

ТИТУЛЬНЫЙ ЛИСТ

Название статьи (рус.): Искусственный интеллект в сердечно-сосудистой хирургии и смежных специальностях: состояние проблемы и пути развития технологии

Article title (eng.): Artificial intelligence in cardiovascular surgery and related specialties: state of the art and development of the technology

Тип статьи: обзорная (нарративный обзор).

Авторы (рус.): Яблонский П.П.^{1, 2}, Эфендиев В.У.², Минин Е.А.², Земцова И.Ю.¹, Светликов А.В.^{1, 3}, Яблонский П.К.^{1, 4}

Authors (eng.): Iablonskii P.P.^{1,2}, Efendiev V.U.², Minin E.A.², Zemtsova I.Yu.¹, Svetlikov A.V.^{1,3}, Yablonski P.K.^{1,4}

Аффилиации (рус.):

1 — Медицинский институт ФГБОУ ВО «Санкт-Петербургский государственный университет», Санкт-Петербург, Россия;

2 — ООО «Мой медицинский центр» — клиника высоких технологий «Белоостров», Санкт-Петербург, Россия;

3 — ФГБУ «Северо-Западный окружной научно-клинический центр им. Л.Г. Соколова» ФМБА России, Санкт-Петербург, Россия;

4 — ФГБУ «Санкт-Петербургский научно-исследовательский институт фтизиопульмонологии». МЗ РФ, Санкт-Петербург, Россия.

Affiliations (eng.) *[уточнить официальные англоязычные названия учреждений]:*

1 — Medical Institute, Saint Petersburg State University, Saint Petersburg, Russia;

2 — “My Medical Center” LLC — Beloostrov Clinic of High Technologies, Saint Petersburg, Russia;

3 — L.G. Sokolov North-Western District Scientific and Clinical Center, FMBA of Russia, Saint Petersburg, Russia;

4 — Russian Federation Healthcare Ministry Saint-Petersburg State Phthisiopulmonology Research Institute

СВЕДЕНИЯ ОБ АВТОРАХ

1. Яблонский Павел Петрович (Iablonskii Pavel Petrovich)

Должность, учёная степень/звание: к.м.н., врач – сердечно-сосудистый хирург, доцент кафедры госпитальной хирургии

Место работы (аффилиация № 1): Медицинский институт ФГБОУ ВО «Санкт-Петербургский государственный университет»

Место работы (аффилиация № 2): ООО «Мой медицинский центр» — клиника высоких технологий «Белоостров»

ORCID ID: <https://orcid.org/0000-0002-0192-1931>

e-mail: pavel.yablonski@gmail.com

2. Эфендиев Видади Умудович (Efendiev Vidadi Umudovitch)

Должность, учёная степень/звание: к.м.н., врач – сердечно-сосудистый хирург

Место работы (аффилиация № 2): ООО «Мой медицинский центр» — клиника высоких технологий «Белоостров»

ORCID ID: <https://orcid.org/0000-0002-5170-4978>

e-mail: vefendiev@groupmmc.ru

3. Минин Евгений Александрович (Minin Evgenii Aleksandrovitch)

Должность, учёная степень/звание: врач – сердечно-сосудистый хирург

Место работы (аффилиация № 2): ООО «Мой медицинский центр»
— клиника высоких технологий «Белоостров»

ORCID ID: <https://orcid.org/0009-0003-6320-5783>

e-mail: eminin@groupmmc.ru

4. Земцова Ирина Юрьевна (Minin Evgenii Aleksandrovitch)

Должность, учёная степень/звание: к.м.н., врач – торакальный хирург, ассистент кафедры госпитальной хирургии

Место работы (аффилиация № 1): Медицинский институт ФГБОУ ВО «Санкт-Петербургский государственный университет»

ORCID ID: <https://orcid.org/0000-0002-4587-601X>

e-mail: zemtsova2908@gmail.com

5. Светликов Алексей Владимирович (Svetlikov Alexey Vladimirovitch)

Должность, учёная степень/звание: д.м.н., врач – сердечно-сосудистый хирург, профессор кафедры госпитальной хирургии

Место работы (аффилиация № 1): Медицинский институт ФГБОУ ВО «Санкт-Петербургский государственный университет»

ORCID ID: <https://orcid.org/0000-0001-8652-8778>

e-mail: asvetlikov@mail.ru

6. Яблонский Петр Казимирович (Yablonsky Piotr Kazimirovitch)

Должность, учёная степень/звание: д.м.н., профессор, заведующий кафедрой, директор СПбНИИФ

Место работы (аффилиация № 1): Медицинский институт ФГБОУ ВО «Санкт-Петербургский государственный университет»

Место работы (аффилиация № 4): ФГБУ «Санкт-Петербургский научно-исследовательский институт фтизиопульмонологии» МЗ РФ

ORCID ID: <https://orcid.org/0000-0003-4385-9643>

e-mail: piotr_yablonskii@mail.ru

ОТВЕТСТВЕННЫЙ ЗА ПЕРЕПИСКУ (CORRESPONDING AUTHOR)

Ф.И.О.: Яблонский Павел Петрович

Почтовый адрес: 194214, Санкт-Петербург, Костромской пр. 71-49

Телефон: +7 9062602247

e-mail: pavel.yablonski@gmail.com

АННОТАЦИЯ

Цель — систематизировать современные направления применения искусственного интеллекта (ИИ) в сердечно-сосудистой хирургии и смежных специальностях и обозначить новейшие технологические тенденции. **Материалы и методы** — нарративный обзор литературы из баз PubMed/MEDLINE, Scopus, Web of Science, Cochrane Library, CyberLeninka и РИНЦ (eLibrary) за 2014–2026 гг.; при критической оценке включённых работ учитывались рекомендации EQUATOR (TRIPOD, STARD, PRISMA). **Результаты** — рассмотрены основные клинические приложения ИИ: автоматизированный анализ электрокардиограмм и медицинских изображений, прогнозирование исходов вмешательств и сердечно-сосудистого риска, системы поддержки принятия решений. Показан переход от узкоспециализированных нейросетей к фундаментальным моделям и трансформерам, обученным на десятках миллионов записей, появление больших языковых моделей в клиническом контуре и первые демонстрации автономной роботизированной хирургии. **Заключение** — на обозримую перспективу наиболее реалистична и безопасна модель «дополненного интеллекта», в которой ИИ выступает помощником врача, тогда как окончательное решение и ответственность остаются за человеком; ключевыми условиями внедрения являются проспективная валидация, прозрачность алгоритмов и адекватная регуляторная рамка.

Ключевые слова: искусственный интеллект, машинное обучение, глубокое обучение, нейронные сети, сердечно-сосудистая хирургия, прогностические модели.

ABSTRACT

Aim — to systematise current applications of artificial intelligence (AI) in cardiovascular surgery and related specialties and to outline the latest technological trends. **Materials and methods** — a narrative review of the literature from PubMed/MEDLINE, Scopus, Web of Science, the Cochrane Library, CyberLeninka and the RSCI (eLibrary) for 2014–2026; included studies were appraised with reference to the EQUATOR guidelines (TRIPOD, STARD, PRISMA). **Results** — the principal clinical applications of AI are reviewed: automated analysis of electrocardiograms and medical images, prediction of procedural outcomes and cardiovascular risk, and clinical decision-support systems. The shift from narrow task-specific networks to foundation models and transformers trained on tens of millions of records is demonstrated, together with the emergence of large language models within the clinical loop and the first demonstrations of autonomous robotic surgery. **Conclusion** — for the foreseeable future the most realistic and safe model is that of ‘augmented intelligence’, in which AI assists the physician while the final decision and responsibility remain human; prospective validation, algorithmic transparency and an adequate regulatory framework are key prerequisites for implementation.

Keywords: artificial intelligence; machine learning; deep learning; neural networks, computer; cardiac surgical procedures; forecasting.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Источники финансирования: исследование проведено без спонсорской поддержки.

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В СЕРДЕЧНО-СОСУДИСТОЙ ХИРУРГИИ И СМЕЖНЫХ СПЕЦИАЛЬНОСТЯХ: СОСТОЯНИЕ ПРОБЛЕМЫ И ПУТИ РАЗВИТИЯ ТЕХНОЛОГИИ

Обзорная статья

Аннотация. **Цель** — систематизировать современные направления применения искусственного интеллекта (ИИ) в сердечно-сосудистой хирургии и смежных специальностях и обозначить новейшие технологические тенденции. **Материалы и методы** — нарративный обзор литературы из баз PubMed/MEDLINE, Scopus, Web of Science, Cochrane Library, CyberLeninka и РИНЦ (eLibrary) за 2014–2026 гг.; при критической оценке включённых работ учитывались рекомендации EQUATOR (TRIPOD, STARD, PRISMA). **Результаты** — рассмотрены основные клинические приложения ИИ: автоматизированный анализ электрокардиограмм и медицинских изображений, прогнозирование исходов вмешательств и сердечно-сосудистого риска, системы поддержки принятия решений. Показан переход от узкоспециализированных нейросетей к фундаментальным моделям и трансформерам, обученным на десятках миллионов записей, появление больших языковых моделей в клиническом контуре и первые демонстрации автономной роботизированной хирургии. **Заключение** — на обозримую перспективу наиболее реалистична и безопасна модель «дополненного интеллекта», в которой ИИ выступает помощником врача, тогда как окончательное решение и ответственность остаются за человеком; ключевыми условиями внедрения являются проспективная валидация, прозрачность алгоритмов и адекватная регуляторная рамка.

Ключевые слова: искусственный интеллект, машинное обучение, глубокое обучение, нейронные сети, сердечно-сосудистая хирургия, прогностические модели.

Abstract. Aim — to systematise current applications of artificial intelligence (AI) in cardiovascular surgery and related specialties and to outline the latest technological trends. **Materials and methods** — a narrative review of the literature from PubMed/MEDLINE, Scopus, Web of Science, the Cochrane Library, CyberLeninka and the RSCI (eLibrary) for 2014–2026; included studies were appraised with reference to the EQUATOR guidelines (TRIPOD, STARD, PRISMA). **Results** — the principal clinical applications of AI are reviewed: automated analysis of electrocardiograms and medical images, prediction of procedural outcomes and cardiovascular risk, and clinical decision-support systems. The shift from narrow task-specific networks to foundation models and transformers trained on tens of millions of records is demonstrated, together with the emergence of large language models within the clinical loop and the first demonstrations of autonomous robotic surgery. **Conclusion** — for the foreseeable future the most realistic and safe model is that of ‘augmented intelligence’, in which AI assists the physician while the final decision and responsibility remain human; prospective validation, algorithmic transparency and an adequate regulatory framework are key prerequisites for implementation.

Keywords: artificial intelligence; machine learning; deep learning; neural networks, computer; cardiac surgical procedures; forecasting.

Введение

Развитие цифровых технологий, рост вычислительной мощности и совершенствование программного обеспечения закономерно привели к появлению сложных продуктов, объединяемых общим названием «**искусственный интеллект**» (ИИ). Если первые такие программы были способны, по сути, лишь к автоматизированному статистическому анализу, то следующий уровень — **машинное обучение (machine learning)** — позволил проводить анализ после «обучения»: система не требует программирования под конкретную задачу, а на основании сформулированных человеком вводных сама распознаёт закономерности и

строит прогноз. Дальнейшая ступень — **глубокое обучение (deep learning)**, или нейросети, — в некотором приближении имитирует процессы головного мозга и опирается на многослойную структуру вычислительных алгоритмов, промежуточные результаты которой скрыты от человека (чем больше слоёв — тем «глубже» обучение). Такие системы способны учиться на собственных ошибках, сравнивая расчёты с реальностью и корректируя алгоритмы. Сложность их применения в том, что для обучения требуются огромные массивы данных и значительные вычислительные ресурсы.

Различные архитектуры глубокого обучения — конволюционные (CNN), рекуррентные (RNN), байесовские (BNN) и графовые конволюционные сети (GCN) — имеют свои структуры и подходят для разных типов данных. Так, CNN превосходны в обработке изображений; RNN — в работе с последовательными данными (текст, речь, сигнал); BNN оперируют вероятностными распределениями, что важно при высокой цене ошибки прогноза; GCN ориентированы на данные с графовой структурой [1]. Особое место занимает **генеративный предобученный трансформер (GPT, generative pre-trained transformer)**, изначально созданный для синтеза текста, но проявивший себя и в систематизации, ранжировании и прогнозировании. В понятие ИИ применительно к медицине входят также **когнитивное вычисление (cognitive computing)** — автоматизированное планирование лечения; **компьютерное зрение (computer vision)** — интерпретация изображений; и **робототехника (robotics)** — автоматизированные или полуавтоматизированные вмешательства [2]. Примерное соотношение этих компонентов представлено на рис. 1.




Рисунок 1. Общая схема взаимоотношений компонентов искусственного интеллекта (CNNs — convolutional neural networks, RNNs — recurrent neural networks, DNNs — deep neural networks, GPT — generative pre-trained transformer, NLP — natural language processing).

По мере развития технологий в литературе прослеживается чёткий тренд перехода от простых моделей статистического анализа к глубокому обучению (общая эволюция методов представлена на рис. 2). Так, в систематическом обзоре R.M. Sulague и соавт., охватывающем работы до 2022 года, лишь одна из 42 публикаций использовала глубокое обучение, тогда как более поздние работы опираются на нейросети практически повсеместно [3]; новейшие обзоры рассматривают ИИ уже как сквозную технологию кардиохирургии — от предоперационной стратификации риска до интраоперационной навигации и послеоперационного ведения [4]. Тем не менее внедрение ИИ в клинику пока ограничено в силу этических, юридических и технических нюансов (подробнее — в разделе об ограничениях), и эти барьеры мы рассмотрим отдельно [5,6]. Возможности ИИ не исчерпываются клиникой: он применяется в разработке новых лекарств [7] и материалов [8], — однако настоящий обзор посвящён преимущественно клиническому использованию ИИ в практике кардиолога и кардиохирурга.




Рисунок 2. Эволюция методов искусственного интеллекта в медицине — от автоматизированного статистического анализа к фундаментальным и большим языковым моделям.

Условно можно выделить несколько типовых ситуаций, в которых ИИ способен помочь врачу: **(1)** оценка результатов обследования и анализ медицинских изображений (ЭКГ, рентгенограммы, КТ, УЗИ) — снятие монотонных, легко оцифровываемых задач и ускорение диагностики; **(2)** прогнозирование исходов лечения; **(3)** прогнозирование риска развития сердечно-сосудистых заболеваний; **(4)** помощь в принятии решения о выборе тактики — выявление пациентов высокого риска, углублённая оценка периоперационного риска, рекомендации по типу вмешательства (открытое или катетерное) и модели импланта. В соответствии с этой логикой и построен дальнейший обзор. Подчеркнём, что настоящая работа носит нарративный характер: она обобщает наиболее показательные исследования и не претендует на исчерпывающий систематический охват.

Материалы и методы

Работа представляет собой нарративный обзор литературы. Поиск публикаций проводился в международных базах данных PubMed/MEDLINE, Scopus, Web of Science и Cochrane Library, а также в русскоязычных ресурсах CyberLeninka и РИНЦ (eLibrary). Использовались ключевые слова и их сочетания: «искусственный интеллект», «машинное обучение», «глубокое обучение», «нейронные сети», «фундаментальные

модели», «большие языковые модели» в комбинации с терминами «сердечно-сосудистая хирургия», «кардиохирургия», «кардиология», «электрокардиография», «эхокардиография», «компьютерная томография» (и их англоязычными эквивалентами). Глубина поиска — преимущественно 2014–2026 гг., с включением отдельных основополагающих более ранних работ. Отбирались публикации, описывающие клинически значимые приложения ИИ; приоритет отдавался оригинальным исследованиям, систематическим обзорам и высокоцитируемым источникам. При критической оценке включённых работ авторы ориентировались на рекомендации ресурса EQUATOR — TRIPOD (для моделей прогнозирования), STARD (для диагностических исследований) и PRISMA (для систематических обзоров). Ввиду нарративного характера обзора формальный протокол PRISMA не регистрировался; настоящая работа не претендует на исчерпывающий систематический охват.

Результаты

Искусственный интеллект в диагностике сердечно-сосудистых заболеваний Анализ электрокардиограмм

Электрокардиограмма (ЭКГ) — базовый и при этом информативный инструмент, удобный для автоматизированного анализа. Алгоритм на основе глубокой нейросети (DNN) позволил с высокой точностью различать 12 классов нарушений ритма — фибрилляцию предсердий, атриовентрикулярную блокаду, тригеминию и другие, — причём анализ выполнялся всего по одному отведению носимого монитора (Zio, iRhythm, США), что говорит о лёгкости переноса технологии на любые носимые устройства — смарт-часы, браслеты, кольца [9]. Возможности ЭКГ выходят далеко за рамки распознавания аритмий. Так, S. Raghunath и соавт. на 2,34 млн ЭКГ более чем 536 000 пациентов обучили нейросеть прогнозировать годовичную выживаемость с площадью под кривой (AUC) 0,876 — выше, чем у индекса Charlson (0,816; $p < 0,05$). Наиболее показательно, что на ЭКГ, расценённых врачами как «нормальные» (17,7 % исследований), модель

сохраняла AUC 0,849, а относительный риск смерти в этой когорте оказался даже выше, чем при патологических ЭКГ (HR 9,5 против 6,8). При повторной слепой оценке десятью кардиологами знакомство с прогнозом нейросети улучшало их точность в среднем на 13 % ($p = 0,017$) [10]. Схожий подход — прогнозирование 30-дневной послеоперационной летальности по ЭКГ — показал почти девятикратное повышение риска у отнесённых к группе высокого риска (OR 8,83; 95 % ДИ 5,57–13,2), превзойдя индекс RCRI и сохраняя эффективность после самых разных вмешательств [11].

Принципиально новый этап — переход от моделей «под одну задачу» к **фундаментальным моделям (foundation models)**: предобученным на огромных неразмеченных массивах сетям, которые затем «дообучаются» под конкретную задачу с минимальным числом примеров. Так, модель **ECGFounder** обучена на 10 771 552 ЭКГ от 1 818 247 пациентов (Harvard–Emory ECG Database) с разметкой по 150 нозологическим категориям и демонстрирует экспертный уровень распознавания, в том числе будучи перенесённой на одноканальную ЭКГ для носимых устройств [12]. Открытая трансформерная модель **ECG-FM**, предобученная по принципу самообучения (self-supervised learning) на 1,5 млн 12-канальных ЭКГ, показала, что такой подход обеспечивает высокую точность при существенно меньшем объёме размеченных данных на этапе дообучения [13]. Именно фундаментальные и трансформерные модели, по-видимому, станут технологической основой ЭКГ-диагностики ближайших лет.

Анализ медицинских изображений (ЭхоКГ, КТ, МРТ)

Конволюционные нейросети (КНС) хорошо приспособлены к анализу сложных визуальных данных. В работе О. Namila и соавт. 2D- и 3D-КНС выявляли инфаркт миокарда по данным рутинной эхокардиографии — метода, крайне зависимого от исполнителя; лучшие модели достигли точности 90,9 %, F1-метрики 97,2 % и воспроизводимости 95 %, что превзошло предшествующие попытки на основе более простых маркеров

[14–16]. Анализ КТ традиционно трудоёмок: медианное время описания одной зоны достигает 14 мин против ~1,5 мин для обзорной рентгенограммы [17], а в условиях перегрузки до половины ошибок интерпретации связаны с эффектом «удовлетворённости поиском» (satisfaction of search) [18–23]. Автоматизация способна не только разгрузить врача, но и снизить вред от исследований: для выявления аневризм брюшной аорты на нативных (без контрастирования) КТ предложены сети ResNet, VGG-16 и AlexNet, причём ResNet показала точность 0,872 и AUC 0,931, что делает её пригодной для скрининга без введения контраста и сопряжённых с ним рисков [24,25]. Развивая эту идею, А. Chandrashekar и соавт. с помощью **генеративно-сопоставительной сети (GAN, generative adversarial network)** [26] получали из нативных изображений симулированное контрастное: алгоритм Cycle-GAN обеспечил точность сегментирования полости аневризмы 86,1 % и тромба 93,5 % [27].

В области коронарного атеросклероза исследование CLARIFY продемонстрировало высокую точность выявления стенозов (99,7 % для > 70 % и 94,8 % для > 50 %) при относительно невысокой чувствительности, характерной для КТ-коронарографии [28,29,30]. Особый интерес представляет субанализ исследования CREDENCE (W.F. Griffin и соавт.), где автоматическую КТ-коронарографию с нейросетевой обработкой (**AI-QCT**) сопоставили с количественной инвазивной коронарографией (QCA) и инвазивным измерением фракционного резерва кровотока (FFR) у 303 пациентов. Сравнительная информативность методов приведена в таблице 1. Примечательно, что среди артерий, расценённых AI-QCT как стеноз > 70 %, но «недооценённых» QCA, две трети (66,1 %) имели патологический FFR ($< 0,8$), — то есть нейросетевая обработка КТ местами оказывалась ближе к «золотому стандарту», чем инвазивная ангиография [31].

Таблица 1. Диагностическая значимость QCA и AI-QCT в выявлении стеноза ≥ 70 % с FFR $< 0,8$ (по Griffin W.F. и соавт., 2023).

Критерий	QCA	AI-QCT	p
Чувствительность	45,6 %	58,9 %	< 0,0001
Специфичность	99,4 %	96,1 %	< 0,0001
Положительная прогн. ценность	96,3 %	84,7 %	0,0010
Отрицательная прогн. ценность	83,4 %	86,5 %	0,0005
Точность	85,0 %	86,2 %	0,2173
AUC	0,953	0,916	0,001

Нейросети ускоряют и магнитно-резонансную диагностику. Так, вариант вариационной сети, получивший название joint Multi-Scale Variational Neural Network (jMS-VNN), реконструировал мультиконтрастные МРТ-изображения высокого разрешения из пятикратно прореженных данных без потери качества по сравнению с полной выборкой, существенно превосходя метод Compressed Sensing [32,33].

Мультимодальный анализ

Подлинная ценность ИИ раскрывается при интеграции разнородных источников — изображений, сигналов, лабораторных и клинических данных. Ещё в 2018 году искусственная нейросеть и скрытая марковская модель распознавали клапанные пороки по фонокардиограмме с общей точностью 97,9 % и 98,7 % соответственно, причём на относительно небольшой выборке (230 записей) [34]. Объединение фонокардиографии с ЭКГ (Pengrai и соавт., 2021) повышало информативность модели (совокупная AUC 0,936), хотя основной вклад вносила именно ЭКГ (AUC 0,916 против 0,748 для фонокардиографии). Сложность мультимодальных систем в том, что они оперируют данными принципиально разной природы — числовыми, акустическими, статическими и динамическими изображениями [6,35,36,37], — отчего этап предобработки становится определяющим. Логичным развитием направления стали **мультимодальные фундаментальные модели**: так, совместная модель ЭКГ и эхокардиографии превзошла одномодальные аналоги в выявлении

систолической дисфункции левого желудочка (AUROC 0,94 против 0,89 для каждой модальности по отдельности) [38].

Прогнозирование исходов и течения заболеваний

Прогнозирование исходов хирургических вмешательств

Прогнозирование исходов — одно из ключевых применений ИИ в кардиохирургии. Актуальность задачи иллюстрирует то, что протезирование аортального клапана (как открытое, так и эндоваскулярное) не устраняет повышенного относительного риска смерти от сердечно-сосудистых причин (SMR 1,79; 95 % ДИ 1,75–1,83), причём максимальный разрыв наблюдается у молодых пациентов (SMR до 51,9 в группе 35–39 лет) [39]. В рандомизированном британском исследовании годовичная летальность составила 4,6 % для TAVI против 6,6 % для открытого протезирования [40], однако у значительной доли больных вмешательство не приносит пользы (по данным S.V. Arnold и соавт., у 50,8 % — смерть, отсутствие улучшения или ухудшение качества жизни в течение года) [41]. Это делает особенно ценным отбор пациентов. P. Mohammadyari и соавт. сравнили методы глубокого обучения для анализа выживаемости (DeepSurv, Random Survival Forest, RSF) с классической регрессией Кокса: однофакторный анализ Кокса выявил значимым лишь один предиктор (CHIP — клональный гемопоэз неопределённого потенциала), тогда как RSF достигла C-индекса 0,835, и, что важнее, однократно обученная сеть способна обрабатывать любые массивы данных точнее классического подхода [42]. Прогресс заметен и в предсказании послеоперационного делирия (до 30 % больных после открытых операций): если первые модели давали F1 ~40 %, то модели Extra-Trees и XGBoost достигли AUC 0,75–0,76 при приемлемой чувствительности и специфичности, что уже допускает клиническое применение [43,44].

Прогнозирование осложнений и динамики после вмешательства

ИИ применяют и для автоматизированного контроля результатов вмешательств. Так, основанная на машинном обучении программа

PRAEVAorta оценивает послеоперационную инволюцию аневризматического мешка после EVAR с коэффициентом корреляции $> 0,99$ ($p < 0,0001$) относительно экспертной оценки, причём для обучения хватило менее 50 дооперационных исследований [45].

Прогнозирование риска сердечно-сосудистых заболеваний

Нейросети позволяют оценивать риск событий иногда лишь по одной ЭКГ: в работе С. Cruz и соавт. сеть Long Short-Term Memory предсказывала инфаркт по трёхканальной ЭКГ с точностью 78 % [46]. На несопоставимо большем материале С.-Н. Lin и соавт. (2,82 млн ЭКГ от 1,08 млн пациентов) обучили сеть ResNet-18 (модель ECG-MACE) прогнозировать четыре исхода; годичный AUROC составил 0,90 для сердечной недостаточности, 0,85 для инфаркта миокарда, 0,89 для общей смертности и 0,76 для ишемического инсульта, причём прогноз сохранял силу на горизонте 3, 5 и 10 лет [47]. В масштабной работе I. Boudali и соавт. (441 455 пациентов, 21 параметр) сравнили градиентный бустинг (XGBoost), случайный лес, логистическую регрессию и метод опорных векторов; лучшим оказался XGBoost на нормализованных данных (точность 0,78, AUC 0,85, F1 0,77) [48].

Системы поддержки принятия решений

Обладая достаточной вычислительной мощностью и одновременным доступом ко всей доступной литературе, программы глубокого обучения способны быстрее и зачастую точнее человека оценивать риск — тем более что используемые врачами шкалы обновляются раз в годы и десятилетия. Слабость ИИ зеркальна: он опирается лишь на доступные ему данные, которые не всегда адекватны конкретной ситуации, тогда как врач учитывает и плохо поддающиеся оцифровке обстоятельства (хотя и подвержен усталости и эмоциям). Большинство клинических ситуаций, однако, поддаются систематизации. Так, ансамблевые методы машинного обучения, обученные на данных шкал EuroSCORE I и II, достигли AUC

0,833 — заметно выше, чем при «ручном» применении этих шкал [49,50,51]. Конкретный пример помощи в планировании — подбор протеза при TAVI: алгоритм глубокого обучения TAVI-PREP в полностью автоматическом режиме анализирует КТ корня аорты за две минуты, обеспечивая по большинству параметров корреляцию 0,90–0,95 с экспертом и точнее альтернативных методов; наибольшую трудность ожидаемо составляло измерение высоты устьев коронарных артерий [52,53]. Программное обеспечение может не только анализировать изображения, но и оповещать врача: система Viz.ai выявляет расслоение аорты и присылает тревожный сигнал на смартфон с чувствительностью 94,2 % и специфичностью 97,3 % [54].

Большие языковые модели и генеративный ИИ

Появление **больших языковых моделей (large language models, LLM)** открыло принципиально новую модальность поддержки решений — диалоговую, оперирующую неструктурированным текстом. В систематическом обзоре Н. Dore и соавт. ChatGPT-4 при сопоставлении с рекомендациями кардиокоманды у 150 пациентов с клапанными пороками показал согласие в 77 % случаев (90 % — по показаниям к TAVI, 65 % — к открытому протезированию и медикаментозной тактике), превзойдя основанное на рекомендациях «дерево решений». При этом другие работы отмечали и резкие расхождения (например, конфликт с решением кардиолога в 95 % случаев артериальной гипертензии), а также характерные слабости LLM — «галлюцинации», избыточную уверенность, ошибки в расчётах и неспособность интерпретировать изображения [55]. В рандомизированном исследовании экспериментальная диалоговая система AMIE улучшала качество ведения сложных пациентов с подозрением на генетическую кардиомиопатию, что указывает на потенциал LLM скорее в планировании лечения, чем в первичной диагностике [56]. Подчеркнём: на сегодняшний день ни одна генеративная модель или LLM не одобрена для

самостоятельного клинического применения, и их следует рассматривать как ассистента, а не как лицо, принимающее решение.

Интраоперационное применение и автономная хирургия

Роботические платформы по своей природе непрерывно регистрируют кинематические и силовые данные, формируя богатую основу для анализа: ИИ применяется для оценки хирургического мастерства, обнаружения ошибок в реальном времени и оптимизации этапов операции, а компьютерное зрение помогает идентифицировать анатомические структуры [4]. Интраоперационно прогностические модели (например, индекс прогнозирования гипотензии) уже используются для упреждающей коррекции гемодинамики. Знаковым событием стала первая демонстрация (2025) практически автономного роботического этапа операции — отделения структуры от окружающих тканей с минимальным участием человека на экспериментальной модели, — обозначившая переход к концепции уровней хирургической автономии. Применительно к кардиохирургии эти технологии пока находятся на самой ранней стадии, а убедительная клиническая доказательная база отсутствует [4], — поэтому реалистичным горизонтом остаётся «дополненная», а не автономная хирургия.

Обсуждение

Ограничения, этические и регуляторные аспекты

Несмотря на впечатляющие метрики, путь ИИ в клинику сопряжён с системными трудностями. Среди них — сохранность персональных данных и доверие пациента; «машинная предвзятость» (**machine bias**), причём не только расовая дискриминация [5]: врач нередко принимает решение с учётом приверженности к лечению, семейного и социального контекста, которые трудно корректно представить для обучения, отчего модель может систематически ошибаться. Подобные искажения способны быть и преднамеренно заложены недобросовестным производителем, что при

большом числе скрытых слоёв чрезвычайно трудно выявить (проблема «чёрного ящика» и объяснимости). Отдельно отмечают риск **избыточного доверия и деградации профессионализма** врачей [6]. М. Moshawrab и соавт. систематизировали эти барьеры (таблица 2) [7].

Таблица 2. Классификация проблем внедрения машинного обучения в практическое здравоохранение (по Moshawrab М. и соавт., 2023).

Группа проблем	Содержание
Проблемы данных	Наличие, доступность и физическое расположение данных; готовность к обработке; гетерогенность, шумы и артефакты; неполнота; дисбаланс классов; объём данных и накопление ошибок множественных сравнений; выбор и представление признаков
Проблемы модели	Точность и результативность; способ оценки модели; вариативность и ошибка; объяснимость (интерпретируемость)
Проблемы внедрения	Обработка в режиме реального времени; выбор модели для развёртывания; вычислительная сложность и время отклика
Организационные	Конфиденциальность данных; обучение и мотивация персонала; этические аспекты

Существенно изменился и **регуляторный ландшафт**. В Европейском союзе принят Регламент об ИИ (Regulation (EU) 2024/1689, «AI Act») — первая комплексная правовая рамка, относящая медицинский ИИ к категории «высокого риска» с требованиями прозрачности, прослеживаемости решений и обязательного человеческого надзора; основные обязанности для высокорисковых медицинских систем вступают в силу к августу 2027 года [59]. В США к декабрю 2024 года FDA авторизовало более 1000 устройств с ИИ/машинным обучением, однако подавляющее их большинство относится к лучевой диагностике, а на сердечно-сосудистую медицину приходится лишь около 10 %; при этом ни одно генеративное или языковое решение пока не одобрено для клинического применения, а доля устройств, подтверждённых рандомизированными исследованиями, остаётся крайне низкой [57,58]. Это

подчёркивает разрыв между исследовательскими метриками и зрелостью клинического внедрения.

Валидация и стандарты отчётности

Критическая оценка любой модели требует разграничения **внутренней и внешней валидации**: высокие метрики, полученные на данных одного центра, нередко резко снижаются при переносе на иную популяцию и иное оборудование, поэтому решающим аргументом служит проспективная валидация на независимых когортах. Для повышения прозрачности и воспроизводимости предложен ряд специализированных чек-листов отчётности: **TRIPOD-AI** (разработка и валидация прогностических моделей), **DECIDE-AI** (ранняя клиническая оценка систем поддержки решений), а также **CONSORT-AI** и **SPIRIT-AI** (рандомизированные испытания вмешательств с участием ИИ). Их соблюдение постепенно становится фактическим требованием рецензируемых журналов и условием доверия к публикуемым результатам; в практическом отношении читателю обзоров целесообразно оценивать каждую модель не только по величине AUC, но и по типу валидации, размеру и репрезентативности выборки, наличию проспективного подтверждения и регуляторного статуса.

В Российской Федерации программное обеспечение с применением ИИ регистрируется Росздравнадзором как самостоятельное медицинское изделие (SaMD) с отнесением к одному из классов риска (1, 2а, 2б, 3) в зависимости от значимости результата и условий применения. К лету 2026 года, по данным Webiomed в стране было зарегистрировано порядка 59 таких изделий, из которых около 54 созданы отечественными разработчиками; преобладают решения для лучевой диагностики [60]. Приказом Росздравнадзора № 4472 от 21.07.2025 введён порядок обязательной автоматической передачи в надзорную систему сведений о работе медицинских изделий с ИИ, включая сбои, ошибки и проблемы с

качеством данных, — что отражает общемировой тренд на ужесточение пострыночного (постмаркетингового) контроля за алгоритмами.

Сводная характеристика основных направлений

Для удобства читателя в таблице 3 обобщены рассмотренные направления применения ИИ с указанием типичных методов, репрезентативных работ, ключевых показателей и достигнутой степени зрелости — от экспериментальных моделей до решений, зарегистрированных регуляторами.

Таблица 3. Сводная характеристика основных направлений применения ИИ в сердечно-сосудистой хирургии и смежных специальностях.

Направление	Методы / модели	Репрезентативные работы	Ключевые показатели	Зрелость
ЭКГ-диагностика	DNN, ResNet; фундаментальные модели (ECGFounder, ECG-FM)	Hannun 2019; Raghunath 2020; Li 2025 [9,11,12]	AUC 0,85–0,88; экспертный уровень	Ретроспективная валидация; отд. алгоритмы зарегистрированы
Визуализация (ЭхоКГ, КТ, МРТ)	CNN, GAN, AI-QCT, jMS-VNN	Hamila 2022; Golla 2021; Griffin 2023 [15,25,31]	Точность 84–91 %; AUC до 0,93	Проспект. валидация; AI-QCT, Viz.ai — одобрены FDA
Мультимодальный анализ	KNC + LSTM; мультимодальные foundation models	Fahad 2018; Nargesi 2025 [34,38]	AUROC до 0,94	Эксперимент / ранняя валидация
Прогноз исходов и осложнений	RSF, DeepSurv, XGBoost, Extra-Trees	Mohammadyari 2024; Nagata 2023 [42,44]	C-индекс до 0,84; AUC ~0,76	Ретроспективная валидация
Прогноз риска ССЗ	LSTM, ResNet-18 (ECG-MACE), XGBoost	Lin 2025; Boudali 2024 [47,48]	AUROC 0,76–0,90	Ретроспективная валидация
Поддержка решений и LLM	Ансамбли ML; ChatGPT-4, AMIE	Dong 2023; Santaló-Corcoy 2023; Dores 2025 [51,52,55]	AUC 0,83; согласие с кардиокомандой 77 %	СППР внедряются; LLM — эксперимент (не одобрены)
Интраоперационно / автономная хирургия	Компьютерное зрение, кинематический анализ	Leivaditis 2025 [4]	—	Доклинический эксперимент

Международные бенчмарки для оценки больших языковых моделей в медицине

Оценка больших языковых моделей (LLM) в клиническом и биомедицинском контексте опирается на ряд стандартизированных международных бенчмарков. Одним из наиболее цитируемых является MedQA, основанный на вопросах экзамена USMLE и позволяющий оценивать медицинские рассуждения на уровне лицензирования врачей [61] (Jin et al., 2021). Дополняют его MedMCQA, охватывающий вопросы индийских медицинских экзаменов AIIMS/NEET [62] (Pal et al., 2022), и PubMedQA, ориентированный на ответы на исследовательские вопросы по аннотациям PubMed [63] (Jin et al., 2019).

Отдельного внимания заслуживает агрегированный бенчмарк MultiMedQA, предложенный в работе Singhal et al. (2023) при валидации моделей Med-PaLM [64]. Он объединяет несколько наборов данных (MedQA, MedMCQA, PubMedQA, MMLU-clinical, а также датасет пользовательских медицинских запросов HealthSearchQA) и вводит оценку не только точности, но и фактологичности, безопасности и потенциального вреда ответов с участием врачей-экспертов. Это стало важным сдвигом от чисто «тестовой» точности к клинически релевантным критериям.

Подмножество медицинских и биологических задач также присутствует в универсальном бенчмарке MMLU (Massive Multitask Language Understanding), включающем разделы clinical knowledge, medical genetics, anatomy, professional medicine и college biology [65] (Hendrycks et al., 2021). Для оценки способности моделей рассуждать над реальными клиническими случаями применяются наборы на основе клинических виньеток и записей MIMIC [66] (Johnson et al., 2016).

Несмотря на широкое распространение перечисленных ресурсов, в литературе подчёркиваются их ограничения: преобладание формата множественного выбора, риск «утечки» тестовых данных в обучающие корпуса (data contamination), англоязычная и северо-американская доминанта, а также слабое отражение реальной клинической коммуникации

и мультимодальности [64,67] (Singhal et al., 2023; Umapathi et al., 2023). Это стимулирует разработку новых бенчмарков, ориентированных на безопасность (например, Med-HALT для оценки галлюцинаций; Umapathi et al., 2023) и на генеративные, а не селективные ответы.

Заключение

Искусственный интеллект всё ощутимее влияет на диагностику, прогнозирование и планирование лечения сердечно-сосудистых заболеваний, позволяя точнее ставить диагноз, оценивать риск и индивидуализировать тактику. Ключевая технологическая тенденция последних лет — переход от узкоспециализированных нейросетей к фундаментальным и трансформерным моделям, обученным на десятках миллионов записей, а также появление больших языковых моделей в контуре поддержки решений. Вместе с тем сохраняются принципиальные ограничения — непрозрачность алгоритмов, «машинная предвзятость», вопросы безопасности данных и ответственности, — а формирующаяся регуляторная рамка (AI Act, подходы FDA) задаёт всё более строгие требования к доказательности и надзору. На обозримую перспективу наиболее реалистичной и безопасной представляется модель **«дополненного интеллекта»**, в которой ИИ выступает помощником врача, а окончательное решение и ответственность остаются за человеком.

Конфликт интересов

Авторы заявляют об отсутствии явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Источники финансирования

Исследование и подготовка статьи проводились без спонсорской поддержки.

Вклад авторов

Все авторы соответствуют четырём критериям авторства ICMJE: внесли существенный вклад в концепцию работы и анализ литературы,

участвовали в написании и критическом пересмотре рукописи, одобрили её окончательный вариант и несут ответственность за все аспекты работы.

Список литературы

1. Huang L, Lu J, Xiao Y, et al. Deep learning techniques for imaging diagnosis and treatment of aortic aneurysm. *Front Cardiovasc Med* 2024;11:1–11.
2. Sardar P, Abbott JD, Kundu A, et al. Impact of Artificial Intelligence on Interventional Cardiology: From Decision-Making Aid to Advanced Interventional Procedure Assistance. *JACC Cardiovasc Interv* 2019;12:1293–1303.
3. Sulague RM, Beloy FJ, Medina JR, et al. Artificial Intelligence in Cardiac Surgery: A Systematic Review. *World J Surg.* 2024 Sep;48(9):2073-2089. doi: 10.1002/wjs.12265.
4. Leivaditis V, Beltsios E, Papatriantafyllou A, et al. Artificial Intelligence in Cardiac Surgery: Transforming Outcomes and Shaping the Future. *Clin Pract* 2025;15(1):17.
5. Angwin J, Larson J, Mattu S, et al. Machine Bias. ProPublica 2016. www.propublica.org/article/machine-bias-risk-assessments-in-criminal-sentencing
6. Char DS, Shah NH, Magnus D. Implementing Machine Learning in Health Care — Addressing Ethical Challenges. *N Engl J Med* 2018;378:981–983.
7. Moshawrab M, Adda M, Bouzouane A, et al. Reviewing Federated Machine Learning and Its Use in Diseases Prediction. *Sensors (Basel).* 2023 Feb 13;23(4):2112. doi: 10.3390/s23042112.
8. Tompa R. Generative AI develops potential new drugs for antibiotic-resistant bacteria. *Stanford Medicine — News Center* 2024. <https://med.stanford.edu/>
9. Merchant A, Batzner S, Schoenholz SS, et al. Scaling deep learning for materials discovery. *Nature.* 2023 Dec;624(7990):80-85. doi: 10.1038/s41586-023-06735-9.
10. Hannun AY, Rajpurkar P, Haghpanahi M, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nat Med.* 2019 Jan;25(1):65-69. doi: 10.1038/s41591-018-0268-3. Epub 2019 Jan 7. Erratum in: *Nat Med.* 2019 Mar;25(3):530. doi: 10.1038/s41591-019-0359-9.

11. Raghunath S, Ulloa Cerna AE, Jing L, et al. Prediction of mortality from 12-lead electrocardiogram voltage data using a deep neural network. *Nat Med*. 2020 Jun;26(6):886-891. doi: 10.1038/s41591-020-0870-z.
12. Ouyang D, Theurer J, Stein NR, et al. Electrocardiographic deep learning for predicting post-procedural mortality: a model development and validation study. *Lancet Digit Health*. 2024 Jan;6(1):e70-e78. doi: 10.1016/S2589-7500(23)00220-0.
13. Li J, Aguirre AD, Moura V, et al. An Electrocardiogram Foundation Model Built on over 10 Million Recordings. *NEJM AI* 2025;2(7). doi:10.1056/AIoa2401033.
14. McKeen K, Masood S, Toma A, Rubin B, Wang B. ECG-FM: an open electrocardiogram foundation model. *JAMIA Open* 2025;8(5):ooaf122.
15. Hamila O, Ramanna S, Henry CJ, et al. Fully Automated 2D and 3D Convolutional Neural Networks Pipeline for Video Segmentation and Myocardial Infarction Detection in Echocardiography. *Multimed Tools Appl* 2022;81:37417–37439.
16. Wu C-C, Hsu W-D, Islam MM, et al. An artificial intelligence approach to early predict non-ST-elevation myocardial infarction patients with chest pain. *Comput Methods Programs Biomed*. 2019 May;173:109-117. doi: 10.1016/j.cmpb.2019.01.013.
17. Kiranyaz S, Degerli A, Ince T, et al. Left Ventricular Wall Motion Estimation by Active Polynomials for Acute Myocardial Infarction Detection. *IEEE Access* 2020;8:210301–210317.
18. Cowan IA, Macdonald SLS, Floyd RA. Measuring and managing radiologist workload: measuring radiologist reporting times using data from a Radiology Information System. *J Med Imaging Radiat Oncol*. 2013 Oct;57(5):558-66. doi: 10.1111/1754-9485.
19. Kasalak Ö, Alnahwi H, Toxopeus R, et al. Work overload and diagnostic errors in radiology. *Eur J Radiol*. 2023 Oct;167:111032. doi: 10.1016/j.ejrad.2023.111032. Epub 2023 Aug 10.
20. Onder O, Yarasir Y, Azizova A, et al. Errors, discrepancies and underlying bias in radiology with case examples: a pictorial review. *Insights Imaging*. 2021 Apr 20;12(1):51. doi: 10.1186/s13244-021-00986-8.
21. Нечаев ВА, Васильев АЮ. Факторы риска появления ошибок восприятия у врачей-рентгенологов при анализе лучевых

исследований. Вестник СурГУ. Медицина. 2024;17(4):14-22.
<https://doi.org/10.35266/2949-3447-2024-4-2>

22. Waite S, Scott J, Gale B, et al. Interpretive error in radiology. *AJR Am J Roentgenol.* 2017 Apr;208(4):739-749. doi: 10.2214/AJR.16.16963.
23. Lee CS, Nagy PG, Weaver SJ, et al. Cognitive and System Factors Contributing to Diagnostic Errors in Radiology. *AJR Am J Roentgenol.* 2013 Sep;201(3):611-7. doi: 10.2214/AJR.12.10375.
24. Andreucci M, Solomon R, Tasanarong A. Side Effects of Radiographic Contrast Media: Pathogenesis, Risk Factors, and Prevention. *Biomed Res Int.* 2014;2014:741018. doi: 10.1155/2014/741018.
25. Golla A, Tönnies C, Russ T, et al. Automated Screening for Abdominal Aortic Aneurysm in CT Scans under Clinical Conditions Using Deep Learning. *Diagnostics (Basel).* 2021 Nov 17;11(11):2131. doi: 10.3390/diagnostics11112131.
26. Goodfellow IJ, Pouget-Abadie J, Mirza M, et al. Generative Adversarial Nets. *Adv Neural Inf Process Syst* 2014;27:2672–2680.
27. Chandrashekar A, Handa A, Lapolla P, et al. A Deep Learning Approach to Visualize Aortic Aneurysm Morphology Without the Use of Intravenous Contrast Agents. *Ann Surg.* 2023 Feb 1;277(2):e449-e459. doi: 10.1097/SLA.0000000000004835.
28. Choi AD, Marques H, Kumar V, et al. CT Evaluation by Artificial Intelligence for Atherosclerosis, Stenosis and Vascular Morphology (CLARIFY): a multi-center, international study. *J Cardiovasc Comput Tomogr.* 2021 Nov-Dec;15(6):470-476. doi: 10.1016/j.jcct.2021.05.004.
29. Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. *SSRN Electronic Journal* 12(08):301-307. doi: 10.48550/arXiv.1409.1556
30. Çiçek Ö, Abdulkadir A, Lienkamp SS, et al. 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. *Lecture Notes in Computer Science.* Springer; 2016;9901:424–432. doi: 10.48550/arXiv.1606.06650
31. Griffin WF, Choi AD, Riess JS, et al. AI Evaluation of Stenosis on Coronary CTA, Comparison With Quantitative Coronary Angiography and Fractional Flow Reserve: A CREDENCE Trial Substudy. *JACC Cardiovasc Imaging* 2023;16(2):193–205. doi:10.1016/j.jcmg.2021.10.020.

32. Hammernik K, Klatzer T, Kobler E, et al. Learning a variational network for reconstruction of accelerated MRI data. *Magn Reson Med*. 2018 Jun;79(6):3055-3071. doi: 10.1002/mrm.26977.
33. Fotaki A, Fuin N, Nordio G, et al. Accelerating 3D MTC-BOOST in patients with congenital heart disease using a joint multi-scale variational neural network reconstruction. *Magn Reson Imaging*. 2022 Oct;92:120-132. doi: 10.1016/j.mri.2022.06.012.
34. Fahad HM, Ghani Khan MU, Saba T, et al. Microscopic abnormality classification of cardiac murmurs using ANFIS and HMM. *Microsc Res Tech*. 2018 May;81(5):449-457. doi: 10.1002/jemt.22998.
35. Moshawrab M, Adda M, Bouzouane A, et al. Smart Wearables for the Detection of Cardiovascular Diseases: A Systematic Literature Review. *Sensors (Basel)*. 2023 Jan 11;23(2):828. doi: 10.3390/s23020828.
36. Osman AFI, Tamam NM. Deep learning-based convolutional neural network for intramodality brain MRI synthesis. *J Appl Clin Med Phys*. 2022 Apr;23(4):e13530. doi: 10.1002/acm2.13530.
37. Demirci F, Akan P, Kume T, et al. Artificial neural network approach in laboratory test reporting: learning algorithms. *Am J Clin Pathol*. 2016 Aug;146(2):227-37. doi: 10.1093/ajcp/aqw104.
38. Nargesi AA, Friedman S, Shnitzer Dery T, et al. Multimodal foundation model for evaluating cardiovascular disease from electrocardiography and echocardiography. *Eur Heart J* 2025;46(Suppl_1):ehaf784.4471.
39. Glaser N, Persson M, Franco-Cereceda A, et al. Cause of death after surgical aortic valve replacement: SWEDEHEART observational study. *J Am Heart Assoc*. 2021 Nov 16;10(22):e022627. doi: 10.1161/JAHA.121.022627.
40. UK TAVI Trial Investigators; Fairbairn T, Kemp I, et al. Effect of Transcatheter Aortic Valve Implantation vs Surgical Aortic Valve Replacement on All-Cause Mortality in Patients With Aortic Stenosis: A Randomized Clinical Trial. *JAMA*. 2022 May 17;327(19):1875-1887. doi: 10.1001/jama.2022.5776.
41. Arnold SV, Afilalo J, Spertus JA, et al. Prediction of Poor Outcome After Transcatheter Aortic Valve Replacement. *J Am Coll Cardiol*. 2016 Oct 25;68(17):1868-1877. doi: 10.1016/j.jacc.2016.07.762.
42. Mohammadyari P, Viecei Dalla Sega F, Fortini F, et al. Deep-learning survival analysis for patients with calcific aortic valve disease undergoing

- valve replacement. *Sci Rep* 14, 10902 (2024). doi: 10.1038/s41598-024-61685-0.
43. Mufti HN, Hirsch GM, Abidi SR, et al. Exploiting machine learning algorithms and methods for the prediction of agitated delirium after cardiac surgery: models development and validation study. *JMIR Med Inform.* 2019 Oct 23;7(4):e14993. doi: 10.2196/14993.
44. Nagata C, Hata M, Miyazaki Y, et al. Development of postoperative delirium prediction models in patients undergoing cardiovascular surgery using machine learning algorithms. *Sci Rep.* 2023 Nov 30;13(1):21090. doi: 10.1038/s41598-023-48418-5. Erratum in: *Sci Rep.* 2024 Feb 22;14(1):4396. doi: 10.1038/s41598-024-51975-y.
45. Caradu C, Pouncey A, Brunet C, et al. Fully automatic volume segmentation using deep learning approaches to assess aneurysmal sac evolution after infrarenal endovascular aortic repair. *J Vasc Surg.* 2022 Sep;76(3):620-630.e3. doi: 10.1016/j.jvs.2022.03.891.
46. Cruz C, Leite A, Pires EJS, et al. Myocardial Infarction Prediction Using Deep Learning. *LNICST.* Springer; 2023;484:133–143. doi:10.1007/978-3-031-32029-3_13.
47. Lin CH, Liu ZY, Chu PH, et al. A multitask deep learning model utilizing electrocardiograms for major cardiovascular adverse events prediction. *npj Digit. Med.* 8, 1 (2025). <https://doi.org/10.1038/s41746-024-01410-3>.
48. Boudali I, Chebaane S, Zitouni Y. A predictive approach for myocardial infarction risk assessment using machine learning and big clinical data. *Healthcare Analytics* 2024;5:100319. doi: 10.1016/j.health.2024.100319
49. Nashef SAM, Roques F, Michel P, et al. European system for cardiac operative risk evaluation (EuroSCORE). *Eur J Cardiothorac Surg.* 1999 Jul;16(1):9-13. doi: 10.1016/s1010-7940(99)00134-7.
50. Nashef SAM, Roques F, Sharples LD, et al. EuroSCORE II. *Eur J Cardiothorac Surg.* 2012 Apr;41(4):734-44; discussion 744-5. doi: 10.1093/ejcts/ezs043.
51. Dong T, Sinha S, Zhai B, et al. Cardiac surgery risk prediction using ensemble machine learning to incorporate legacy risk scores: a benchmarking study. *Digit Health.* 2023 Jul 20;9:20552076231187605. doi: 10.1177/20552076231187605.
52. Santaló-Corcoy M, Corbin D, Tastet O, et al. TAVI-PREP: A Deep Learning-Based Tool for Automated Measurements Extraction in TAVI

- Planning. Diagnostics (Basel). 2023 Oct 11;13(20):3181. doi: 10.3390/diagnostics13203181.
53. Ma Q, Lemarchand L, Chan-Sock-Line D, et al. Fully-automatic aortic valve landmarks detection with two-stage-based convolutional neural networks. Доклад на Proc SPIE 12464, Medical Imaging 2023: Image Processing:124643K.
54. Stonko DP, Morrison JJ, Hicks CW. A review of mature machine learning- and artificial intelligence-enabled applications in aortic surgery. JVS-Vascular Insights 2023;1:100016.
55. Dores H, et al. Applications of large language models in cardiovascular disease: a systematic review. Eur Heart J Digit Health 2025;6(4):540. doi:10.1093/ehjdh/ztaf028.
56. Tu T, et al. A large language model for complex cardiology care. Nat Med 2026;32(2):616–623. doi:10.1038/s41591-025-04190-9.
57. Sardar P, Dudorova E, Chatterjee S, et al. Analysis of FDA-Approved Artificial Intelligence and Machine Learning-Enabled Cardiovascular Devices. JACC Adv 2025;4(10):102174. doi:10.1016/j.jacadv.2025.102174.
58. Singh R, Bapna M, Diab AR, et al. How AI is used in FDA-authorized medical devices: a taxonomy across 1,016 authorizations. npj Digit Med 2025;8:388. doi:10.1038/s41746-025-01800-1.
59. Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). Official Journal of the European Union; 2024.
60. Гусев А. Зарегистрированные медицинские изделия, использующие технологии искусственного интеллекта.
<https://webiomed.ru/blog/zaregistrirovannye-meditsinskie-izdeliia-ai/>
61. Jin D, Pan E, Oufattole N, Weng W-H, Fang H, Szolovits P. What Disease Does This Patient Have? A Large-Scale Open Domain Question Answering Dataset from Medical Exams. Applied Sciences. 2021; 11(14):6421. doi:10.3390/app11146421
62. Pal A, Umapathi LK, Sankarasubbu M. MedMCQA: A Large-scale Multi-Subject Multi-Choice Dataset for Medical domain Question Answering. Доклад на Proceedings of Machine Learning Research 174:248-260. doi:10.48550/arXiv.2203.14371
63. Jin Q, Dhingra B et al. PubMedQA: A Dataset for Biomedical Research Question Answering. Доклад на Proceedings of Empirical Methods in Natural Language Processing и the 9th International Joint Conference on

- Natural Language Processing (EMNLP-IJCNLP), pages 2567–2577, Hong Kong, China. Association for Computational Linguistics.
64. Singhal K, Azizi S, et al. Large language models encode clinical knowledge. *Nature*. 2023 Aug;620(7972):172-180. doi: 10.1038/s41586-023-06291-2. Epub 2023 Jul 12. Erratum in: *Nature*. 2023 Aug;620(7973):E19. doi: 10.1038/s41586-023-06455-0
65. Hendrycks D, Burns C et al. Measuring Massive Multitask Language Understanding (MMLU). Доклад на ICLR. 2020. doi:10.48550/arXiv.2009.03300-
66. Johnson AE, Pollard TJ, et al. MIMIC-III, a freely accessible critical care database. *Sci Data*. 2016 May 24;3:160035. doi: 10.1038/sdata.2016.35.
67. Pal A, Umapathi LK, Sankarasubbu M. Med-HALT: Medical Domain Hallucination Test for Large Language Models. Доклад на 2023 Conference on Empirical Methods in Natural Language Processing. doi:10.48550/arXiv.2307.15343