения: АЧТВ — активированное частичное тромбопластиновое время, ДАД — диастолическое артериальное давление, ИМнСТ — инфаркт миокарда с подъемом сегмента ST, ЛГ — легочная гипертензия, ЛЖ — левый желудочек, МВ-КФК — креатинкиназа-МВ, ОКС — острый коронарный синдром, ОКСбнСТ — острый коронарный синдром без подъема сегмента ST, САД — систолическое артериальное давление, ЧКВ — чрескожное коронарное вмешательство, ЧСС — частота сердечных сокращений.

(низкое САД) и органного повреждения (креатинин). Особую ценность представляет способность алгоритма МО выявлять скрытые взаимосвязи, такие как "защитный" эффект подтвержденного анамнеза дислипидемии (маркер предшествующей терапии и комплаентности) и фатальное прогностическое значение отсутствия сведений об анамнезе у тяжелых пациентов [12–15]. У пациентов старческого возраста (углубленный анализ подгрупп) алгоритмы выявили смену приоритетов риска: структурные показатели миокарда уступают место интегральным параметрам системной перфузии.

Внедрение подобных интеллектуальных алгоритмов в виде модулей госпитальных медицинских информационных систем позволит полностью автома-

тизировать расчет риска, избавляя врача от рутинных вычислений и сигнализируя о скрытом ухудшении состояния больного.

Ограничения исследования. Ограничениями данного исследования являются его ретроспективный дизайн и использование базы данных одного крупного стационара. Для подтверждения универсальности (генерализуемости) модели необходимо проведение проспективных мультицентровых исследований, для облегчения взаимодействия с ансамблевыми моделями врачей-клиницистов необходима разработка интерфейса с интегрированной большой языковой моделью-агентом, принимающей команды на естественном языке и интерпретирующей выдачу ансамблей.

Заключение

Разработанная на базе алгоритма градиентного бустинга (CatBoost) ансамблевая модель МО продемонстрировала высокую точность в прогнозировании госпитальной летальности у пациентов с ОКС (AUC-ROC=0,961), статистически превзойдя классическую клиническую шкалу GRACE (AUC-ROC=0,919). Использование SHAP-анализа позволило визуализировать процесс машинного прогнозирования госпитальной летальности, подтвердив его полное соответствие законам клинической патофизиологии. Интеграция таких алгоритмов в медицинские инфор-

мационные системы способна стать мощным инструментом персонализированной стратификации рисков и поддержки врачебных решений, направленных на снижение госпитальной смертности.

Отношения и деятельность: все авторы заявляют об отсутствии потенциального конфликта интересов, требующего раскрытия в данной статье.

Декларация ИИ. Технологии генеративного ИИ использовались исключительно как вспомогательный инструмент на финальных стадиях работы над текстом рукописи.

Литература/References

- Bhatt DL, Lopes RD, Harrington RA. Diagnosis and treatment of acute coronary syndromes: a review. *JAMA*. 2022;327(7):662-75. doi:10.1001/jama.2022.0358.
- Fox KAA, Dabbous OH, Goldberg RJ, et al. Predictors of hospital mortality in the global registry of acute coronary events. *Arch Intern Med*. 2003;163(23):2345-53. doi:10.1001/archinte.163.19.2345.
- Deo RC. Machine learning in medicine. *Circulation*. 2015;132(20):1920-30. doi:10.1161/CIRCULATIONAHA.115.001593.
- Arfat Y, Mittone G, Esposito R, et al. Machine learning for cardiology. *Minerva Cardiol Angiol*. 2022;70(1):75-91. doi:10.23736/S2724-5683.21.05709-4.
- D'Ascenzo F, De Filippo O, Gallone G, et al. Machine learning-based prediction of adverse events following an acute coronary syndrome (PRAISE): a modelling study of pooled datasets. *The Lancet*. 2021;397(10270):199-207. doi:10.1016/S0140-6736(20)32519-8.
- Zhang X, Wang X, Xu L, et al. The predictive value of machine learning for mortality risk in patients with acute coronary syndromes: a systematic review and meta-analysis. *Eur J Med Res*. 2023;28(1):451. doi:10.1186/s40001-023-01027-4.
- Emakhu J, Monplaisir L, Aguwa C, et al. Acute coronary syndrome prediction in emergency care: A machine learning approach. *Comput Methods Programs Biomed*. 2022;225:107080. doi:10.1016/j.cmpb.2022.107080.
- Chopannejad S, Sadoughi F, Bagherzadeh R, Shekarchi S. Predicting Major Adverse Cardiovascular Events in Acute Coronary Syndrome: A Scoping Review of Machine Learning Approaches. *Appl Clin Inform*. 2022;13(3):720-40. doi:10.1055/a-1863-1589.
- Khera R, Haimovich J, Hurley NC, et al. Use of machine learning models to predict death after acute myocardial infarction. *JAMA Cardiol*. 2021;6(6):633-41. doi:10.1001/jamacardio.2021.0122.
- Prokhorenkova L, Gusev G, Vorobev A, et al. CatBoost: unbiased boosting with categorical features. *Adv Neural Inf Process Syst*. 2018;31:6638-48.
- Lundberg SM, Lee SI. A unified approach to interpreting model predictions. *Adv Neural Inf Process Syst*. 2017;30:4765-74. doi:10.48550/arXiv.1705.07874.
- Cho SM, Austin PC, Ross HJ, et al. Machine learning compared with conventional statistical models for predicting myocardial infarction readmission and mortality: a systematic review. *Can J Cardiol*. 2021;37(8):1207-14. doi:10.1016/j.cjca.2021.02.020.
- Jian R, Zhang J, Zeng Y, et al. In-hospital mortality risk prediction models for patients with acute coronary syndrome: a systematic review and meta-analysis. *Frontiers in Cardiovascular Medicine*. 2025;3(12):1659184. doi:10.3389/fcvm.2025.1659184.
- Wu TT, Lin XQ, Mu Y, et al. Machine learning for early prediction of in-hospital cardiac arrest in patients with acute coronary syndromes. *Clin Cardiol*. 2021;44(3):349-56. doi:10.1002/clc.23541.
- Soloviev IA, Kurochkina ON. Artificial intelligence applications in cardiology: a review. *Russian Journal of Cardiology*. 2024;29(11S):5673. (In Russ.) Соловьёв И.А., Курочкина О.Н. Приложения искусственного интеллекта в кардиологии: обзор. *Российский кардиологический журнал*. 2024;29(11S):5673. doi:10.15829/1560-4071-2024-5673.

Адреса организаций авторов: ФГБОУ ВО Сыктывкарский государственный университет им. Питирима Сорокина, Октябрьский проспект, д. 55, Сыктывкар, 167001, Россия; СПб ГБУЗ Александровская больница, пр. Солидарности, д. 4, Санкт-Петербург, 193312, Россия; АННО ВО НИЦ Санкт-Петербургский институт биорегуляции и геронтологии, пр. Динамо, д. 3, Санкт-Петербург, 197110, Россия; ГУ РК Клинический кардиологический диспансер, ул. Маркова, д. 1, Сыктывкар, 167981, Россия.

Addresses of the authors' institutions: Pitirim Sorokin Syktyvkar State University, Oktyabrsky ave., 55, Syktyvkar, 167001, Russia; Alexandrovskaya Hospital, Solidarity ave., 4, St. Petersburg, 193312, Russia; St. Petersburg Institute of Bioregulation and Gerontology, Dynamo ave., 3, St. Petersburg, 197110, Russia; Clinical Cardiology Dispensary, Markova str., 1, Syktyvkar, 167981, Russia.