

Прогнозирование течения хронической сердечной недостаточности с помощью машинного обучения: анализ международных методологических стандартов и их применения в российской исследовательской практике

Буренков Ю. В.¹, Шевцова В. И.¹, Ахьядов А. Д.², Алферова И. П.¹

¹ФГБОУ ВО "Воронежский государственный медицинский университет им. Н. Н. Бурденко" Минздрава России, Воронеж, Россия;

²ГБУЗ Московской области "Химкинская клиническая больница". Химки, Московская область, Россия

Цель обзора — на основе анализа международных стандартов методологического качества и обзора существующей практики разработать адаптированный для российских условий алгоритм применения машинного обучения (МО) для создания воспроизводимых моделей прогнозирования течения хронической сердечной недостаточности (ХСН). Для этого были систематизированы принципы международных стандартов PROBAST (Prediction model Risk Of Bias Assessment Tool, оценка риска систематической ошибки) и TRIPOD-ML (Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis — Machine Learning, отчетность), а также проведен расширенный поиск и методологическая оценка российских исследований за период 2016-2025 гг., в которых МО применялось у пациентов с ХСН. В ходе анализа установлен критический дефицит российских работ, посвященных прогнозированию течения ХСН. Обзор существующих исследований выявил системные нарушения: отсутствие внешней валидации, утечку данных на этапе отбора признаков, неполную отчетность и игнорирование оценки клинической полезности. Причины этих проблем носят системный характер и связаны с фрагментацией данных, междисциплинарным разрывом и регуляторными проблемами. Разрыв между международными стандартами и российской практикой обусловлен не технологическим отставанием, а недостатком методологической культуры. В качестве решения предложен поэтапный практический алгоритм, фокусирующийся на

строгом разделении данных, комплексной валидации, прозрачной отчетности и оценке клинической полезности. Внедрение данного алгоритма станет важным шагом для развития в России доказательного прогностического моделирования при ХСН.

Ключевые слова: машинное обучение, сердечная недостаточность, прогнозирование исходов, методологическое качество, PROBAST, TRIPOD-ML.

Отношения и деятельность: нет.

Поступила 24/12-2025

Рецензия получена 04/02-2026

Принята к публикации 24/03-2026



Для цитирования: Буренков Ю. В., Шевцова В. И., Ахьядов А. Д., Алферова И. П. Прогнозирование течения хронической сердечной недостаточности с помощью машинного обучения: анализ международных методологических стандартов и их применения в российской исследовательской практике. *Кардиоваскулярная терапия и профилактика*. 2026;25(5):4736. doi: 10.15829/1728-8800-2026-4736. EDN: BKSJDF

Predicting the heart failure course using machine learning: an analysis of international methodological standards and their application in Russian research practice

Burenkov Yu. V.¹, Shevtsova V. I.¹, Akhyadov A. D.², Alferova I. P.¹

¹Burdenko Voronezh State Medical University, Voronezh, Russia; ²Khimki Clinical Hospital, Khimki, Moscow Oblast, Russia

The review aim was to develop a machine learning (ML) algorithm adapted to Russian conditions for creating reproducible prediction models of heart failure (HF) course, based on an analysis of international methodological quality standards and a review of existing practices. To this end, the international standards Prediction Model Risk Of Bias Assessment Tool (PROBAST) and Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis Or Diagnosis — Ma-

chine Learning (TRIPOD-ML) were systematized. An extensive search and methodological assessment of Russian studies from 2016-2025, where machine learning was used in patients with HF, were also conducted. The analysis revealed a critical shortage of Russian studies devoted to predicting the HF course. A review of existing studies revealed the following systemic deficiencies: no external validation, data leakage at the feature selection stage, incomplete reporting, and neg-

*Автор, ответственный за переписку (Corresponding author):

e-mail: ghjd56@bk.ru

[Буренков Ю. В.* — ординатор, ORCID: 0009-0007-8705-7438, Шевцова В. И. — доцент, к. м. н., доцент кафедры инфекционных болезней и клинической иммунологии, ORCID: 0000-0002-1707-436X, Ахьядов А. Д. — врач по медицинской профилактике, ORCID: 0009-0000-1425-101X, Алферова И. П. — студентка 6 курса, ORCID: 0009-0002-9061-0963].

Адреса организаций авторов: ФГБОУ ВО "Воронежский государственный медицинский университет им. Н. Н. Бурденко" Минздрава России, ул. Студенческая, д. 10, Воронеж, 394036, Россия; ГБУЗ Московской области "Химкинская клиническая больница", Куркинское шоссе, д. 11, Химки, 141407, Россия.

Addresses of the authors' institutions: N. N. Burdenko Voronezh State Medical University, Studencheskaya str., 10, Voronezh, 394036, Russia; Khimki Clinical Hospital, Kurkinskoe Highway, 11, Khimki, 141407, Russia.

lect of clinical utility assessment. The causes of these problems are systemic and related to data fragmentation, interdisciplinary gaps, and regulatory gaps. The gap between international standards and Russian practice is not due to technological lag, but to a lack of methodological culture. A step-by-step, practical algorithm is proposed as a solution, focusing on strict data separation, comprehensive validation, transparent reporting, and clinical utility assessment. Implementation of this algorithm will be an important step in the development of evidence-based predictive modeling for HF in Russia.

Keywords: machine learning, heart failure, outcome prediction, methodological quality, PROBAST, TRIPOD-ML.

Relationships and Activities: none.

Burenkov Yu. V.* ORCID: 0009-0007-8705-7438, Shevtsova V. I. ORCID: 0000-0002-1707-436X, Akhyadov A. D. ORCID: 0009-0000-1425-101X, Alferova I. P. ORCID: 0009-0002-9061-0963.

*Corresponding author:
ghjd56@bk.ru

Received: 24/12-2025

Revision Received: 04/02-2026

Accepted: 24/03-2026

For citation: Burenkov Yu. V., Shevtsova V. I., Akhyadov A. D., Alferova I. P. Predicting the heart failure course using machine learning: an analysis of international methodological standards and their application in Russian research practice. *Cardiovascular Therapy and Prevention*. 2026;25(5):4736. doi: 10.15829/1728-8800-2026-4736. EDN: BKSJDF

ИИ — искусственный интеллект, МО — машинное обучение, ХСН — хроническая сердечная недостаточность, AUC — area under the curve (площадь под кривой), DCA — Decision Curve Analysis, PROBAST — Prediction model Risk Of Bias Assessment Tool (оценка риска систематической ошибки), TRIPOD-ML — Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis — Machine Learning (отчетность).

Ключевые моменты

Что известно о предмете исследования?

- Международные стандарты PROBAST и TRIPOD-ML задают строгие требования к созданию прогностических моделей с помощью машинного обучения.
- Прогнозирование течения хронической сердечной недостаточности с помощью машинного обучения является важной задачей персонализированной медицины.

Что добавляют результаты исследования?

- Впервые проведен методологический разбор, выявивший в России дефицит целевых исследований и системные нарушения (утечка данных, отсутствие валидации).
- Разработан практический алгоритм для российских исследователей, позволяющий создавать воспроизводимые и клинически полезные модели в отечественных условиях.

Key messages

What is already known about the subject?

- The international PROBAST and TRIPOD-ML standards set strict requirements for the creation of predictive models using machine learning.
- Predicting the heart failure course using machine learning is an important task in personalized medicine.

What might this study add?

- For the first time, a methodological analysis was conducted, revealing a shortage of targeted studies and systemic flaws (data leakage, no validation) in Russia.
- A practical algorithm has been developed for Russian researchers, enabling the creation of reproducible and clinically useful models in a domestic setting.

Введение

Хроническая сердечная недостаточность (ХСН) остается распространенной причиной госпитализации и преждевременной смерти, создавая высокую нагрузку на систему здравоохранения [1, 2]. Гетерогенность заболевания, а также тот факт, что даже однократный эпизод острой декомпенсации ХСН значительно ухудшает прогноз, делают повышение точности прогнозирования индивидуального риска ключевой научно-практической задачей [3].

Ограниченная прогностическая способность традиционных клинических шкал стимулирует поиск новых подходов [4, 5]. Машинное обучение (МО) рассматривается как перспективный инструмент для анализа больших объемов данных и созда-

ния персонализированных прогнозов [6]. По мере накопления исследований в этой области акцент сместился с демонстрации высоких метрик эффективности (AUC — area under the curve) на методологическую строгость [7, 8]. Международный консенсус, закрепленный в руководствах TRIPOD-ML (Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis — Machine Learning, отчетность) и PROBAST (Prediction model Risk Of Bias Assessment Tool, оценка риска систематической ошибки), подчеркивает критическую важность внешней валидации, анализа клинической полезности и прозрачной отчетности [9, 10].

В России также ведется исследовательская работа по применению МО в кардиологии. Тем не



Рис. 1 Ключевые требования руководства по отчетности TRIPOD-ML.

Примечание: SHAP — SHapley Additive exPlanations, TRIPOD-ML — Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis — Machine Learning.

менее, остается неясным, насколько существующие отечественные разработки соответствуют глобальным методологическим стандартам качества [11].

Цель обзора — на основе анализа международных стандартов методологического качества и обзора существующей практики разработать адаптированный для российских условий алгоритм применения МО для создания воспроизводимых моделей прогнозирования течения ХСН.

Методологические подходы

Поиск литературы проводился в базах данных PubMed и eLibrary за период 2016-2025гг. Стратегия включала два независимых подхода:

1) Для отбора международных исследований по МО и ХСН использовались термины: machine learning, artificial intelligence, prediction model, prognostic model, heart failure. Для поиска методологических руководств применялись следующие ключевые слова: TRIPOD-ML, PROBAST, validation.

2) Для анализа российских исследований использовались следующие запросы: машинное обучение, искусственный интеллект (ИИ), логистическая регрессия, градиентный бустинг, случайный лес, сердечная недостаточность, ХСН, прогноз, прогнозирование.

В обзор включались публикации, соответствующие следующим критериям:

- Имеется открытый доступ к полной версии статьи на русском или английском языках;
- Для англоязычных работ: статьи, посвященные принципам, стандартам или являются обзорами методологии разработки прогностических моделей МО;
- Для российских работ: оригинальные исследования, целью которых была разработка модели МО для прогнозирования течения ХСН, систематические обзоры применения методов ИИ в отечественной практике.

Анализ проводился по следующим аспектам: тип решаемой задачи и используемые алгоритмы МО, подход к валидации модели, отчетность и оценивание риска систематической ошибки, оценка клинической полезности.

В связи с нарративным характером обзора и разнородностью включенных источников метаанализ не проводился. Результаты структурированы по 4-м тематическим блокам, отражающим логику перехода от общих принципов к практическим рекомендациям.

Результаты

Концептуальные основы применения МО для прогнозирования в кардиологии

МО — это раздел ИИ, целью которого является создание алгоритмов, выявляющих закономерности в данных для прогнозирования течения заболеваний или принятия решений [4].

Ключевые подходы к МО различаются в зависимости от наличия в данных сведений об исходе: обучение с учителем (алгоритм обучен на примерах с известными исходами) и обучение без учителя (выявляются скрытые закономерности с обнаружением однородных кластеров, фенотипов) [12, 13]. Ансамблевые методы (Random Forest, XGBoost) повышают точность за счет объединения прогнозов множества простых моделей, но их сложность снижает интерпретируемость принятых решений. Для повышения прозрачности применяют методы объяснимого ИИ (XAI, explainable artificial intelligence), такие как SHAP-анализ (SHapley Additive exPlanations), которые позволяют оценить вклад каждого признака в итоговый прогноз [14].

Прогнозирование течения ХСН — методологически сложная задача, требующая предотвращения "утечки данных", борьбы с дисбалансом классов (использование метрик, устойчивых к дисбалансу (F1-score, PR-AUC)) и обеспечения интерпретируемости моделей (XAI) [9, 10, 14, 15].

Таким образом, МО предлагает кардиологии мощный инструментарий для преобразования разнородных клинических данных в персонализированные прогнозы, но его эффективное применение сопряжено с рядом методологических сложностей. Для их системного решения и обеспечения качества прогностических исследований международным сообществом были разработаны специализированные стандарты.

Международные стандарты методологического качества

Несмотря на активно растущее число публикаций, посвященных МО в медицине, систематические обзоры указывают на системную проблему: значительная часть исследований ограничивается демонстрацией высокой точности на внутренних данных без должной проверки на независимых когортах. Данный кризис воспроизводимости носит глобальный характер и в равной степени затрагивает как крупные международные, так и локальные, в т.ч. отечественные исследования [10, 16-18].

Ответом научного сообщества стало формирование методологического консенсуса и создание специализированных инструментов, призванных стандартизировать процесс разработки, отчетности и оценки прогностических моделей. Ключевыми из них являются инструмент оценки риска систематической ошибки PROBAST и руководство по отчетности TRIPOD-ML [19].

PROBAST фокусируется на 4-х разделах (доменах). Из них наиболее критическими для МО являются посвященные предикторам и непосредственно анализу.

Домен 2 (предикторы): для исключения "утечки данных" все предикторы должны быть измерены до наступления изучаемого исхода.

Домен 4 (анализ): ключевой среди всех разделов, оценивающий, насколько надежно проверена модель:

1. Валидация: выстраивается четкая иерархия доказательности от наименее надежной внутренней кросс-валидации к обязательной внешней проверке на независимой выборке. Отсутствие последней автоматически приводит к высокой оценке риска систематической ошибки [9].

2. Обработка данных: анализируется метод работы с пропущенными значениями предикторов (простое удаление таких случаев является методологически слабым подходом).

3. Размер выборки: существует эмпирическое правило "не менее 10 событий на предиктор", которое помогает минимизировать риск переобучения, следовательно, здесь проводят оценку достаточности числа событий (events per variable, EPV) [12, 17, 20].

TRIPOD-ML предъявляет конкретные требования к отчетности. Ключевые требования стандарта систематизированы на рисунке 1 [19, 21].

Даже методологически выверенная и хорошо описанная модель должна доказать свою практическую значимость. Для этого необходимы оценка калибровки (соответствие предсказанных вероятностей реальной частоте событий) и анализ кривых принятия клинических решений (Decision Curve Analysis, DCA), показывающий пользу модели по сравнению со стратегиями "лечить всех" или "не лечить никого" [22, 23].

Таким образом, можно сформулировать современный стандарт для разработки моделей с использованием МО: предотвращение систематических ошибок через следование критериям PROBAST на этапе планирования и проведения исследования, обеспечение прозрачности и воспроизводимости с соблюдением рекомендации TRIPOD-ML при подготовке публикации, проведение оценки непосредственной клинической полезности с помощью анализа калибровки и DCA.

Анализ российской исследовательской практики: вакуум в разработке и существующие ограничения

Систематический поиск и его анализ. Поисковая стратегия для оценки состояния исследовательского поля в России была сфокусирована на выявлении оригинальных исследований, где декларировалось использование методов МО для решения задач, связанных с ХСН. Критерии включения исследований в обзор: наличие открытого доступа к полнотекстовой версии, разработка модели прогнозирования течения ХСН, использование методов, относящихся к области МО. Критерии невключения: работа посвящена прогнозированию развития ХСН, методология исследования ограничена классической статистикой без элементов прогностического моделирования, обзоры литературы, тезисы, материалы конференций.

Результаты поиска подтвердили тезис о нахождении области в стадии становления. Было найдено 593 публикации. После скрининга названий и аннотаций для полнотекстового анализа отобраны 23 работы, из которых 8 соответствовали критериям включения. Важно отметить, что лишь в 5 исследованиях авторы использовали в названии или тексте терминологию, позволяющую отнести их к области МО. Остальные 3 работы были включены в анализ на том основании, что используемые в них методы относятся к широкому классу методов статистического обучения (логистическая регрессия), однако авторы не идентифицировали свои исследования, как работы по МО. При этом наблюдается значительная гетерогенность в прогнозируемом исходе (смерть, госпитализация, эффективность терапии и др.), изучаемой популяции (общая когорта ХСН, ХСН в сочетании с сахарным диабетом 2 типа, пациенты с ХСН и имплантированными устройствами и др.) и заявленных методах МО. Сводная характеристика работ представлена в таблице 1.

Таблица 1

Характеристика российских прогностических исследований, посвященных ХСН

№	Авторы, год	Прогнозируемый исход или иная цель прогноза	Размер когорты	Метрики эффективности	Проведение валидации	Тип МО-модели
1	Драгомирецкая Н. А. и соавт., 2024 [24]	Смерть от всех причин	135 пациентов	AUC	Нет	Логистическая регрессия
2	Осипова О. А. и соавт., 2023 [25]	Оценка влияния проводимой фармакотерапии	170 пациентов	Оценка качества жизни	Нет	Нейросетевая модель
3	Коваленко Е. В. и соавт., 2023 [30]	Комбинированный исход (смерть, госпитализация) у пациентов с ХСН и СД 2 типа	246 пациентов	AUC	Разделение на тестовую и обучающую выборки	Программируемая МО-модель
4	Лебедева Н. Б. и соавт., 2024 [29]	Острая декомпенсация у пациентов с ХСН со сниженной фракцией выброса и ИКД	260 пациентов	AUC	Внешняя валидация	Логистическая регрессия
5	Коваленко Е. В. и соавт., 2023 [26]	Комбинированный исход (сердечно-сосудистая смерть, декомпенсация ХСН) у пациентов с ХСНсФВ и СД 2 типа, ХБП, перенесших COVID-19	181 пациент	AUC	Нет	Логистическая регрессия
6	Полунина Е. А. и соавт., 2019 [27]	Увеличение функционального класса ХСН по NYHA ≥ 1 в течение 3 лет у пациентов с ФВ	345 пациентов + 60 контроль (здоровые)	AUC	Нет	Кластерный анализ, логистическая регрессия
7	Илов Н. Н. и соавт., 2025 [31]	Однолетняя летальность после имплантации ИКД	451 пациент	AUC	Разделение на тестовую и обучающую выборки	Логистическая регрессия
8	Мухамбетова Г. Н. и соавт., 2019 [28]	Прогрессирование ХСН у пациентов с ишемической кардиомиопатией в течение 3 лет	40 пациентов	AUC	Нет	Логистическая регрессия

Примечание: ИКД — имплантируемый кардиовертер-дефибриллятор, МО — машинное обучение, СД — сахарный диабет, ФВ — фракция выброса, ХСН — хроническая сердечная недостаточность, ХСНсФВ — ХСН с сохраненной фракцией выброса, ХБП — хроническая болезнь почек, AUC — Area Under the Curve (площадь под кривой), COVID-19 — Corona Virus Disease 2019, NYHA — New York Heart Association.

Таким образом, клинически значимая задача — прогнозирование течения ХСН — в российской научной литературе практически не представлена. Немногочисленные существующие работы решают разнородные задачи на узких группах пациентов, что не позволяет сформировать единую доказательную базу.

Глубокий методологический разбор. Проведенный анализ выявил 4 методологические проблемы, которые ставят под сомнение воспроизводимость и клиническую применимость разработанных моделей.

Проблема 1. Проблема адекватности выбора метода — неоптимальное использование сложных алгоритмов на малых выборках или их применение не по назначению.

Проблема 2. Некорректная валидация и игнорирование риска "утечки данных" — отбор признаков и настройка модели на всей выборке, отсутствие внешней валидации.

Проблема 3. Низкая прозрачность и воспроизводимость работ — неполное описание методологии, отсутствие публикации кода.

Проблема 4. Ограниченность оценочных метрик — ориентация только на AUC-ROC (площадь под ROC-кривой) без оценки калибровки и клинической полезности.

Детальное описание каждой проблемы с примерами из конкретных исследований [24-31] и анализом последствий приведено в таблице 2.

Существующие системные ограничения. Выявленные проблемы носят системный характер и их причины заключены в условиях, в которых работает российский исследователь:

— Во-первых, несмотря на активное развитие регистров ХСН в России, их использование для задач внешней валидации прогностических моделей сопряжено с рядом трудностей. Как показано в систематическом обзоре Посненковой О. М. и др., данные большинства отечественных регистров не являются общедоступными [32]. Таким образом, исследователи вынуждены работать с ограниченными одноцентровыми выборками.

— Во-вторых, из числа рассмотренных работ ни в одной не было указаний на взаимодействие со специалистами по МО или биостатистике. Между тем, междисциплинарный подход способствует корректному проведению прогностических исследований с использованием МО [21]. Отсутствие такого взаимодействия может приводить к поверхностному применению сложных методов или их излишнему смешению.

Обобщенные результаты методологического разбора российских исследований

Требования стандартов (PROBAST/TRIPOD-ML)	Реальная практика	Вероятные последствия для прогностической модели
Использовать сложные алгоритмы для решения соответствующих им по сложности задач на достаточных по объему выборках	В исследовании [24] алгоритм случайного леса применялся исключительно для ранжирования признаков, а финальная модель представляла собой логистическую регрессию. В работе [25] применялась нейросетевая модель на ограниченной по объему выборке	Остаются нереализованными ключевые преимущества сложных методов, усложняется проведение исследования без явного выигрыша. При отсутствии должной валидации использование сложных моделей на малой выборке приведет к повышенному риску переобучения и снизит воспроизводимость результатов
Обязательно разделять данные на независимые обучающую и тестовую выборки до начала любого анализа. Внешняя валидация — "золотой стандарт" для доказательности	В большинстве работ [24, 26-28] отбор признаков проводился на всей выборке. Внешняя валидация проводилась лишь в одном исследовании [29], но на данных из другого временного промежутка того же регистра	Утечка данных ведет к искусственному завышению AUC. Результаты становятся невоспроизводимыми на новых данных, что делает модель клинически неприменимой [9]. Внешняя валидация на данных из одного регистра может потребовать дополнительного анализа из-за большей обученности модели на особенностях, присущих именно этой базе данных
Детально описывать методологию исследования: от источника данных и методов обработки пропусков до этапов настройки модели и публикации кода	В рассмотренных работах отсутствует описание обработки пропущенных значений, стратегии борьбы с дисбалансом классов, этапов настройки модели, деталей разделения на тренировочную и тестовую выборки [26-28, 31]. Авторами также не оставлены ссылки на публично доступный код [26, 30]	Неполная отчетность делает невозможной независимую проверку и воспроизведение результатов
Не ограничиваться только показателями AUC при оценке эффективности модели. Оценивать клиническую пользу с помощью анализа калибровки и кривых принятия клинических решений	Все работы, использующие показатель AUC в качестве метрики эффективности, не применяли анализ кривой принятия решений и не отображали графики калибровки [24, 26-31]	Оценивается лишь способность модели к ранжированию пациентов по риску, без оценки потенциальной пользы для принятия клинических решений

Примечание: AUC — Area Under the Curve (площадь под кривой), PROBAST — Prediction model Risk Of Bias Assessment Tool (оценка риска систематической ошибки), TRIPOD-ML — Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis — Machine Learning (отчетность).

— В-третьих, отсутствие формальных требований со стороны редакций российских научных журналов к обязательному соблюдению TRIPOD-ML, публикации кода и проведению внешней валидации снижает мотивацию исследователей к обеспечению прозрачности и воспроизводимости своих работ.

Следует отметить, что выявленные недостатки встречаются и в зарубежных исследованиях, где проблема воспроизводимости также стоит достаточно остро. Систематически обзоры подчеркивают необходимость ответственного подхода к валидации моделей и выбора оптимального метода для решения задач исследования [10, 16, 17].

Проведенный методологический разбор свидетельствует о том, что область прогностического моделирования при ХСН с использованием МО в России находится в стадии становления и характеризуется значительным методологическим разрывом с международными стандартами. Развитие области зависит, в первую очередь, от методологической культуры: внедрение культуры строгой валидации, прозрачной отчетности и оценки реальной клинической значимости. Этот вывод служит

прямым обоснованием для разработки практической инструкции, которая позволит российским исследователям, действуя в условиях существующих барьеров, создавать модели, соответствующие принятым стандартам доказательности.

Практический алгоритм для российских исследователей

На основе выявленных системных проблем предлагается практический алгоритм действий. Его цель — способствовать созданию прогностических моделей, соответствующих международным стандартам качества и адаптированных к российским условиям. Ключевой принцип: строгая методология важнее технологической сложности. Последовательность шагов визуализирована на рисунке 2.

Шаг 1. Подготовка и постановка задач. Сформировать междисциплинарную команду: кардиолог (специалист соответствующей области, определяющий клиническую значимость задачи и исхода), специалист по данным (data scientist, отвечающий за программирование и методологию МО) и биостатистик (контролирует дизайн исследования и анализ). До начала работы с данными команда совместно



Рис. 2 Алгоритм разработки и валидации прогностических моделей МО для клинических исследований.

Примечание: МО — машинное обучение, РКИ — рандомизированное контролируемое исследование, AUC-ROC – Area Under the Receiver Operating Characteristic Curve (площадь под ROC-кривой), DCA — Decision Curve Analysis, PROBAST — Prediction model Risk Of Bias Assessment Tool (оценка риска систематической ошибки), TRIPOD-ML — Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis — Machine Learning (отчетность).

формулирует и фиксирует в протоколе следующие элементы исследования:

- Четкое определение прогнозируемого исхода (например, "госпитализация по поводу декомпенсации ХСН в течение 90 дней после выписки").
- Целевая популяция и критерии включения/невключения.
 - План сбора и источники данных.
 - План валидации.

Шаг 2. Разделение данных и их обработка. Перед любым анализом вся доступная когорта случайным образом делится на тренировочную (обычно 70-80%) и тестовую (20-30%) выборки [8]. Тестовая выборка не используется до финальной оценки модели. Все процедуры обработки пропущенных значений, кодирования категориальных признаков и масштабирования должны быть обучены исключительно на тренировочных данных, а затем применены к тестовым. Весь процесс разработки должен быть реализован в виде исполняемого кода (например, на Python) — это основа воспроизводимости исследования [21].

Шаг 3. Разработка и валидация модели. 1) Выбор и настройка модели исключительно на тренировоч-

ных данных: начинать с простых интерпретируемых методов (например, логистическая регрессия со специальными настройками, предотвращающими переобучение), использовать кросс-валидацию для их оптимальной настройки (подбора параметров), переходить к сложным ансамблевым моделям только при доказанном недостатке качества и наличии достаточно большого объема данных. 2) Комплексная оценка на тестовом наборе (проводится единожды): расчет дискриминации (способности модели ранжировать пациентов, AUC-ROC), построение графика калибровки и определение Brier score (точность предсказанных вероятностей), анализ кривой принятия решений (DCA).

Шаг 4. Отчетность и публикация. При подготовке публикации необходимо соблюдать пункты руководства TRIPOD-ML. Весь код, включая подготовку, обучение и валидацию модели, выкладывается в открытый доступ. В статье детально описываются все этапы шагов 1-3.

Шаг 5. Путь к внедрению в практику. Разрабатывается рабочий прототип (например, веб-калькулятор) для пилотного тестирования. Заранее планируется проведение проспективного этапа исследования,

в котором модель будет работать с новыми пациентами, а ее прогнозы — регистрироваться для последующей проверки с реально наступившими исходами. Рассматривается дизайн рандомизированного исследования, в котором одна группа врачей использует подсказки модели, а другая — нет, для оценки влияния на клинические решения и исходы лечения.

Заключение

Проведенный анализ раскрывает суть разрыва между международными стандартами разработки прогностических моделей с использованием МО и текущей российской исследовательской практикой в области ХСН.

Международные стандарты (PROBAST, TRIPOD-ML) требуют минимизации систематических ошибок (особенно за счет строгого разделения данных и внешней валидации), обеспечение прозрачной отчетности и оценку клинической полезности (DCA, калибровка).

Анализ российских исследований по ХСН выявил две ключевые проблемы: критически малое количество работ, посвященных прогнозированию течения ХСН, и систематические методологиче-

ские нарушения: утечка данных, отсутствие внешней валидации, низкая прозрачность и ориентация исключительно на технические метрики.

Выявленные проблемы носят системный характер. Они следуют из сложившихся условий работы российского исследователя: фрагментация данных, междисциплинарный разрыв между клиницистами и специалистами по МО, отсутствие регуляторных требований к публикациям в данной области.

В качестве конструктивного решения предложен практический алгоритм для российских исследователей. Его основа — последовательность обязательных шагов, смещающих фокус с технологической сложности на воспроизводимость и клиническую обоснованность результатов. Данный алгоритм адаптирует международные стандарты к условиям отечественного здравоохранения и охватывает весь цикл исследования — от постановки задачи и сбора данных до валидации модели и планирования ее клинической проверки.

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

Литература/References

- Larina VN, Kokorin VA, Larin VG, et al. Decompensated heart failure: a reconceptualization in the light of updated consensus statement of the European Society of Cardiology. *Russian Journal of Cardiology*. 2023;28(12):5581. (In Russ.) Ларина В.Н., Кокорин В.А., Ларин В.Г. и др. Декомпенсация хронической сердечной недостаточности: новый взгляд на проблему в свете обновленного консенсуса экспертов Европейского общества кардиологов. *Российский кардиологический журнал*. 2023;28(12):5581. doi:10.15829/1560-4071-2023-5581.
- Drapkina OM, Boytsov SA, Omelyanovskiy VV, et al. Socio-economic impact of heart failure in Russia. *Russian Journal of Cardiology*. 2021;26(6):4490. (In Russ.) Драпкина О.М., Бойцов С.А., Омеляновский В.В. и др. Социально-экономический ущерб, обусловленный хронической сердечной недостаточностью, в Российской Федерации. *Российский кардиологический журнал*. 2021;26(6):4490. doi:10.15829/1560-4071-2021-4490.
- Larina VN, Skiba IK. Prospects for predicting and preventing the heart failure deterioration: an analytical review. *Russian Journal of Cardiology*. 2024;29(9):5854. (In Russ.) Ларина В.Н., Скиба И.К. Перспективы прогнозирования и профилактики ухудшения течения хронической сердечной недостаточности: аналитический обзор. *Российский кардиологический журнал*. 2024;29(9):5854. doi:10.15829/1560-4071-2024-5854.
- Shin S, Austin PC, Ross HJ, et al. Machine learning vs. conventional statistical models for predicting heart failure readmission and mortality. *ESC Heart Fail*. 2020;8(1):106-15. doi:10.1002/ehf2.13073.
- Tohyama T, Ide T, Ikeda M, et al. Machine learning-based model for predicting 1 year mortality of hospitalized patients with heart failure. *ESC Heart Fail*. 2021;8(5):4077-85. doi:10.1002/ehf2.13556.
- Saqib M, Perswani P, Muneem A, et al. Machine learning in heart failure diagnosis, prediction, and prognosis: review. *Ann Med Surg (Lond)*. 2024;86(6):3615-23. doi:10.1097/MS9.0000000000002138.
- Abreu J, Seringa J, Magalhaes T. Machine learning methods, applications and economic analysis to predict heart failure hospitalisation risk: a scoping review. *BMJ Open*. 2025;15(6):e093495. doi:10.1136/bmjopen-2024-093495.
- Mpanya D, Celik T, Klug E, et al. Predicting mortality and hospitalization in heart failure using machine learning: A systematic literature review. *Int J Cardiol. Heart Vasc*. 2021;34:100773. doi:10.1016/j.ijcha.2021.100773.
- Wolff RF, Moons KGM, Riley RD, et al. PROBAST: A Tool to Assess the Risk of Bias and Applicability of Prediction Model Studies. *Ann Intern Med*. 2019;170(1):51-8. doi:10.7326/M18-1376.
- Alnomasy N, Pangket P, Mostoles R, et al. Predictive Performance of Machine Learning Models for Heart Failure Readmission: A Systematic Review. *Biomedicine*. 2025;13(9):2111. doi:10.3390/biomedicine13092111.
- Kovelkova MN, Iakovleva EG. Artificial intelligence in the prevention and diagnosis of cardiovascular diseases in Russia (literature review). *Siberian Journal of Clinical and Experimental Medicine*. 2025;40(1):28-41. (In Russ.) 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. doi:10.29001/2073-8552-2025-40-1-28-41.
- Yang HS, Rhoads DD, Sepulveda J, et al. Building the Model. *Arch Pathol Lab Med*. 2023;147(7):826-36. doi:10.5858/arpa.2021-0635-RA.
- Ignatenko GA, Sedakov IE, Kolycheva OV, et al. Artificial intelligence in cardiovascular diseases: prospects for diagnostics and therapy. *Neoplasm*. 2023;15(4):10-6. (In Russ.) Игнатенко Г.А., Седиков И.Е., Кольчева О.В. и др. Искусственный интеллект при сердечно-сосудистых заболеваниях: перспективы диагностики и терапии. *Новообразование*. 2023;15(4):10-6.
- Shakhgeldyan KI, Kuskun NS, Domzhalov IG, et al. Random forest of risk factors as a predictive tool for adverse events in clinical medicine. *Computer Research and Modeling*. 2025;17(5):987-

1004. (In Russ.) Шахгельдян К. И., Куксин Н. С., Домжалов И. Г. и др. Случайный лес факторов риска как прогностический инструмент неблагоприятных событий в клинической медицине. Компьютерные исследования и моделирование. 2025;17(5):987-1004. doi:10.20537/2076-7633-2025-17-5-987-1004.
15. Ru B, Tan X, Liu Y, et al. Comparison of Machine Learning Algorithms for Predicting Hospital Readmissions and Worsening Heart Failure Events in Patients With Heart Failure With Reduced Ejection Fraction: Modeling Study. *JMIR Form Res.* 2023;7:e41775. doi:10.2196/41775.
 16. Błaziak M, Urban S, Wietrzyk W, et al. An Artificial Intelligence Approach to Guiding the Management of Heart Failure Patients Using Predictive Models: A Systematic Review. *Biomedicines.* 2022;10(9):2188. doi:10.3390/biomedicines10092188.
 17. Jia Y, Cui N, Jia T, et al. Prognostic models for patients suffering a heart failure with a preserved ejection fraction: a systematic review. *ESC Heart Fail.* 2024;11(3):1341-51. doi:10.1002/ehf2.14696.
 18. Mishkin IA, Kontsevaya AV, Gusev AV, et al. Prediction of cardiovascular events using proportional risk models and machine learning models: a systematic review. *Current problems of health care and medical statistics.* 2023(2):804-29. (In Russ.) Мишкин И. А., Концевая А. В., Гусев А. В. и др. Прогнозирование сердечно-сосудистых событий с помощью моделей пропорциональных рисков и моделей машинного обучения: систематический обзор. Современные проблемы здравоохранения и медицинской статистики. 2023(2):804-29. doi:10.24412/2312-2935-2023-2-804-829.
 19. Collins GS, Dhiman P, Andaur Navarro CL, et al. Protocol for development of a reporting guideline (TRIPOD-AI) and risk of bias tool (PROBAST-AI) for diagnostic and prognostic prediction model studies based on artificial intelligence. *BMJ Open.* 2021;11(7):e048008. doi:10.1136/bmjopen-2020-048008.
 20. Iba K, Shinozaki T, Maruo K, et al. Re-evaluation of the comparative effectiveness of bootstrap-based optimism correction methods in the development of multivariable clinical prediction models. *BMC Med Res Methodol.* 2021;21:9. doi:10.1186/s12874-020-01201-w.
 21. Moons KGM, Altman DG, Reitsma JB, et al. Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis (TRIPOD): Explanation and Elaboration. *Ann Intern Med.* 2015;162(1):W1-73. doi:10.7326/M14-0698.
 22. Austin PC, Putter H, Giardiello D, et al. Graphical calibration curves and the integrated calibration index (ICI) for competing risk models. *Diagn Progn Res.* 2022;6(1):2. doi:10.1186/s41512-021-00114-6.
 23. Vickers AJ, Holland F. Decision curve analysis to evaluate the clinical benefit of prediction models. *Spine J.* 2021;21(10):1643-8. doi:10.1016/j.spinee.2021.02.024.
 24. Dragomiretskaya NA, Tolmacheva AV, Vetluzhskaya MV, et al. Multifactor model to predict adverse outcomes in patients with chronic heart failure with preserved and moderately reduced left ventricular ejection fraction. *Practical medicine.* 2024;22(3):48-56. (In Russ.) Драгомирецкая Н. А., Толмачева А. В., Ветлужская М. В. и др. Многофакторная модель прогнозирования неблагоприятных исходов у пациентов с хронической сердечной недостаточностью с сохраненной и умеренно сниженной фракцией выброса левого желудочка. *Практическая медицина.* 2024;22(3):48-56. doi:10.32000/2072-1757-2024-3-48-56.
 25. Osipova OA, Kontsevaya AV, Demko VV, et al. Elements of artificial intelligence in a predictive personalized model of pharmacotherapy choice in patients with heart failure with mildly reduced ejection fraction of ischemic origin. *Cardiovascular Therapy and Prevention.* 2023;22(7):3619. (In Russ.) Осипова О. А., Концевая А. В., Демко В. В. и др. Использование элементов искусственного интеллекта в прогнозирующей модели персонализированного подхода к выбору фармакотерапии у больных хронической сердечной недостаточностью с умеренно низкой фракцией выброса ишемического генеза. *Кардиоваскулярная терапия и профилактика.* 2023;22(7):3619. doi:10.15829/1728-8800-2023-3619.
 26. Kovalenko EV, Markova LI, Belaya OL, et al. Prognostic significance of cardiac dysfunction markers in comorbid patients with chronic heart failure. *Lechaschi Vrach.* 2023;26(12):15-24. (In Russ.) Коваленко Е. В., Маркова Л. И., Белая О. Л. и др. Прогностическое значение маркеров кардиальной дисфункции у коморбидных больных с хронической сердечной недостаточностью. *Лечащий врач.* 2023;26(12):15-24. doi:10.51793/OS.2023.26.12.002.
 27. Polunina EA, Voronina LP, Popov EA, et al. Prognostic algorithms for the progression of chronic heart failure depending on the clinical phenotype. *Cardiovascular Therapy and Prevention.* 2019;18(3):41-7. (In Russ.) Полунина Е. А., Воронина Л. П., Попов Е. А. и др. Прогностические алгоритмы прогрессирования хронической сердечной недостаточности в зависимости от клинического фенотипа. *Кардиоваскулярная терапия и профилактика.* 2019;18(3):41-7. doi:10.15829/1728-8800-2019-3-41-47.
 28. Mukhambetova GN, Voronina LP, Polunina OS, et al. The mathematical algorithm for predicting the progression of chronic heart failure in patients with ischemic cardiomyopathy. *Modern problems of science and education.* 2019;(6):108. (In Russ.) Мухамбетова Г. Н., Воронина Л. П., Полунина О. С. и др. Математический алгоритм прогнозирования прогрессирования хронической сердечной недостаточности у пациентов с ишемической кардиомиопатией. *Современные проблемы науки и образования.* 2019;(6):108.
 29. Lebedeva NB, Egle AP, Argunova YuA, et al. Digital model for predicting the risk of developing acute decompensated heart failure. *Rational Pharmacotherapy in Cardiology.* 2024;20(3):309-15. (In Russ.) Лебедева Н. Б., Егле А. П., Аргунова Ю. А. и др. Цифровая модель прогнозирования риска острой декомпенсации сердечной недостаточности. *Рациональная Фармакотерапия в Кардиологии.* 2024;20(3):309-15. doi:10.20996/1819-6446-2024-3034.
 30. Kovalenko EV, Markova LI, Belaya OL. Characteristics of heart failure and the predictors of adverse outcomes in patients with cardiovascular pathology, type 2 diabetes mellitus and chronic kidney disease. *International Journal of Heart and Vascular Diseases.* 2023;11(39):17-34. (In Russ.) Коваленко Е. В., Маркова Л. И., Белая О. Л. Особенности течения сердечной недостаточности и возможности прогнозирования неблагоприятных исходов у больных сердечно-сосудистой патологией, сахарным диабетом 2 типа и хронической болезнью почек. *Международный журнал сердца и сосудистых заболеваний.* 2023;11(39):17-34. EDN: AKPDQY.
 31. Ilov NN, Palnikova OV, Stoppel DR, et al. Lethal risk index — a novel tool for predicting one-year mortality in patients with heart failure with reduced ejection fraction. *Russian Journal of Cardiology.* 2025;30(6):6222. (In Russ.) Илов Н. Н., Пальникова О. В., Стомпель Д. Р. и др. Индекс летального риска — новый инструмент прогнозирования однолетней летальности больных хронической сердечной недостаточностью со сниженной фракцией выброса левого желудочка. *Российский кардиологический журнал.* 2025;30(6):6222. doi:10.15829/1560-4071-2025-6222.
 32. Posnenkova OM, Bogdanova TM, Fedonnikov AS. Practical and methodological aspects of managing a registry to assess the quality of health care for patients with heart failure. A systematic review. *Russian Journal of Cardiology.* 2025;30(9S):6345. (In Russ.) Посненкова О. М., Богданова Т. М., Федонников А. С. Практические и методологические аспекты организации регистра для оценки качества медицинской помощи пациентам с хронической сердечной недостаточностью. *Систематический обзор. Российский кардиологический журнал.* 2025;30(9S):6345. doi:10.15829/1560-4071-2025-6345.