



УДК 616.132.2

DOI 10.17802/2306-1278-2025-14-3-96-111

ОБЗОР СОВРЕМЕННЫХ ПРЕДСКАЗАТЕЛЬНЫХ МОДЕЛЕЙ МНОЖЕСТВЕННЫХ ОСЛОЖНЕНИЙ ЧКВ: РОЛЬ МАШИННОГО ОБУЧЕНИЯ И ТРАДИЦИОННЫХ ПОДХОДОВ

А.А. Гороховский, С.Е. Пекарский, А.Е. Баев, М.Г. Тарасов, И.В. Суслов, Е.С. Гергерт,
Ю.И. Богданов, С.М. Султанов

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

Основные положения

• Впервые представлен сравнительный обзор современных моделей одновременного предсказания нескольких осложнений чрескожных коронарных вмешательств, в том числе на основе машинного обучения. Продемонстрировано преимущество моделей машинного обучения (особенно XGBoost), которые даже при использовании единого набора данных обладают высокой точностью и способны учитывать сложные нелинейные факторы, ранее не учтенные в традиционных шкалах риска. Определены три ключевые модели, способные одновременно предсказывать несколько исходов без дублирования переменных, что закладывает основу для более эффективных и универсальных клинических инструментов.

Резюме

Современные модели прогнозирования осложнений чрескожных коронарных вмешательств (ЧКВ) стремительно эволюционируют под влиянием новых технологий машинного обучения (МО). В данной работе представлен сравнительный обзор существующих методов, ориентированных на одновременное предсказание нескольких осложнений ЧКВ (смерть, кровотечение, острая почечная недостаточность и др.). Сравняются традиционные шкалы стратификации риска (NCDR Cath-PCI, CART VA и др.) и современные алгоритмы МО. В базе данных PubMed по ключевым словам были найдены 2 667 работ, опубликованных за последние 10 лет и посвященных прогнозированию осложнений ЧКВ. После исключения публикаций, не представляющих в достаточном объеме информации о дизайне, построении модели и анализе виртуальных данных, дублирующих, предсказывающих только один исход, а также обзоров и отчетов о клинических случаях отобрано 9 наиболее релевантных исследований, охватывающих многотысячные реестры США, Японии и международные базы данных. Несмотря на разнообразие подходов, лишь ограниченное число моделей формально способно одновременного прогнозировать несколько осложнений на основе единого набора переменных. При этом в большинстве исследований использование МО (особенно XGBoost) повышало точность по сравнению с традиционными методами. Полученные результаты подтверждают перспективность применения машинного обучения для множественной оценки рисков ЧКВ. Однако условиями их эффективного использования в клинической практике являются надежная внешняя валидация, адаптация к локальным особенностям и учет технологических инноваций (внутрикоронарная визуализация, инвазивная физиология). Развитие методов прогнозирования, использующих МО и отвечающих этим требованиям, позволит существенно повысить точность стратификации рисков ЧКВ, оптимизировать выполнение вмешательств и улучшить исходы лечения пациентов с ишемической болезнью сердца. Естественным расширением методологии является включение в модели данных внутрисосудистой визуализации и инвазивной физиологии.

Ключевые слова

Ишемическая болезнь сердца • Чрескожное коронарное вмешательство • Машинное обучение • Осложнения после ЧКВ • Предсказательные модели • Шкалы риска

Поступила в редакцию: 26.02.2025; поступила после доработки: 18.03.2025; принята к печати: 12.04.2025

Для корреспонденции: Алексей Александрович Гороховский, alegorohovs@yandex.ru; адрес: ул. Киевская, 111А, Томск, Российская Федерация, 634012

Corresponding author: Alexey A. Gorokhovsky, alegorohovs@yandex.ru; address: Kievskaya St., 111a, Tomsk, Russian Federation, 634012

REVIEW OF MODERN PREDICTIVE MODELS OF MULTIPLE COMPLICATIONS AFTER PCI: THE ROLE OF MACHINE LEARNING AND TRADITIONAL APPROACHES

A.A. Gorokhovskiy, S.E. Pekarskiy, A.E. Baev, M.G. Tarasov, I.V. Suslov, E.S. Gergert, Yu.I. Bogdanov, S.M. Sultanov

Cardiology Research Institute, branch of the Federal State Budgetary Scientific Institution “Tomsk National Research Medical Center of the Russian Academy of Sciences”, Kievskaya St., 111a, Tomsk, Russian Federation, 634012

Highlights

- The first comparative review of modern models for predicting multiple PCI complications simultaneously, including those based on machine learning, is presented. The advantage of machine learning models (especially XGBoost) is demonstrated, which, even when using a single data set, have high accuracy and are able to take into account complex nonlinear factors that were not previously taken into account by traditional risk scales. The top 3 models have been identified that can simultaneously predict multiple outcomes without duplicating variables, which lays the foundation for more effective and versatile clinical tools.

Abstract

Modern models for predicting complications of percutaneous coronary interventions (PCI) are rapidly evolving under the influence of new machine learning (ML) technologies. This paper presents a comparative review of existing methods aimed at simultaneously predicting multiple complications of PCI (death, bleeding, acute kidney failure, etc.). The study compares traditional risk stratification scales (such as NCDR Cath-PCI, CART VA, and others) with modern ML algorithms. A keyword search in the PubMed database over the past 10 years identified 2 667 publications related to PCI complication prediction. After excluding publications that did not provide sufficient information regarding study design, model construction, and data analysis, those based on virtual data analysis, single-outcome prediction studies, as well as reviews and clinical case reports, 9 of the most relevant studies were selected. These studies covered large registries from the USA, Japan, and international databases. Despite the diversity of approaches, only a limited number of models are formally capable of simultaneously predicting multiple complications based on a single set of variables. Moreover, in most studies, the use of ML (particularly XGBoost) increased accuracy compared to traditional methods. The results confirm the potential of machine learning in the multi-outcome risk assessment of PCI. However, the effective use of these models in clinical practice requires reliable external validation, adaptation to local conditions, and consideration of technological innovations (such as intravascular imaging and invasive physiology). The development of ML-based prediction methods that meet these criteria will significantly improve the accuracy of PCI risk stratification, optimize procedural performance, and enhance patient outcomes in ischemic heart disease. A natural extension of this methodology is the inclusion of intravascular imaging and invasive physiology data in the models.

Keywords

Ischemic heart disease • Percutaneous coronary intervention • Machine learning • PCI complications • Predictive models • Risk scores

Received: 26.02.2025; received in revised form: 18.03.2025; accepted: 12.04.2025

Список сокращений

ДИ – доверительный интервал ОПН – острая почечная недостаточность
МО – машинное обучение ЧКВ – чрескожное коронарное вмешательство

Введение

Чрескожное коронарное вмешательство (ЧКВ) является наиболее перспективной стратегией лечения ишемической болезни сердца [1]. Однако

инвазивный характер вмешательства определяет ряд существенных рисков, величина которых значительно варьирует в зависимости от множества факторов, включая возраст, анатомическую слож-

ность и физиологическую значимость коронарных поражений, коморбидность и др. [2–4]. Наиболее значимыми осложнениями служат смерть, тяжелые кровотечения, инсульт и инфаркт миокарда. Для обеспечения персонализированного подхода к лечению и принятия обоснованных клинических решений крайне важна точная оценка этих рисков.

Традиционные модели стратификации риска, применяемые в клинической практике, обладают рядом существенных ограничений. В первую очередь, они ориентированы на предсказание только одного конкретного исхода, что делает оценку риска либо сложной задачей комплексного прогнозирования по нескольким отдельным шкалам/моделям, либо неспецифичным прогнозированием общей смертности/композитного осложнения. Кроме того, они основываются преимущественно на предоперационных параметрах и часто не учитывают современные достижения в области интервенционной кардиологии, такие как использование стентов с инновационным дизайном и новыми лекарственными препаратами, стентов без полимерного покрытия, преимущественно лучевого доступа, внутрикоронарной визуализации и физиологии, атерэктомии. Таким образом, традиционные модели могут быть малоприменимы в актуальной клинической практике и, следовательно, предлагают ограниченную поддержку при выборе оптимальной стратегии реваскуляризации.

С развитием технологий машинного обучения (МО) появилась возможность преодолеть некоторые ограничения. МО использует сложные алгоритмы для анализа больших объемов данных, что позволяет выявлять нелинейные зависимости и сложные взаимодействия переменных [5]. Это открывает путь к созданию более точных и персонализированных моделей прогнозирования, способных учитывать широкий спектр клинических, анатомических и процедурных данных. Например, такой алгоритм, как XGBoost, демонстрирует превосходные результаты в прогнозировании исходов ЧКВ, позволяя выявить значимые предикторы, которые традиционные модели могут не учитывать [6–8].

На основе МО уже разработано несколько инструментов для оценки рисков, которые предлагают ряд значительных преимуществ в сравнении с традиционными моделями. В частности, они позволяют прогнозировать сразу несколько исходов, а также учитывать как пред-, так и интраоперационные параметры [8, 9]. Эти модели также адаптированы к современным практикам ЧКВ, что делает их особенно актуальными для клинического применения.

Цель данного обзора заключалась в сравнении существующих методов оценки множественных исходов при ЧКВ, основанных на традиционных моделях и моделях машинного обучения. Внедре-

ние эффективных способов оценки риска основных осложнений ЧКВ в клиническую практику будет способствовать оптимизации планирования вмешательств, снижению нагрузки на врачей и обеспечению интегрированного подхода к лечению пациентов.

Материалы и методы

Выполнен поиск публикаций на английском языке в базе данных PubMed с использованием комбинации терминов MeSH и свободного текста: percutaneous coronary intervention[MeSH terms], PCI, death[MeSH terms], mortality[MeSH terms], nomograms[MeSH terms], risk assessment[MeSH terms], risk score, risk prediction, risk model, risk tool, predictive tool, predict model и scoring system. Проанализированы исследования, опубликованные в период с января 2014 г. по август 2024 г. Дополнительно оценены списки литературы включенных публикаций. Рассмотрены когортные исследования, исследования «случай – контроль», поперечные исследования и рандомизированные контролируемые испытания, посвященные разработке моделей прогнозирования риска. Для включения в обзор модели должны были содержать как минимум два предиктора и два исхода. Также оценены модели, предсказывающие один исход, но интегрированные в более сложные системы стратификации риска на основе общего набора данных.

Из анализа исключались исследования, не содержавшие достаточно данных о дизайне, построении модели и статистическом анализе, а также исследования, основанные на виртуальных данных. Не включались материалы конференций, неофициальные и дублирующие публикации, диссертации, обзоры и отчеты о клинических случаях.

Всего найдено 2 667 публикаций, 2 658 не соответствовали вышеуказанным критериям отбора и были исключены, в обзор включено 9 работ.

Модели прогнозирования множественных исходов при чрескожных коронарных вмешательствах

BMC2 Risk Score. В исследовании BMC2 разработана предоперационная модель стратификации риска осложнений ЧКВ с использованием данных 107 793 пациентов из реестра Blue Cross Blue Shield of Michigan Cardiovascular Consortium (BMC2), охватывающего 48 больниц в Мичигане в период с апреля 2018 г. по декабрь 2021 г. [8]. Модель XGBoost, основанная на 91 предоперационном факторе, оценивала такие исходы, как смертность, острая почечная недостаточность (ОПН), диализ, инсульт, серьезные кровотечения и необходимость переливания крови. В ходе разработки модель была сокращена до 23 ключевых признаков и протестирована на внешней когорте из 56 583 пациентов

базы данных Cardiac Care Outcomes Assessment Program (33 больницы, Вашингтон). XGBoost показала высокие значения AUC для смертности (0,939, 95% доверительный интервал (ДИ) [0,933–0,946]), ОПН (0,881, 95% ДИ [0,872–0,889]), диализа (0,949, 95% ДИ [0,938–0,961]), переливания крови (0,915, 95% ДИ [0,907–0,923]), кровотечений (0,858, 95% ДИ [0,843–0,872]) и инсульта (0,749, 95% ДИ [0,722–0,777]). Средний возраст участников исследования составил 67 лет, большинство (68,1%) были мужчины. Основные сопутствующие заболевания включали предыдущее ЧКВ (45,0%), аортокоронарное шунтирование (15,8%), табакокурение (64,9%), гипертонию (86,3%), гиперлипидемию (82,5%) и сахарный диабет (41,8%). В 42,2% случаев ЧКВ выполнено в экстренном порядке, основным показанием был острый коронарный синдром без подъема сегмента ST (22,2%). Внутрибольничная смертность составила 1,85% случаев, ОПН – 2,51%, новая потребность в диализе – 0,44%, инсульт – 0,41%, тяжелое кровотечение – 0,89%, потребность в переливании крови – 2,41%. Важно отметить, что каждый исход оценивается отдельно в течение госпитализации, что позволяет врачам и пациентам принимать более обоснованные клинические решения. Дополнительно доступен онлайн-калькулятор для оценки риска, созданный на основе этой модели: <https://shiny.bmc2.org/pci-prediction/>.

CART VA Risk Score. Программа VA CART – национальная инициатива, направленная на повышение качества медицинской помощи в лабораториях катетеризации системы здравоохранения ветеранского управления (VA) США [10]. В рамках программы собираются и анализируются данные пациентов перед проведением ЧКВ. На основе этих данных были разработаны несколько онлайн-калькуляторов для оценки рисков кровотечений, нефропатии и смертности, объединенных единым интерфейсом: <https://www.va.gov/QUALITYANDPATIENTSAFETY/cart/models.html?goto=mortality>. В исследование для разработки модели риска кровотечений включены данные 107 451 процедуры ЧКВ, выполненной в 74 больницах VA с 1 октября 2005 г. по 30 сентября 2019 г. (амбулаторные случаи исключены) [11]. Основным исходом исследования были кровотечение до выписки, определяемое как снижение уровня гемоглобина на ≥ 3 г/дл, необходимость переливания крови или значительное кровотечение. Модель логистической регрессии с эластичной сетью, включавшая 12 переменных, продемонстрировала умеренную дискриминацию (С-индекс 0,756, 95% ДИ [0,749–0,764]). Высокий уровень гемоглобина и использование лучевого доступа снижали риск кровотечений. Частота кровотечений составила 4,86% и чаще наблюдалась у пациентов с повышенным возрастом, низким

индексом массы тела, низким уровнем гемоглобина и сопутствующими заболеваниями. Для разработки модели риска смертности включены данные 58 634 процедур ЧКВ, выполненных в 59 больницах VA с 2008 по 2018 г. [12]. Основной конечной точкой исследования была 30-дневная смертность, которая составила 1,7%. Модель CART PCI, включавшая 14 переменных, продемонстрировала высокий С-индекс 0,93 (95% ДИ [0,92–0,94]), с валидацией 0,87 (95% ДИ [0,83–0,92]). Модель интегрирована в системы VA и позволяет прогнозировать риск в реальном времени. Также разработана модель оценки риска нефропатии, однако оригинальной статьи, содержащей описание ее валидации, не удалось обнаружить. Специфичность выборки, состоящей преимущественно из мужчин-ветеранов, требует осторожного подхода к обобщению результатов и может требовать перекалибровки моделей для их применения в других популяциях.

Mayo PCI Risk Score. Исследование, основанное на данных реестра клиники Мейо, охватило 15 129 пациентов, проходивших ЧКВ с 2000 по 2016 г., и представило две модели стратификации риска (А и В) [13]. Модель А включала как дооперационные, так и ангиографические переменные, в то время как модель В исключала ангиографические данные для оценки предсказательной ценности и использовала только предоперационные факторы. Обе модели, построенные с использованием логистической регрессии и клинически значимых переменных, оценивали внутрибольничную смертность, кровотечения, ОПН и инсульт. Модель А продемонстрировала значения С-статистики в диапазоне от 0,71 до 0,90 (смертность – 0,92, 95% ДИ [0,85–0,96]; кровотечение – 0,70, 95% ДИ [0,66–0,74]; ОПН – 0,77, 95% ДИ [0,72–0,80]; инсульт – 0,71, 95% ДИ [0,34–0,92]). Хотя ангиографические данные улучшили прогнозирование, модель В оказалась почти столь же эффективной, что подчеркивает значимость дооперационных переменных (смертность – 0,90, 95% ДИ [0,82–0,95]; кровотечение – 0,67, 95% ДИ [0,62–0,71]; ОПН – 0,76, 95% ДИ [0,72–0,80]; инсульт – 0,71, 95% ДИ [0,34–0,92]). Дополнительно доступен онлайн-калькулятор для оценки риска, созданный на основе этой модели: https://rtools.mayo.edu/Mayo_PCI_Risk_Score/. Ограничения включают одноцентровый характер исследования и исключение таких факторов, как опыт хирурга и современные технологии стентирования.

NCDR Cath-PCI Risk Score. Реестр NCDR Cath-PCI, поддерживаемый ACC и SCAI, охватывает данные более 1 000 учреждений США, включая характеристики пациентов и клинические исходы [14]. Данные вводятся в сертифицированное ПО и проходят строгий контроль качества. На базе регистра были разработаны несколько моделей риска различных осложнений, связанных с ЧКВ. Эти модели

позволяют оценивать риск кровотечения, острого повреждения почек (нефропатии) и смертности.

Модель риска кровотечения была разработана на основе анализа данных 1 043 759 процедур ЧКВ, выполненных в 1 142 центрах в период с февраля 2008 г. по апрель 2011 г. [15]. Кровотечение после процедуры наблюдалось в 5,8% случаев (60 194). В процессе создания модели использовалась логистическая регрессия с обратным отбором переменных, что позволило выделить 10 ключевых предикторов, включая наиболее значимые – женский пол, шок и спасительное ЧКВ. Нелинейные ассоциации переменных, таких как гемоглобин до процедуры, индекс массы тела и возраст, учитывались через сплайны. Итоговая модель продемонстрировала дискриминацию с С-индексом 0,78 (95% ДИ не указан¹) в тренировочной выборке и 0,77 (95% ДИ не указан) в тестовой выборке.

Модель риска острого повреждения почек (нефропатии) была разработана на основе данных 947 012 пациентов, перенесших ЧКВ в период с 1 июня 2009 г. по 30 июня 2011 г. [16]. Изучались предикторы ОПН, известные до ЧКВ. Контрастное вещество не включалось в анализ из-за неопределенности объема. Средний возраст пациентов – 64,8 года, 67% – мужчины. ОПН развилось у 7,1% пациентов, а ОПН-Д – у 0,3%. Окончательные модели включали 11 предикторов для ОПН (С-индекс 0,713, 95% ДИ [0,709–0,717]) и 6 для ОПН-Д (С-индекс 0,88, 95% ДИ не указан). Основные предикторы: инфаркт миокарда с подъемом сегмента ST, кардиогенный шок, хроническая болезнь почек. Калькулятор доступен по ссылке: https://qxmd.com/calculate/calculator_386/ncdr-aki-and-dialysis-risk-after-pci.

Модель риска смертности была разработана с использованием данных 1 208 137 пациентов, перенесших ЧКВ в 1 253 центрах с 1 июля 2009 г. по 30 июня 2011 г. [17]. Средний возраст участников составил 65 лет, 33% из них были женщины, 36% – диабетики, 40% имели предшествующие ЧКВ. Для анализа были использованы три типа моделей логистической регрессии с обратным отбором переменных: полная модель, модель до катетеризации (без ангиографических данных) и ограниченная модель (с упрощенным набором переменных). В обновленную версию модели смертности были включены такие переменные, как хроническая окклюзия и тромбоз стента. Все три модели продемонстрировали высокую прогностическую точность с С-индексом более 0,925 (0,930, 0,928, 0,925; 95% ДИ не указан) и хорошую калибровку по всему диапазону рисков.

The Japan Cardiovascular Database-Keio Interhospital Cardiovascular Studies (JCD-KiCS). Исследование, основанное на данных реестра The

Japan Cardiovascular Database-Keio Interhospital Cardiovascular Studies (JCD-KiCS), созданного синхронно с регистром NCDR, охватило 22 958 пациентов, перенесших ЧКВ с 2008 по 2020 г., и представило две модели: логистической регрессии и XGBoost [18]. В логистической регрессии использовались категоризированные переменные исходных моделей NCDR-CathPCI, тогда как в XGB применялись те же переменные, но в непрерывной форме. Пациенты, в основном мужчины, имели средний возраст 70 лет и индекс массы тела 24,0, из них 55,4% страдали стабильной ишемической болезнью сердца, а 58,6% перенесли плановое ЧКВ. Распространенность ОПН, кровотечений и внутрибольничной смертности составила 9,6, 7,8 и 2,3% соответственно. Модель логистической регрессии продемонстрировала хорошую дискриминацию: С-индекс составил 0,83 для ОПН (95% ДИ [0,81–0,85]), 0,75 для кровотечений (95% ДИ [0,73–0,78]) и 0,95 для внутрибольничной смертности (95% ДИ [0,94–0,97]). XGB улучшила дискриминацию для ОПН (С-индекс 0,84, 95% ДИ [0,82–0,86]) и кровотечений (С-индекс 0,79, 95% ДИ [0,76–0,81]).

Японский регистр PCI показал, что исходные показатели риска NCDR CathPCI эффективно прогнозируют частоту различных исходов в Японии с высокой точностью в отношении дискриминации и калибровки. В сравнении с этими показателями модель XGB продемонстрировала немногим лучшие результаты, но в некоторых случаях ухудшила калибровку, особенно для внутрибольничной смертности. Модель XGB переоценила риск внутрибольничной смертности у пациентов с низким риском, что могло бы привести к необоснованным отказам от процедуры. Причиной такой переоценки, вероятно, являются низкие показатели событий в этой группе: среди пациентов с низким риском не было случаев внутрибольничной смертности. Несбалансированные данные остаются проблемой для моделей машинного обучения, так как они склонны придавать большее значение классу большинства, что смещает калибровку.

National Inpatient Sample Risk Score. В данном исследовании было проанализировано 1 815 595 случаев госпитализации пациентов старше 18 лет, которым проводилось ЧКВ в период с 2016 по 2019 г. [19]. Для отбора признаков применялась несупервизированная методика, основанная на супервизированных алгоритмах, реализованная с использованием библиотеки FRUFS. Это позволило сократить число исходных признаков с 361 до 101 и создать мультизадачную модель машинного обучения для предсказания семи возможных исходов, включая смерть, инсульт, кровотечение и их комбинации. Средний возраст пациентов составил 65 лет. Среди

¹ В оригинальном исследовании авторы не представили данные для расчета доверительного интервала.

всех случаев госпитализаций в 98 180 достигнуты конечные точки исследования: 42 820 случаев завершились смертью, 27 900 – крупными кровотечениями, 17 390 – ишемическим инсультом. Комбинированные исходы были зафиксированы в 9 300 случаях, а 770 пациентов испытали одновременное возникновение трех неблагоприятных событий: смерти, крупного кровотечения и ишемического инсульта. Пациенты с такими исходами были старше, чаще госпитализировались в выходные дни, среди них преобладали женщины и представители негроидной расы.

Для оценки точности моделей (логистическая регрессия, SVM, наивный байесовский классификатор, случайный лес, XGBoost) была использована отдельная валидационная когорта, калибровка осуществлялась с помощью изотонического подхода и метода Платта. Оценка качества калибровки проводилась с использованием калибровочных кривых и ожидаемой ошибки калибровки (ECE); модель с наименьшим ECE была признана наиболее корректной. Важность признаков оценивалась с помощью значений SHapley Additive exPlanations (SHAP). Модель XGBoost продемонстрировала наилучшие результаты с AUC 0,86 (95% ДИ [0,85–0,87]), превзойдя традиционные методы. Среди наиболее значимых признаков оказались индекс коморбидности по Эликсхаузеру, почечная недостаточность, анамнез сердечных заболеваний, возраст и пол. Было разработано веб-приложение для прогнозирования риска по восьми исходам, которое может быть интегрировано в системы электронных медицинских записей. Код доступен на GitHub, однако модель и приложение не опубликованы в открытом доступе в связи с рисками повторной идентификации пациентов и вопросами авторского права [20].

Точность прогнозов: роль моделей и факторов. Анализ показал, что модели JCD-KiCS и BMC2 Risk Score при использовании алгоритма XGBoost обеспечивают высокую точность и устойчивость предсказаний для ряда клинических исходов. Например, для риска кровотечений модель JCD-KiCS с XGBoost достигла C-индекса 0,79 (95% ДИ [0,76, 0,81]), а модель BMC2 Risk Score с тем же алгоритмом обеспечила AUC 0,89 (95% ДИ [0,87, 0,91]), что подтверждает ее высокий потенциал для классификации. Самые узкие доверительные интервалы (0,04) были у модели BMC2 Risk Score, что указывает на стабильность и надежность прогнозов. Для исхода «смерть» модель JCD-KiCS с XGBoost продемонстрировала наивысший C-индекс 0,96 (95% ДИ [0,94–0,97]), а BMC2 Risk Score с XGBoost – максимальное значение AUC 0,93 (95% ДИ [0,92–0,94]) с узкими доверительными интервалами (0,02).

Для исхода «острая почечная недостаточность» модель JCD-KiCS с XGBoost показала C-индекс 0,84 (95% ДИ [0,82, 0,86]), а BMC2 Risk Score продемонстрировала максимальный AUC 0,89 (95% ДИ [0,88, 0,90]). В исходе «инсульт» наибольший AUC (0,92, 95% ДИ не указан) показала модель National Inpatient Sample с алгоритмом SVM.

Анализ влияния таких факторов, как размер выборки, частота события и число предикторов, показал умеренные, но значимые корреляции с метриками (табл. 1). Например, для кровотечений и смертности увеличение размера выборки не влияло на C-индекс, но умеренно снижало AUC. В случае острой почечной недостаточности размер выборки положительно коррелировал с AUC (0,95), вероятно, благодаря улучшению предсказательной способности модели. Частота события положительно коррелировала с C-индексом для кровотечений (0,76) и почечной недостаточности (0,77), тогда как для AUC это влияние было менее выраженным.

Количество предикторов отрицательно коррелировало с C-индексом для кровотечений (–0,85) и почечной недостаточности (–0,82), что указывает на возможное снижение устойчивости моделей при увеличении числа факторов. В то же время для инсульта увеличение числа предикторов положительно коррелировало с AUC (0,72), улучшая точность модели. Наибольшие значения C-индекса для кровотечений и смертности наблюдались при разделении выборки 75/25, а для AUC – при разделении 60/40, что подтверждает значимость подбора подходящей стратегии разделения выборки (табл. 2).

Таким образом, данные анализа подчеркивают важность выбора модели, алгоритма и конфигурации факторов для оптимального прогнозирования различных клинических исходов. Результаты анализа подчеркивают значительные преимущества моделей JCD-KiCS и BMC2 Risk Score, особенно при использовании алгоритма XGBoost, который обеспечивает наилучшие дискриминационные свойства, высокие значения AUC и узкие доверительные интервалы по широкому спектру клинических исходов.

Кроме того, для повышения качества прогнозов и надежности моделей необходимо учитывать особенности медицинских данных. Во-первых, данные для обучения часто собираются на протяжении длительного времени или из разных медицинских центров, что создает различия в подходах к лечению и используемых диагностических инструментах. Важно применять модели, которые учитывают эти вариации и способны распознавать значимые предикторы, даже если они встречаются нечасто. Во-вторых, медицинские данные отличаются высокой сложностью и многокомпонентностью, охваты-

вая демографические, антропометрические, анатомические и физиологические показатели. Избыточность данных может привести к переобучению и снижению точности моделей, а также к проблемам мультиколлинеарности. Высокая размерность данных увеличивает требования к вычислительным ресурсам и усложняет построение эффективных моделей. В-третьих, медицинские данные часто не сбалансированы по классам, что ведет к смещению модели в сторону более распространенных исходов. Использование методов синтетической выборки не всегда оказывается эффективным и может ухудшить качество предсказаний, снижая спо-

собность модели к обобщению. В-четвертых, для надежности прогнозов модели должны проходить внешнюю валидацию на независимых группах пациентов. Это сложнее при большом числе признаков, поэтому важно определять наиболее значимые для упрощения модели. Однако определение значимых признаков также связано с интерпретируемостью, что не всегда легко, особенно в случае сложных моделей из-за нелинейных взаимосвязей. В таких случаях предпочтение клиницистом отдается более простой и интерпретируемой модели, если ее точность близка к сложной. Наконец, неполнота данных является важным ограничением в меди-

Таблица 1. Влияние основных факторов на дискриминационные показатели (С-индекс и AUC) при прогнозировании различных клинических исходов
Table 1. Influence of key factors on the discriminative metrics (C-index and AUC) in predicting various clinical outcomes

Метрика и событие / Metric and event		Фактор / Factor	Корреляция / Correlation	Регрессия / Regression	p
Кровотечение / Bleeding	C-index	Размер выборки / Sample size	0,046	0,94	3,3e-09
		Частота события / Event frequency	0,76	0,14	1,5e-02
		Число предикторов / Number of predictors	-0,85	0,06	-9,0e-03
	AUC	Размер выборки / Sample size	-0,71	0,12	-3,8e-08
		Частота события / Event frequency	-0,71	0,12	-1,06e-01
		Число предикторов / Number of predictors	-0,71	0,12	-8,3e-04
Смерть / Death	C-index	Размер выборки / Sample size	0,06	0,89	2,1e-09
		Частота события / Event frequency	0,44	0,29	1,5e-02
		Число предикторов / Number of predictors	-0,62	0,18	-6,0e-03
	AUC	Размер выборки / Sample size	-0,71	0,08	-1,4e-08
		Частота события / Event frequency	-0,51	0,15	-3,6e-02
		Число предикторов / Number of predictors	-0,38	0,30	-2,0e-03
ОПН / AKI	C-index	Размер выборки / Sample size	-0,64	0,17	-5,9e-06
		Частота события / Event frequency	0,77	0,12	1,2e-02
		Число предикторов / Number of predictors	-0,82	0,08	-1,0e-02
	AUC	Размер выборки / Sample size	0,95	0,003	1,4e-06
		Частота события / Event frequency	-0,71	0,11	-8,0e-02
		Число предикторов / Number of predictors	-0,5	0,3	-4,0e-03
Инсульт / Stroke	AUC	Размер выборки / Sample size	-0,42	0,27	-4,4e-08
		Частота события / Event frequency	-0,34	0,41	-2,1e-02
		Число предикторов / Number of predictors	0,72	0,11	1,5e-0

Примечание: здесь и далее в табл. 2: ОПН – острая почечная недостаточность; AUC – площадь под ROC-кривой; C-index – индекс соответствия (С-индекс).
Note: here and then in Table 2: AKI – acute kidney injury; AUC – area under the ROC curve; C-index – concordance index.

Таблица 2. Сравнение С-индекса и AUC при различных стратегиях разделения выборки для прогнозирования клинических исходов
Table 2. Comparison of C-index and AUC with different data splitting strategies in predicting clinical outcomes

Разделение выборки / Data Splitting	Кровотечение / Bleeding		Смерть / Death		ОПН / AKI		Инсульт / Stroke	
	C-index	AUC	C-index	AUC	C-index	AUC	C-index	AUC
60/40	–	0,87	0,93	0,93	–	0,89	–	0,78
70/30	0,7	–	–	–	0,74	–	0,71	–
75/25	0,77	–	0,96	–	0,84	–	–	–
80/20	0,75	0,81	0,95	0,8	–	–	0,70	0,76

цинских исследованиях из-за длительного периода сбора и высокой стоимости и/или недоступности технологий. Тщательная предобработка данных и использование моделей, способных работать с пропусками, без необходимости их заполнения, повышают точность и надежность прогнозов.

В этом контексте использование ансамблевых моделей, заявленных в статье (случайный лес, градиентный бустинг), тоже имеет преимущества, так как отсутствуют обязательные требования в импутации пропусков, что снижает роль решения исследователя в смещении важных характеристик. Также отсутствуют требования к устранению мультиколлинеарности, что более полно отражает весь пул признаков и помогает обнаруживать новые редкие, но значимые предикторы. Это становится доступным как за счет сохранения пула признаков, так и из-за заложенной способности ансамблевых моделей к обнаружению нелинейных зависимостей. Последнее может стать проблемой в интерпретации окончательной модели, однако современные алгоритмы, такие как метод SHAP, помогают выявить важные признаки и оценить их направленность и силу влияния. Также важным ограничением ансамблевых моделей остается их склонность к переобучению, что особенно актуально в условиях малой выборки и непропорционально большого количества признаков – частой особенностью медицинских данных. Это сопряжено с другой проблемой – дисбалансом классов, который остается критической точкой для любого алгоритма. Увеличение выборки остается основным решением последних двух проблем.

Обсуждение

В обзоре представлены шесть ключевых моделей оценки риска, одновременно учитывающих несколько исходов. Установлено, что врачи редко используют шкалы для оценки рисков из-за их сложности или неудобства [21]. Одной из возможных причин этого является отсутствие надежных валидированных моделей для одновременной оценки нескольких исходов без необходимости обобщать оценки, сделанные с использованием нескольких отдельных моделей с разным набором переменных. В результате основными инструментами прогнозирования остаются шкалы, оценивающие риск универсальных, но малоспецифичных исходов в виде смерти от всех причин или комбинированного события серьезных осложнений, которые к тому же слабо отражают современную клиническую практику, например GRACE и SYNTAX [22, 23]. В ряде исследований продемонстрирована их низкая дискриминационную способность [24, 25]. Кроме того, целесообразность использования шкал, основанных преимущественно на анатомических переменных, после полной реваскуляризации, ког-

да ожидается минимальное влияние анатомии на последующие исходы, остается под вопросом [26]. В крупном ретроспективном одноцентровом исследовании эффективности пяти риск-баллов среди когорты последовательных пациентов, достигших полной реваскуляризации после ЧКВ, ни один из баллов не продемонстрировал полезной дискриминации для MACCE. В проспективном исследовании 2016–2017 гг. шкалы GRACE, ACEF, SYNTAX II 2020 и TIMI были сравнены с моделью машинного обучения CatBoost для предсказания многовариантной классификации, включая внутрибольничную смертность, трехлетнюю смертность вне больницы и выживание более 3 лет [27]. CatBoost показала значительно более высокую эффективность в предсказании трехлетней выживаемости с AUC-ROC 0,854 (95% ДИ [0,835–0,875]) для общей смертности и 0,886 (95% ДИ [0,867–0,901]) для сердечно-сосудистой смертности. Таким образом, машинное обучение представляет собой многообещающий инструмент.

В ходе обзора было отмечено, что лишь три инструмента оценивают риски на основании единого набора переменных: BMC2 Risk Score, Mayo PCI Risk Score и National Inpatient Sample Risk Score. Примечательно, что два из них были созданы с использованием современной модели градиентного бустинга – XGBoost, вероятно благодаря ее способности выявлять сложные нелинейные взаимосвязи [6]. Хотя инструменты CART VA Risk Score, NCDR Cath-PCI Risk Score и The Japan Cardiovascular Database-Keio Interhospital Cardiovascular Studies (JCD-KiCS) оценивали каждый исход отдельно, они имели общие характеристики, такие как интерфейс (например, CART VA Risk Score) и исследуемую популяцию, что послужило основанием для их включения в данный обзор. Кроме того, только три модели имели общедоступные веб-сайты – BMC2 Risk Score, Mayo PCI Risk Score и CART VA Risk Score, что свидетельствует об их стремлении к широкому использованию и существенно упрощает их применение. С учетом того, что BMC2 Risk Score и Mayo PCI Risk Score также используют единый набор переменных для предсказания исходов, это делает их привлекательными инструментами для дальнейших исследований по внешней валидации.

Только шкала NCDR Cath-PCI Risk Score прошла надежную внешнюю валидацию на различных популяциях пациентов: американской, европейской и азиатской [28–30]. Дискриминационная способность моделей сопоставима с исходными исследованиями, однако калибровка показала значительные отклонения, особенно у пациентов с высоким риском, что подтверждает необходимость адаптации моделей к современным данным и условиям, включая калибровку на новых когортных данных. Исследование The Japan Cardiovascular

Database-Keio Interhospital Cardiovascular Studies (JCD-KiCS) фактически является примером внешней валидации.

Внешняя валидация остается краеугольным камнем для моделей прогнозирования. В систематическом обзоре практичность многих моделей была поставлена под сомнение из-за отсутствия внешней валидации и методологических недостатков [31]. Последнее объясняется высоким риском необъективности: ретроспективный дизайн исследований, отсутствие «ослепления» при оценке предикторов или исходов, неоправданная категоризация и определение исходов, недостаточный размер выборки, неправильные методы внутренней валидации и некорректное обращение с недостающими данными.

Помимо отсутствия внешней валидации, другим существенным ограничением современных моделей является характер данных, на которых они разработаны. Зачастую используются либо административные базы данных страховых заявлений, собираемые преимущественно для целей возмещения расходов, либо регистры, формируемые главным образом для исследовательских целей и оценки качества медицинской помощи. Например, National Inpatient Sample (NIS) – база данных стационарных пациентов в США, собираемая в рамках проекта Healthcare Cost and Utilization Project (HCUP) [32]. NIS предоставляет всестороннюю информацию о госпитализациях, включая диагнозы, процедуры, стоимость лечения и демографические данные пациентов, однако лабораторные и инструментальные показатели не включены.

S. Shoji и соавт. оценили эффективность моделей прогнозирования риска для пациентов, перенесших ЧКВ, на основе данных страховых заявлений и клинических регистров. В исследование было включено 43 095 пациентов, разделенных на когорты с острым коронарным синдромом и хронической ишемической болезнью сердца [33]. Авторы пришли к выводу, что модели, включающие данные регистров, превосходят модели, основанные только на данных страховых заявлений, по точности предсказания внутрибольничной смертности и кровотечений. Объединение данных страховых заявлений и клинических регистров обеспечило более точные прогнозы с С-индексом до 0,83 (95% ДИ [0,79–0,86]).

Кроме того, формальный подход к кодированию исходов может быть серьезным препятствием для использования моделей, разработанных исключительно на основе административных данных. Например, такие распространенные исходы, как 30-дневная или перипроцедурная смертность, могут не быть следствием самого вмешательства. Анализ перипроцедурной смертности крупной когорты пациентов, охватившей несколько центров

в системе здравоохранения США за последнее десятилетие, показал, что меньшая часть смертей связана непосредственно с процедурой [34]. Это демонстрирует значительные проблемы при использовании смертности в качестве суррогатного показателя качества вмешательства. Большинство смертей имели недифференцированную причину (59%), в меньшем количестве случаев смерть была связана с сердечно-сосудистыми причинами (28%), и лишь небольшая доля смертей была непосредственно связана с ЧКВ (8%).

С точки зрения объема данных все представленные инструменты обладают значительным количеством наблюдений – от 15 129 до 1 815 595 случаев госпитализации, причем ряд баз данных собраны из нескольких центров. Это критически важно в условиях предвзятости моделей к непредставленной популяции и типичной проблемы медицинских данных – несбалансированности классов, когда количество случаев с исходами кратно меньше числа наблюдений без событий [35]. Это является существенной проблемой для современных алгоритмов МО, которые склонны к переобучению, в отличие от традиционной логистической регрессии. Частично это отмечено в исследовании The Japan Cardiovascular Database-Keio Interhospital Cardiovascular Studies (JCD-KiCS). Проблема несбалансированных данных в моделях МО заключается в том, что методы, ориентированные на общую точность, часто игнорируют малочисленный класс, что приводит к его низкой распознаваемости, несмотря на высокую общую точность. Метод синтетической избыточной выборки меньшинства (SMOTE), часто применяемый в таких случаях, доказал эффективность в различных областях, включая клинические исследования, однако он не устраняет дилемму использования синтетических данных, которая была особо подчеркнута в последнем обзоре журнала Nature [36, 37].

Большой объем данных в представленных работах также обусловлен длительным накоплением данных, а следовательно, включением разных этапов ЧКВ: использование голометаллических стентов, отсутствие доминирования лучевого доступа, крайне низкая распространенность внутрикоронарной визуализации и дополнительных процедур, таких как атерэктомия. Между тем сложность поражения коронарного русла меняется вместе с расширением показаний для ЧКВ. Это обнажает другую проблему: недопредставленность пациентов с высокорисковым ЧКВ и сложными поражениями коронарного русла, которые имеют большую потребность в прогнозировании исходов для планирования процедур. Например, более тяжелое поражение коронарного русла приводит к увеличению объема контрастного вещества, что линейно повышает риски нефропатии. Однако существует пара-

докс, когда меры профилактики не применяются у пациентов с самым высоким риском [38]. Это подчеркивает особую важность инструментов прогнозирования. Хотя существуют опасения, что включение высокорисковых пациентов может смещать модели, М. Тасеу и соавт. показали, что предсказательная точность модели 30-дневной смертности, включающей всех пациентов, сопоставима с моделью, исключающей случаи с высоким риском [39]. Таким образом, возможно, не следует исключать ряд предикторов, которые могут выявить новые связи и улучшить общее качество прогнозирования. Этот подход во всех смыслах лучше реализуется в моделях МО, которые показали способность учитывать тяжесть состояния.

Необходимо отметить, что модели, рассмотренные в обзоре, отражают тенденцию более взвешенного принятия решений о реваскуляризации на основе оценки индивидуального соотношения риска и пользы выполнения ЧКВ, индивидуальной оптимизации процедуры (например, уменьшение объема используемого контраста, механическая поддержка кровообращения и т. д.), послеоперационного ведения (контроль функции почек, сократительной функции сердца и т. д.). Точность прогнозирования рисков ЧКВ можно существенно повысить с помощью дополнительного учета интраоперационных факторов, например длины стентирования, степени раскрытия стента, наличия остаточного транс-стенотического градиента, дефектов имплантации стента (краевые диссекции коронарной артерии, мальаппозиция, протрузия). Доказано значимое влияние многих интраоперационных факторов, например недораскрытия стента, краевой диссекции, протрузии, на риск неблагоприятных исходов ЧКВ, в том числе смертности, за счет повторных сердечно-сосудистых событий [40]. Таким образом, современные инструменты оценки риска также должны учитывать интраоперационные факторы, модифицирующие эффекты вмешательства, в том числе, риск осложнений/неблагоприятных исходов.

Актуальность этого вопроса возросла с внедрением в практику методов оценки физиологии и анатомии коронарных артерий, которые выполняются непосредственно до основных манипуляций, а также могут быть использованы после в качестве контроля, что существенно расширяет возможности. В исследовании на основе международного регистра Post PCI FFR, включавшем данные 2 200 пациентов из четырех регистров Кореи, Китая и Японии, оценивался риск несостоятельности целевой артерии после имплантации стентов с лекарственным покрытием второго поколения [41]. Выявлено, что снижение фракционного резерва кровотока после стентирования ассоциируется с повышенным риском несостоятельности целевой артерии, осо-

бенно в группе с короткими стентами. Поскольку фракционный резерв кровотока после стентирования отражает физиологическую нагрузку на стеноз как в стентированных, так и в нестентированных сегментах, его учет может улучшить точность прогнозирования риска, особенно если модель риска будет учитывать факторы, влияющие на резерв, например артериальную гипертонию [42]. Градиент фракционного резерва кровотока через стент и отношение градиента к длине применяли для предсказания оптимального раскрытия стента по данным внутрисосудистого ультразвукового исследования [43]. Отмечено, что клинические события для этого предиктора были в основном связаны с поражением целевой области (инфаркт миокарда и кардиоренальный синдром), что делает этот предиктор полезным для прогнозирования событий «по сегменту» коронарной артерии. Классификация Medina, угол бифуркации, диаметр стента показали себя важными предикторами, поскольку вмешательства на бифуркационных поражениях составляют около 20% всех ЧКВ [44–46]. Эти примеры кандидатов-переменных могут улучшить интраоперационную диагностику событий, однако выбор значительно шире ввиду рутинного внедрения новых методов инвазивной диагностики.

Теоретически строение стенки и характер провета коронарной артерии могут заблаговременно предсказать вероятность краевой диссекции, что может повлиять на ход процедуры. Однако моделей, предсказывающих такие исходы, практически нет. Существуют единичные модели, нацеленные на прогнозирование специфических, целенаправленных вмешательств, таких как лечение хронической окклюзии или вмешательства на бифуркации [47, 48]. Кроме предсказания исходов МО может использоваться для выбора стратегии вмешательства. Так, L. Jie и соавт. с использованием МО обнаружили, что возраст и фракция выброса левого желудочка могут помочь в выборе метода реваскуляризации и оценке риска смерти для пациентов с трехсосудистым поражением коронарного русла с показателем SYNTAX ≥ 23 баллов [49].

Таким образом, МО является многообещающей стратегией для предсказания исходов. Потенциал МО слабо раскрыт в прогнозировании осложнений интраоперационных событий, хотя методы современной диагностики, такие как моментальный и фракционный резерв кровотока, оптическая когерентная томография, внутрисосудистое ультразвуковое исследование, обладают высоким разрешением и низкой межоператорской вариабельностью, что делает получение маркеров более надежным. Это повышает общее качество данных, которое столь же важно, как и объем данных, следуя известной поговорке в машинном обучении «мусор входит – мусор выходит».

Заключение

Количество моделей для прогнозирования множественных исходов при чрескожных коронарных вмешательствах ограничено. Лишь небольшая часть этих моделей включает единый набор данных, причем чаще всего это модели машинного обучения. Несмотря на широкий спектр методов машинного обучения, в представленном нами обзоре определена только одна модель – XGBoost, что, вероятно, отражает ее эффективность при анализе медицинских данных. Высокая точность этих моделей, даже при использовании единого набора данных, подчеркивает необходимость дальнейших исследований в этой области. Естественным расширением методологии является включение в модели данных внутрисосудистой визуализации и инвазивной физиологии.

Информация об авторах

Гороховский Алексей Александрович, младший научный сотрудник лаборатории рентгенэндоваскулярной хирургии Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0003-3909-9282

Пекарский Станислав Евгеньевич, доктор медицинских наук ведущий научный сотрудник лаборатории рентгенэндоваскулярной хирургии Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0002-4008-4021

Баев Андрей Евгеньевич, кандидат медицинских наук заведующий лабораторией рентгенэндоваскулярных диагностики и лечения Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0002-8163-1618

Тарасов Михаил Георгиевич, младший научный сотрудник лаборатории рентгенэндоваскулярной хирургии Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0001-5263-9488

Суслов Иван Владимирович, младший научный сотрудник лаборатории рентгенэндоваскулярной хирургии Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0002-0288-4191

Гергерт Егор Сергеевич, младший научный сотрудник лаборатории рентгенэндоваскулярной хирургии Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0001-9464-3354

Конфликт интересов

А.А. Гороховский заявляет об отсутствии конфликта интересов. С.Е. Пекарский заявляет об отсутствии конфликта интересов. А.Е. Баев заявляет об отсутствии конфликта интересов. М.Г. Тарасов заявляет об отсутствии конфликта интересов. И.В. Суслов заявляет об отсутствии конфликта интересов. Е.С. Гергерт заявляет об отсутствии конфликта интересов. Ю.И. Богданов заявляет об отсутствии конфликта интересов. С.М. Султанов заявляет об отсутствии конфликта интересов.

Финансирование

Авторы заявляют об отсутствии финансирования исследования.

Author Information Form

Gorokhovskiy Alexey A., Junior Researcher at the Laboratory of Image-guided Endovascular Surgery, Cardiology Research Institute, a branch of the Federal State Budgetary Institution “Tomsk National Research Medical Center” of the Russian Academy of Sciences, Tomsk, Russian Federation; **ORCID** 0000-0003-3909-9282

Pekarskiy Stanislav E., PhD, Leading Researcher at the Laboratory of Image-guided Endovascular Surgery, Cardiology Research Institute, a branch of the Federal State Budgetary Institution “Tomsk National Research Medical Center” of the Russian Academy of Sciences, Tomsk, Russian Federation; **ORCID** 0000-0002-4008-4021

Baev Andrey E., PhD, Head of the Laboratory of Image-guided Endovascular Diagnostics and Treatment at the Cardiology Research Institute, a branch of the Federal State Budgetary Institution “Tomsk National Research Medical Center” of the Russian Academy of Sciences, Tomsk, Russian Federation; **ORCID** 0000-0002-8163-1618

Tarasov Mikhail G., Junior Researcher at the Laboratory of Image-guided Endovascular Surgery, Cardiology Research Institute, a branch of the Federal State Budgetary Institution “Tomsk National Research Medical Center” of the Russian Academy of Sciences, Tomsk, Russian Federation; **ORCID** 0000-0001-5263-9488

Suslov Ivan V., Junior Researcher at the Laboratory of Image-guided Endovascular Surgery, Cardiology Research Institute, a branch of the Federal State Budgetary Institution “Tomsk National Research Medical Center” of the Russian Academy of Sciences, Tomsk, Russian Federation; **ORCID** 0000-0002-0288-4191

Gergert Egor S., Junior Researcher at the Laboratory of Image-guided Endovascular Surgery, Cardiology Research Institute, a branch of the Federal State Budgetary Institution “Tomsk National Research Medical Center” of the Russian Academy of Sciences, Tomsk, Russian Federation; **ORCID** 0000-0001-9464-3354

Богданов Юрий Игоревич, научный сотрудник лаборатории рентгенэндоваскулярной хирургии Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0003-2939-6291

Султанов Сыргак Мавланович, младший научный сотрудник лаборатории рентгенэндоваскулярной хирургии Научно-исследовательского института кардиологии – филиала Федерального государственного бюджетного научного учреждения «Томский национальный исследовательский медицинский центр Российской академии наук», Томск, Российская Федерация; **ORCID** 0000-0002-1569-2914

Bogdanov Yuri I., Junior Researcher at the Laboratory of Image-guided Endovascular Surgery, Cardiology Research Institute, a branch of the Federal State Budgetary Institution “Tomsk National Research Medical Center” of the Russian Academy of Sciences, Tomsk, Russian Federation; **ORCID** 0000-0003-2939-6291

Sultanov Syrgak M., Junior Researcher at the Laboratory of Image-guided Endovascular Surgery, Cardiology Research Institute, a branch of the Federal State Budgetary Institution “Tomsk National Research Medical Center” of the Russian Academy of Sciences, Tomsk, Russian Federation; **ORCID** 0000-0002-1569-2914

Вклад авторов в статью

ГАА – вклад в концепцию и дизайн исследования, анализ и интерпретация данных исследования, написание и корректировка статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

ПСЕ – вклад в концепцию исследования, корректировка статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

БАЕ – интерпретация данных исследования, корректировка статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

ТМГ – интерпретация данных исследования, корректировка статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

СИВ – интерпретация данных исследования, корректировка статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

ГЕС – интерпретация данных исследования, корректировка статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

БЮИ – интерпретация данных исследования, корректировка статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

ССМ – интерпретация данных исследования, корректировка статьи, утверждение окончательной версии для публикации, полная ответственность за содержание

Author Contribution Statement

GAA – contribution to the concept and design of the study, data analysis and interpretation, manuscript writing, editing, approval of the final version, fully responsible for the content

PSE – contribution to the concept of the study, editing, approval of the final version, fully responsible for the content

BAE – data interpretation, editing, approval of the final version, fully responsible for the content

TMG – data interpretation, editing, approval of the final version, fully responsible for the content

SIV – data interpretation, editing, approval of the final version, fully responsible for the content

GES – data interpretation, editing, approval of the final version, fully responsible for the content

BYU – data interpretation, editing, approval of the final version, fully responsible for the content

SSM – data interpretation, editing, approval of the final version, fully responsible for the content

СПИСОК ЛИТЕРАТУРЫ

1. Canfield J., Totary-Jain H. 40 years of percutaneous coronary intervention: history and future directions. *J Pers Med*. 2018;8(4):33. doi: 10.3390/jpm8040033.
2. Amin A.P., Salisbury A.C., McCullough P.A., Gosch K., Spertus J.A., Venkitachalam L., Stolker J.M., Parikh C.R., Masoudi F.A., Jones P.G., Kosiborod M. Trends in the incidence of acute kidney injury in patients hospitalized with acute myocardial infarction. *Arch Intern Med*. 2012;172(3):246-53. doi: 10.1001/archinternmed.2011.1202.
3. Subherwal S., Peterson E.D., Dai D., Thomas L., Messenger J.C., Xian Y., Brindis R.G., Feldman D.N., Senter S., Klein L.W., Marso S.P., Roe M.T., Rao S.V. Temporal trends in and factors associated with bleeding complications among patients undergoing percutaneous coronary intervention: a report from the National Cardiovascular Data CathPCI Registry. *J Am Coll Cardiol*. 2012;59(21):1861-9. doi: 10.1016/j.jacc.2011.12.045.
4. Murali S., Vogrin S., Noaman S., Dinh D.T., Brennan A.L., Lefkowitz J., Reid C.M., Cox N., Chan W. Bleeding severity in percutaneous coronary intervention (PCI) and its impact on short-term clinical outcomes. *J Clin Med*. 2020;9(5):1426. doi:

10.3390/jcm9051426.

5. Deo R.C. Machine learning in medicine. *Circulation*. 2015;132(20):1920-30. doi: 10.1161/CIRCULATIONAHA.115.001593.

6. Chen T., Guestrin C. XGBoost: a scalable tree boosting system. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York (NY): Association for Computing Machinery; 2016. p. 785–94.

7. Ninomiya K., Kageyama S., Garg S., Masuda S., Kotoku N., Revaiah P.C., O'Leary N., Onuma Y., Serruys P.W.; SYNTAX Extended Survival Investigators. Can machine learning unravel unsuspected, clinically important factors predictive of long-term mortality in complex coronary artery disease? A call for 'big data'. *Eur Heart J Digit Health*. 2023;4(3):275-278. doi: 10.1093/ehjdh/ztad014.

8. Hamilton D.E., Albright J., Seth M., Painter I., Maynard C., Hira R.S., Sukul D., Gurm H.S. Merging machine learning and patient preference: a novel tool for risk prediction of percutaneous coronary interventions. *Eur Heart J*. 2024;45(8):601-609. doi: 10.1093/eurheartj/ehad836.

9. Galimzhanov A., Matetic A., Tenekecioglu E., Mamas M.A. Prediction of clinical outcomes after percutaneous coronary intervention: machine-learning analysis of the National Inpatient Sample. *Int J Cardiol.* 2023;392:131339. doi: 10.1016/j.ijcard.2023.131339.
10. Clinical Assessment Reporting and Tracking System for Cath Labs (CART-CL). VA Health Services Research & Development. Available from: <https://www.hsrd.research.va.gov/impacts/cart-cl.cfm>. (Accessed 2024 Sep 23).
11. Doll J.A., O'Donnell C.I., Plomondon M.E., Waldo S.W. Development and Implementation of an In-Hospital Bleeding Risk Model for Percutaneous Coronary Intervention. *Cardiovasc Revasc Med.* 2021;28:20-24. doi: 10.1016/j.carrev.2020.07.033.
12. Doll J.A., O'Donnell C.I., Plomondon M.E., Waldo S.W. Contemporary Clinical and Coronary Anatomic Risk Model for 30-Day Mortality After Percutaneous Coronary Intervention. *Circ Cardiovasc Interv.* 2021;14(12):e010863. doi: 10.1161/CIRCINTERVENTIONS.121.010863.
13. Singh M., Gulati R., Lewis B.R., Zhou Z., Alkhouli M., Friedman P., Bell M.R. Multimorbidity and Mortality Models to Predict Complications Following Percutaneous Coronary Interventions. *Circ Cardiovasc Interv.* 2022;15(7):e011540. doi: 10.1161/CIRCINTERVENTIONS.121.011540.
14. Moussa I., Hermann A., Messenger J.C., Dehmer G.J., Weaver W.D., Rumsfeld J.S., Masoudi F.A. The NCDR CathPCI Registry: a US national perspective on care and outcomes for percutaneous coronary intervention. *Heart.* 2013;99(5):297-303. doi: 10.1136/heartjnl-2012-303379.
15. Rao S.V., McCoy L.A., Spertus J.A., Krone R.J., Singh M., Fitzgerald S., Peterson E.D. An updated bleeding model to predict the risk of post-procedure bleeding among patients undergoing percutaneous coronary intervention: a report using an expanded bleeding definition from the National Cardiovascular Data Registry CathPCI Registry. *JACC Cardiovasc Interv.* 2013;6(9):897-904. doi: 10.1016/j.jcin.2013.04.016.
16. Tsai T.T., Patel U.D., Chang T.I., Kennedy K.F., Masoudi F.A., Matheny M.E., Kosiborod M., Amin A.P., Weintraub W.S., Curtis J.P., Messenger J.C., Rumsfeld J.S., Spertus J.A. Validated contemporary risk model of acute kidney injury in patients undergoing percutaneous coronary interventions: insights from the National Cardiovascular Data Registry CathPCI Registry. *J Am Heart Assoc.* 2014;3(6):e001380. doi: 10.1161/JAHA.114.001380.
17. Brennan J.M., Curtis J.P., Dai D., Fitzgerald S., Khandelwal A.K., Spertus J.A., Rao S.V., Singh M., Shaw R.E., Ho K.K., Krone R.J., Weintraub W.S., Weaver W.D., Peterson E.D.; National Cardiovascular Data Registry. Enhanced mortality risk prediction with a focus on high-risk percutaneous coronary intervention: results from 1,208,137 procedures in the NCDR (National Cardiovascular Data Registry). *JACC Cardiovasc Interv.* 2013;6(8):790-799. doi: 10.1016/j.jcin.2013.03.020.
18. Niimi N., Shiraishi Y., Sawano M., Ikemura N., Inohara T., Ueda I., Fukuda K., Kohsaka S. Machine learning models for prediction of adverse events after percutaneous coronary intervention. *Sci Rep.* 2022;12(1):6262. doi: 10.1038/s41598-022-10346-1.
19. Galimzhanov A., Matetic A., Tenekecioglu E., Mamas M.A. Prediction of clinical outcomes after percutaneous coronary intervention: Machine-learning analysis of the National Inpatient Sample. *Int J Cardiol.* 2023;392:131339. doi: 10.1016/j.ijcard.2023.131339.
20. Akhmetzhan. Prediction of clinical outcomes after percutaneous coronary intervention (NIS). GitHub. Available at: https://github.com/Akhmetzhan/Prediction_of_clinical_outcomes_after_percutaneous_coronary_intervention_NIS. (Accessed September 23, 2024).
21. Shillinglaw B., Viera A.J., Edwards T., Simpson R., Sheridan S.L. Use of global coronary heart disease risk assessment in practice: a cross-sectional survey of a sample of U.S. physicians. *BMC Health Serv Res.* 2012;12:20. doi: 10.1186/1472-6963-12-20.
22. Eagle K.A., Lim M.J., Dabbous O.H., Pieper K.S., Goldberg R.J., Van de Werf F., Goodman S.G., Granger C.B. et al.; GRACE Investigators. A validated prediction model for all forms of acute coronary syndrome: estimating the risk of 6-month postdischarge death in an international registry. *JAMA.* 2004;291(22):2727-33. doi: 10.1001/jama.291.22.2727.
23. Sianos G., Morel M.A., Kappetein A.P., Morice M.C., Colombo A., Dawkins J., van den Brand M., Van Dyck N., Russell M.E., Mohr F.W., Serruys P.W. The SYNTAX Score: an angiographic tool grading the complexity of coronary artery disease. *EuroIntervention.* 2005;1(2):219-27.
24. Gerber Y., Weston S.A., Enriquez-Sarano M., Jaffe A.S., Manemann S.M., Jiang R., Roger V.L. Contemporary Risk Stratification After Myocardial Infarction in the Community: Performance of Scores and Incremental Value of Soluble Suppression of Tumorigenicity-2. *J Am Heart Assoc.* 2017;6(10):e005958. doi: 10.1161/JAHA.117.005958.
25. He C., Song Y., Wang C.S., Yao Y., Tang X.F., Zhao X.Y., Gao R.L., Yang Y.J., Xu B., Yuan J.Q. Prognostic Value of the Clinical SYNTAX Score on 2-Year Outcomes in Patients With Acute Coronary Syndrome Who Underwent Percutaneous Coronary Intervention. *Am J Cardiol.* 2017;119(10):1493-1499. doi: 10.1016/j.amjcard.2017.02.031.
26. Zhang D., Yan R., Gao G., Wang H., Fu R., Li J., Yin D., Zhu C., Feng L., Song W., Xu B., Dou K., Yang Y. Validating the Performance of 5 Risk Scores for Major Adverse Cardiac Events in Patients Who Achieved Complete Revascularization After Percutaneous Coronary Intervention. *Can J Cardiol.* 2019;35(8):1058-1068. doi: 10.1016/j.cjca.2019.02.017.
27. Călborean P.A., Grebenişan P., Nistor I.A., Pal K., Vacariu V., Drincal R.K., Țepeș O., Bârlea I., Șuş I. et al. Prediction of 3-year all-cause and cardiovascular cause mortality in a prospective percutaneous coronary intervention registry: Machine learning model outperforms conventional clinical risk scores. *Atherosclerosis.* 2022;350:33-40. doi: 10.1016/j.atherosclerosis.2022.03.028.
28. Wolff G., Lin Y., Quade J., Bader S., Kosejian L., Brockmeyer M., Karathanos A., Parco C. et al. Validation of National Cardiovascular Data Registry risk models for mortality, bleeding and acute kidney injury in interventional cardiology at a German Heart Center. *Clin Res Cardiol.* 2020;109(2):235-245. doi: 10.1007/s00392-019-01506-x.
29. Agasthi P., Chao C.J., Wang P., Yang E.H., Arsanjani R. National Cardiovascular Data Registry Model Predicts Long-Term Mortality in Patients Undergoing Percutaneous Coronary Interventions. *Cardiology.* 2021;146(3):311-314. doi: 10.1159/000512419.
30. Kohsaka S., Miyata H., Ueda I., Masoudi F.A., Peterson E.D., Maekawa Y., Kawamura A., Fukuda K., Roe M.T., Rumsfeld J.S.; JCD-KiCS and NCDR. An international comparison of patients undergoing percutaneous coronary intervention: A collaborative study of the National Cardiovascular Data Registry (NCDR) and Japan Cardiovascular Database-Keio interhospital Cardiovascular Studies (JCD-KiCS). *Am Heart J.* 2015;170(6):1077-85. doi: 10.1016/j.ahj.2015.09.017.
31. Deng W., Wang D., Wan Y., Lai S., Ding Y., Wang X. Prediction models for major adverse cardiovascular events after percutaneous coronary intervention: a systematic review. *Front Cardiovasc Med.* 2024;10:1287434. doi: 10.3389/fcvm.2023.1287434.
32. Healthcare Cost and Utilization Project (HCUP). HCUP National (Nationwide) Inpatient Sample (NIS). Agency for Healthcare Research and Quality (AHRQ). Updated 2021. Available at: <https://www.hcup-us.ahrq.gov> (accessed Sep 23, 2024).
33. Shoji S., Kohsaka S., Kumamaru H., Nishimura S., Ishii H., Amano T., Fushimi K., Miyata H., Ikari Y. Risk prediction models in patients undergoing percutaneous coronary intervention: a collaborative analysis from a Japanese

administrative dataset and nationwide academic procedure registry. *Int J Cardiol.* 2023;370:90-97. doi: 10.1016/j.ijcard.2022.10.144.

34. Bricker R.S., Valle J.A., Plomondon M.E., Armstrong E.J., Waldo S.W. Causes of mortality after percutaneous coronary intervention. *Circ Cardiovasc Qual Outcomes.* 2019;12(5):e005355. doi: 10.1161/CIRCOUTCOMES.118.005355.

35. Li X., Chen Z., Zhang J.M., Sarro F., Zhang Y., Liu X. Bias behind the wheel: fairness analysis of autonomous driving systems. *ACM Trans Softw Eng Methodol.* 2024;1(1):Article 1. doi: 10.1145/nnnnnnn.nnnnnnn.

36. Chawla N.V., Bowyer K.W., Hall L.O., Kegelmeyer W.P. SMOTE: Synthetic minority over-sampling technique. *J Artif Intell Res.* 2002;16:321-357. doi: 10.1613/jair.953.

37. Chouffani El Fassi S., Abdullah A., Fang Y., Natarajan S., Masroor A.B., Kayali N., Prakash S., Henderson G.E. Not all AI health tools with regulatory authorization are clinically validated. *Nat Med.* 2024 ;30(10):2718-2720. doi: 10.1038/s41591-024-03203-3.

38. Spertus J.A., Decker C., Gialde E., Jones P.G., McNulty E.J., Bach R., Chhatrwalla A.K. Precision medicine to improve use of bleeding avoidance strategies and reduce bleeding in patients undergoing percutaneous coronary intervention: prospective cohort study before and after implementation of personalized bleeding risks. *BMJ.* 2015;350:h1302. doi: 10.1136/bmj.h1302.

39. Tacey M., Dinh D.T., Andrianopoulos N., Brennan A.L., Stub D., Liew D., Reid C.M., Duffy S.J., Lefkowitz J. Risk-adjusting key outcome measures in a clinical quality PCI registry: development of a highly predictive model without the need to exclude high-risk conditions. *JACC Cardiovasc Interv.* 2019;12(19):1966-1975. doi: 10.1016/j.jcin.2019.07.002.

40. Landmesser U., Ali Z.A., Maehara A., Matsumura M., Shlofmitz R.A., Guagliumi G., Price M.J., Hill J.M. et al. Optical coherence tomography predictors of clinical outcomes after stent implantation: the ILUMIEN IV trial. *Eur Heart J.* 2024;45(43):4630-4643. doi: 10.1093/eurheartj/ehae521.

41. Hwang D., Lee J.M., Yang S., Chang M., Zhang J., Choi K.H., Kim C.H., Nam C.W. et al. Role of Post-Stent Physiological Assessment in a Risk Prediction Model After Coronary Stent Implantation. *JACC Cardiovasc Interv.* 2020;13(14):1639-1650. doi: 10.1016/j.jcin.2020.04.041.

42. Мордовин В.Ф., Личикаки В.А., Пекарский С.Е., Зюбанова И.В., Манукян М.А., Солонская Е.И., Попова А.А., Хунхинова С.А., Скомкина И.А., Солтанхметова

ва А.Д., Фальковская А.Ю. Функциональная значимость стенозов коронарных артерий: роль артериальной гипертензии (обзор литературы). *Сибирский журнал клинической и экспериментальной медицины.* 2024; 39(4): 10-17. doi:10.29001/2073-8552-2024-39-4-10-17

43. Yang H.M., Lim H.S., Yoon M.H., Seo K.W., Choi B.J., Choi S.Y., Hwang G.S., Tahk S.J. Usefulness of the transient fractional flow reserve gradient for predicting clinical outcomes. *Catheter Cardiovasc Interv.* 2020;95(5):E123-E129. doi: 10.1002/ccd.28363

44. Plitt A., Claessen B.E., Sartori S., Baber U., Chandrasekhar J., Aquino M., Vijay P., Elsayed S. et al. Impact of stent diameter on outcomes following percutaneous coronary intervention with second-generation drug-eluting stents: Results from a large single-center registry. *Catheter Cardiovasc Interv.* 2020;96(3):558-564. doi: 10.1002/ccd.28488.

45. Zhang D., Xu B., Yin D., Li Y., He Y., You S., Qiao S., Wu Y., Yan H., Yang Y., Gao R., Dou K. How bifurcation angle impacts the fate of side branch after main vessel stenting: a retrospective analysis of 1,200 consecutive bifurcation lesions in a single center. *Catheter Cardiovasc Interv.* 2015;85 Suppl 1:706-15. doi: 10.1002/ccd.25858.

46. Perl L., Witberg G., Greenberg G., Vaknin-Assa H., Kornowski R., Assali A. Prognostic significance of the Medina classification in bifurcation lesion percutaneous coronary intervention with second-generation drug-eluting stents. *Heart Vessels.* 2020;35(3):331-339. doi: 10.1007/s00380-019-01504-z.

47. Nakachi T., Yamane M., Kishi K., Muramatsu T., Okada H., Oikawa Y., Yoshikawa R., Kawasaki T., Tanaka H., Katoh O. Machine Learning for Prediction of Technical Results of Percutaneous Coronary Intervention for Chronic Total Occlusion. *J Clin Med.* 2023;12(10):3354. doi: 10.3390/jcm12103354.

48. Mamas M.A., Roffi M., Fröbert O., Chieffo A., Beneduce A., Matetic A., Tonino P.A.L., Paunovic D. et al. Predicting target lesion failure following percutaneous coronary intervention through machine learning risk assessment models. *Eur Heart J Digit Health.* 2023;4(6):433-443. doi: 10.1093/ehjdh/ztd051.

49. Jie L., Feng X.X., Duan Y.F., Liu J.H., Zhang C., Jiang L., Xu L.J., Tian J. et al. Using machine learning to aid treatment decision and risk assessment for severe three-vessel coronary artery disease. *J Geriatr Cardiol.* 2022;19(5):367-376. doi: 10.11909/j.issn.1671-5411.2022.05.005.

REFERENCES

1. Canfield J., Totary-Jain H. 40 years of percutaneous coronary intervention: history and future directions. *J Pers Med.* 2018;8(4):33. doi: 10.3390/jpm8040033.

2. Amin A.P., Salisbury A.C., McCullough P.A., Gosch K., Spertus J.A., Venkitachalam L., Stolker J.M., Parikh C.R., Masoudi F.A., Jones P.G., Kosiborod M. Trends in the incidence of acute kidney injury in patients hospitalized with acute myocardial infarction. *Arch Intern Med.* 2012;172(3):246-53. doi: 10.1001/archinternmed.2011.1202.

3. Subherwal S., Peterson E.D., Dai D., Thomas L., Messenger J.C., Xian Y., Brindis R.G., Feldman D.N., Senter S., Klein L.W., Marso S.P., Roe M.T., Rao S.V. Temporal trends in and factors associated with bleeding complications among patients undergoing percutaneous coronary intervention: a report from the National Cardiovascular Data CathPCI Registry. *J Am Coll Cardiol.* 2012;59(21):1861-9. doi: 10.1016/j.jacc.2011.12.045.

4. Murali S., Vogrin S., Noaman S., Dinh D.T., Brennan A.L., Lefkowitz J., Reid C.M., Cox N., Chan W. Bleeding severity in percutaneous coronary intervention (PCI) and its impact on short-term clinical outcomes. *J Clin Med.* 2020;9(5):1426. doi: 10.3390/jcm9051426.

5. Deo R.C. Machine learning in medicine. *Circulation.* 2015;132(20):1920-30. doi: 10.1161/CIRCULATIONAHA.115.001593.

6. Chen T., Guestrin C. XGBoost: a scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining.* New York (NY): Association for Computing Machinery; 2016. p. 785-94.

7. Ninomiya K., Kageyama S., Garg S., Masuda S., Kotoku N., Revaiah P.C., O'Leary N., Onuma Y., Serruys P.W.; SYNTAX Extended Survival Investigators. Can machine learning unravel unsuspected, clinically important factors predictive of long-term mortality in complex coronary artery disease? A call for 'big data'. *Eur Heart J Digit Health.* 2023;4(3):275-278. doi: 10.1093/ehjdh/ztd014.

8. Hamilton D.E., Albright J., Seth M., Painter I., Maynard C., Hira R.S., Sukul D., Gurm H.S. Merging machine learning and patient preference: a novel tool for risk prediction of percutaneous coronary interventions. *Eur Heart J.* 2024;45(8):601-609. doi: 10.1093/eurheartj/ehad836.

9. Galimzhanov A., Matetic A., Tenekecioglu E., Mamas M.A. Prediction of clinical outcomes after percutaneous

coronary intervention: machine-learning analysis of the National Inpatient Sample. *Int J Cardiol.* 2023;392:131339. doi: 10.1016/j.ijcard.2023.131339.

10. Clinical Assessment Reporting and Tracking System for Cath Labs (CART-CL). VA Health Services Research & Development. Available from: <https://www.hsrd.research.va.gov/impacts/cart-cl.cfm>. (Accessed 2024 Sep 23).

11. Doll J.A., O'Donnell C.I., Plomondon M.E., Waldo S.W. Development and Implementation of an In-Hospital Bleeding Risk Model for Percutaneous Coronary Intervention. *Cardiovasc Revasc Med.* 2021;28:20-24. doi: 10.1016/j.carrev.2020.07.033.

12. Doll J.A., O'Donnell C.I., Plomondon M.E., Waldo S.W. Contemporary Clinical and Coronary Anatomic Risk Model for 30-Day Mortality After Percutaneous Coronary Intervention. *Circ Cardiovasc Interv.* 2021;14(12):e010863. doi: 10.1161/CIRCINTERVENTIONS.121.010863.

13. Singh M., Gulati R., Lewis B.R., Zhou Z., Alkhouli M., Friedman P., Bell M.R. Multimorbidity and Mortality Models to Predict Complications Following Percutaneous Coronary Interventions. *Circ Cardiovasc Interv.* 2022;15(7):e011540. doi: 10.1161/CIRCINTERVENTIONS.121.011540.

14. Moussa I., Hermann A., Messenger J.C., Dehmer G.J., Weaver W.D., Rumsfeld J.S., Masoudi F.A. The NCDR CathPCI Registry: a US national perspective on care and outcomes for percutaneous coronary intervention. *Heart.* 2013;99(5):297-303. doi: 10.1136/heartjnl-2012-303379.

15. Rao S.V., McCoy L.A., Spertus J.A., Krone R.J., Singh M., Fitzgerald S., Peterson E.D. An updated bleeding model to predict the risk of post-procedure bleeding among patients undergoing percutaneous coronary intervention: a report using an expanded bleeding definition from the National Cardiovascular Data Registry CathPCI Registry. *JACC Cardiovasc Interv.* 2013;6(9):897-904. doi: 10.1016/j.jcin.2013.04.016.

16. Tsai T.T., Patel U.D., Chang T.I., Kennedy K.F., Masoudi F.A., Matheny M.E., Kosiborod M., Amin A.P., Weintraub W.S., Curtis J.P., Messenger J.C., Rumsfeld J.S., Spertus J.A. Validated contemporary risk model of acute kidney injury in patients undergoing percutaneous coronary interventions: insights from the National Cardiovascular Data Registry CathPCI Registry. *J Am Heart Assoc.* 2014;3(6):e001380. doi: 10.1161/JAHA.114.001380.

17. Brennan J.M., Curtis J.P., Dai D., Fitzgerald S., Khandelwal A.K., Spertus J.A., Rao S.V., Singh M., Shaw R.E., Ho K.K., Krone R.J., Weintraub W.S., Weaver W.D., Peterson E.D.; National Cardiovascular Data Registry. Enhanced mortality risk prediction with a focus on high-risk percutaneous coronary intervention: results from 1,208,137 procedures in the NCDR (National Cardiovascular Data Registry). *JACC Cardiovasc Interv.* 2013;6(8):790-799. doi: 10.1016/j.jcin.2013.03.020.

18. Niimi N., Shiraishi Y., Sawano M., Ikemura N., Inohara T., Ueda I., Fukuda K., Kohsaka S. Machine learning models for prediction of adverse events after percutaneous coronary intervention. *Sci Rep.* 2022;12(1):6262. doi: 10.1038/s41598-022-10346-1.

19. Galimzhanov A., Matetic A., Tenekecioglu E., Mamas M.A. Prediction of clinical outcomes after percutaneous coronary intervention: Machine-learning analysis of the National Inpatient Sample. *Int J Cardiol.* 2023;392:131339. doi: 10.1016/j.ijcard.2023.131339.

20. Akhmetzhan. Prediction of clinical outcomes after percutaneous coronary intervention (NIS). GitHub. Available at: https://github.com/Akhmetzhan/Prediction_of_clinical_outcomes_after_percutaneous_coronary_intervention_NIS. (Accessed September 23, 2024).

21. Shillinglaw B., Viera A.J., Edwards T., Simpson R., Sheridan S.L. Use of global coronary heart disease risk assessment in practice: a cross-sectional survey of a sample of U.S. physicians. *BMC Health Serv Res.* 2012;12:20. doi: 10.1186/1472-6963-12-20.

22. Eagle K.A., Lim M.J., Dabbous O.H., Pieper K.S., Goldberg R.J., Van de Werf F., Goodman S.G., Granger C.B. et al.; GRACE Investigators. A validated prediction model for all forms of acute coronary syndrome: estimating the risk of 6-month postdischarge death in an international registry. *JAMA.* 2004;291(22):2727-33. doi: 10.1001/jama.291.22.2727.

23. Sianos G., Morel M.A., Kappetein A.P., Morice M.C., Colombo A., Dawkins., van den Brand M., Van Dyck N., Russell M.E., Mohr F.W., Serruys P.W. The SYNTAX Score: an angiographic tool grading the complexity of coronary artery disease. *EuroIntervention.* 2005;1(2):219-27.

24. Gerber Y., Weston S.A., Enriquez-Sarano M., Jaffe A.S., Manemann S.M., Jiang R., Roger V.L. Contemporary Risk Stratification After Myocardial Infarction in the Community: Performance of Scores and Incremental Value of Soluble Suppression of Tumorigenicity-2. *J Am Heart Assoc.* 2017;6(10):e005958. doi: 10.1161/JAHA.117.005958.

25. He C., Song Y., Wang C.S., Yao Y., Tang X.F., Zhao X.Y., Gao R.L., Yang Y.J., Xu B., Yuan J.Q. Prognostic Value of the Clinical SYNTAX Score on 2-Year Outcomes in Patients With Acute Coronary Syndrome Who Underwent Percutaneous Coronary Intervention. *Am J Cardiol.* 2017;119(10):1493-1499. doi: 10.1016/j.amjcard.2017.02.031.

26. Zhang D., Yan R., Gao G., Wang H., Fu R., Li J., Yin D., Zhu C., Feng L., Song W., Xu B., Dou K., Yang Y. Validating the Performance of 5 Risk Scores for Major Adverse Cardiac Events in Patients Who Achieved Complete Revascularization After Percutaneous Coronary Intervention. *Can J Cardiol.* 2019;35(8):1058-1068. doi: 10.1016/j.cjca.2019.02.017.

27. Călburean P.A., Grebenişan P., Nistor I.A., Pal K., Vacariu V., Drincal R.K., Țepes O., Bârlea I., Șuş I. et al. Prediction of 3-year all-cause and cardiovascular cause mortality in a prospective percutaneous coronary intervention registry: Machine learning model outperforms conventional clinical risk scores. *Atherosclerosis.* 2022;350:33-40. doi: 10.1016/j.atherosclerosis.2022.03.028.

28. Wolff G., Lin Y., Quade J., Bader S., Kosejian L., Brockmeyer M., Karathanos A., Parco C. et al. Validation of National Cardiovascular Data Registry risk models for mortality, bleeding and acute kidney injury in interventional cardiology at a German Heart Center. *Clin Res Cardiol.* 2020;109(2):235-245. doi: 10.1007/s00392-019-01506-x.

29. Agasthi P., Chao C.J., Wang P., Yang E.H., Arsanjani R. National Cardiovascular Data Registry Model Predicts Long-Term Mortality in Patients Undergoing Percutaneous Coronary Interventions. *Cardiology.* 2021;146(3):311-314. doi: 10.1159/000512419.

30. Kohsaka S., Miyata H., Ueda I., Masoudi F.A., Peterson E.D., Maekawa Y., Kawamura A., Fukuda K., Roe M.T., Rumsfeld J.S.; JCD-KiCS and NCDR. An international comparison of patients undergoing percutaneous coronary intervention: A collaborative study of the National Cardiovascular Data Registry (NCDR) and Japan Cardiovascular Database-Keio interhospital Cardiovascular Studies (JCD-KiCS). *Am Heart J.* 2015;170(6):1077-85. doi: 10.1016/j.ahj.2015.09.017.

31. Deng W., Wang D., Wan Y., Lai S., Ding Y., Wang X. Prediction models for major adverse cardiovascular events after percutaneous coronary intervention: a systematic review. *Front Cardiovasc Med.* 2024;10:1287434. doi: 10.3389/fcvm.2023.1287434.

32. Healthcare Cost and Utilization Project (HCUP). HCUP National (Nationwide) Inpatient Sample (NIS). Agency for Healthcare Research and Quality (AHRQ). Updated 2021. Available at: <https://www.hcup-us.ahrq.gov> (accessed Sep 23, 2024).

33. Shoji S., Kohsaka S., Kumamaru H., Nishimura S., Ishii H., Amano T., Fushimi K., Miyata H., Ikari Y. Risk prediction models in patients undergoing percutaneous coronary intervention: a collaborative analysis from a Japanese administrative dataset and nationwide academic procedure

registry. *Int J Cardiol.* 2023;370:90-97. doi: 10.1016/j.ijcard.2022.10.144.

34. Bricker R.S., Valle J.A., Plomondon M.E., Armstrong E.J., Waldo S.W. Causes of mortality after percutaneous coronary intervention. *Circ Cardiovasc Qual Outcomes.* 2019;12(5):e005355. doi: 10.1161/CIRCOUTCOMES.118.005355.

35. Li X., Chen Z., Zhang J.M., Sarro F., Zhang Y., Liu X. Bias behind the wheel: fairness analysis of autonomous driving systems. *ACM Trans Softw Eng Methodol.* 2024;1(1):Article 1. doi: 10.1145/nnnnnnnnnnnnnnnnnnnn.

36. Chawla N.V., Bowyer K.W., Hall L.O., Kegelmeyer W.P. SMOTE: Synthetic minority over-sampling technique. *J Artif Intell Res.* 2002;16:321-357. doi: 10.1613/jair.953.

37. Chouffani El Fassi S., Abdullah A., Fang Y., Natarajan S., Masroor A.B., Kayali N., Prakash S., Henderson G.E. Not all AI health tools with regulatory authorization are clinically validated. *Nat Med.* 2024 ;30(10):2718-2720. doi: 10.1038/s41591-024-03203-3.

38. Spertus J.A., Decker C., Gialde E., Jones P.G., McNulty E.J., Bach R., Chhatrwalla A.K. Precision medicine to improve use of bleeding avoidance strategies and reduce bleeding in patients undergoing percutaneous coronary intervention: prospective cohort study before and after implementation of personalized bleeding risks. *BMJ.* 2015;350:h1302. doi: 10.1136/bmj.h1302.

39. Tacey M., Dinh D.T., Andrianopoulos N., Brennan A.L., Stub D., Liew D., Reid C.M., Duffy S.J., Lefkovits J. Risk-adjusting key outcome measures in a clinical quality PCI registry: development of a highly predictive model without the need to exclude high-risk conditions. *JACC Cardiovasc Interv.* 2019;12(19):1966-1975. doi: 10.1016/j.jcin.2019.07.002.

40. Landmesser U., Ali Z.A., Maehara A., Matsumura M., Shlofmitz R.A., Guagliumi G., Price M.J., Hill J.M. et al. Optical coherence tomography predictors of clinical outcomes after stent implantation: the ILUMIEN IV trial. *Eur Heart J.* 2024;45(43):4630-4643. doi: 10.1093/eurheartj/ehae521.

41. Hwang D., Lee J.M., Yang S., Chang M., Zhang J., Choi K.H., Kim C.H., Nam C.W. et al. Role of Post-Stent Physiological Assessment in a Risk Prediction Model After Coronary Stent Implantation. *JACC Cardiovasc Interv.* 2020;13(14):1639-1650. doi: 10.1016/j.jcin.2020.04.041.

42. Mordovin V.F., Lichikaki V.A., Pekarskiy S.E., Zyubanova I.V., Manukyan M.A., Solonskaya E.I., Popova A.A., Khunkhinova S.A., Skomkina I.A., Soltanakhmetova

A.D., Falkovskaya A.Yu. Functional significance of coronary artery stenosis: the role of arterial hypertension (literature review). *Siberian Journal of Clinical and Experimental Medicine.* 2024; 39(4): 10–17. doi:10.29001/2073-8552-2024-39-4-10-17. (In Russian)

43. Yang H.M., Lim H.S., Yoon M.H., Seo K.W., Choi B.J., Choi S.Y., Hwang G.S., Tahk S.J. Usefulness of the trans-stent fractional flow reserve gradient for predicting clinical outcomes. *Catheter Cardiovasc Interv.* 2020;95(5):E123-E129. doi: 10.1002/ccd.28363

44. Plitt A., Claessen B.E., Sartori S., Baber U., Chandrasekhar J., Aquino M., Vijay P., Elsayed S. et al. Impact of stent diameter on outcomes following percutaneous coronary intervention with second-generation drug-eluting stents: Results from a large single-center registry. *Catheter Cardiovasc Interv.* 2020;96(3):558-564. doi: 10.1002/ccd.28488.

45. Zhang D., Xu B., Yin D., Li Y., He Y., You S., Qiao S., Wu Y., Yan H., Yang Y., Gao R., Dou K. How bifurcation angle impacts the fate of side branch after main vessel stenting: a retrospective analysis of 1,200 consecutive bifurcation lesions in a single center. *Catheter Cardiovasc Interv.* 2015;85 Suppl 1:706-15. doi: 10.1002/ccd.25858.

46. Perl L., Witberg G., Greenberg G., Vaknin-Assa H., Kornowski R., Assali A. Prognostic significance of the Medina classification in bifurcation lesion percutaneous coronary intervention with second-generation drug-eluting stents. *Heart Vessels.* 2020;35(3):331-339. doi: 10.1007/s00380-019-01504-z.

47. Nakachi T., Yamane M., Kishi K., Muramatsu T., Okada H., Oikawa Y., Yoshikawa R., Kawasaki T., Tanaka H., Katoh O. Machine Learning for Prediction of Technical Results of Percutaneous Coronary Intervention for Chronic Total Occlusion. *J Clin Med.* 2023;12(10):3354. doi: 10.3390/jcm12103354.

48. Mamas M.A., Roffi M., Fröbert O., Chieffo A., Beneduce A., Matetic A., Tonino P.A.L., Paunovic D. et al. Predicting target lesion failure following percutaneous coronary intervention through machine learning risk assessment models. *Eur Heart J Digit Health.* 2023;4(6):433-443. doi: 10.1093/ehjdh/ztad051.

49. Jie L., Feng X.X., Duan Y.F., Liu J.H., Zhang C., Jiang L., Xu L.J., Tian J. et al. Using machine learning to aid treatment decision and risk assessment for severe three-vessel coronary artery disease. *J Geriatr Cardiol.* 2022;19(5):367-376. doi: 10.11909/j.issn.1671-5411.2022.05.005.

Для цитирования: Гороховский А.А., Пекарский С.Е., Баев А.Е., Тарасов М.Г., Суслов И.В., Гергерт Е.С., Богданов Ю.И., Султанов С.М. Обзор современных предсказательных моделей множественных осложнений чкв: роль машинного обучения и традиционных подходов. *Комплексные проблемы сердечно-сосудистых заболеваний.* 2025;14(3): 96-111. DOI: 10.17802/2306-1278-2025-14-3-96-111

To cite: Gorokhovskiy A.A., Pekarskiy S.E., Baev A.E., Tarasov M.G., Suslov I.V., Gergert E.S., Bogdanov Yu.I., Sultanov S.M. Review of modern predictive models of multiple complications after pci: the role of machine learning and traditional approaches. *Complex Issues of Cardiovascular Diseases.* 2025;14(3): 96-111. DOI: 10.17802/2306-1278-2025-14-3-96-111