



СКРИНИНГ ПОРОКОВ СЕРДЦА ПРИ АНАЛИЗЕ ЭЛЕКТРОКАРДИОГРАММЫ С ПОМОЩЬЮ
МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ
(обзор литературы)

Н.О. КУЗНЕЦОВА, А.М. АЛЕКСЕЕВА, Ф.Э. МАМЕДЗАДЕ, В.П. СЕДОВ, Ф.Ю. КОПЫЛОВ,
А.Л. СЫРКИН, П.Ш. ЧОМАХИДЗЕ

*Федеральное государственное автономное образовательное учреждение высшего образования
Первый Московский государственный медицинский университет имени И.М. Сеченова Министерства
здравоохранения Российской Федерации (Сеченовский Университет),
ул. Большая Пироговская, д.2, стр.4, Москва, 119991, Россия*

Аннотация. В развитых странах распространенность клапанных заболеваний сердца составляет 2,5 %. При этом подчеркивается необходимость раннего выявления пороков сердца, что позволит снизить число пациентов с тяжелой стадией заболевания и своевременно провести консервативное и/или хирургическое лечение, особенно учитывая неспецифичность жалоб и клинические проявления большинства пороков сердца лишь на поздних стадиях болезни. С развитием искусственного интеллекта, в частности методов машинного обучения, появляются новые методики скрининговой диагностики заболеваний сердца. За последние 4 года несколько клинических исследований продемонстрировали возможности выявления пороков сердца (аортального стеноза, митральной и аортальной недостаточности) при анализе стандартной электрокардиограммы с применением искусственного интеллекта. В настоящем обзоре представлены последние мировые научные достижения по данной теме, обсуждаются перспективы и возможности использования и внедрения описанных технологий.

Ключевые слова: аортальный стеноз, митральная недостаточность, аортальная недостаточность, скрининг, электрокардиограмма, машинное обучение, искусственный интеллект

SCREENING OF HEART DEFECTS IN ELECTROCARDIOGRAM ANALYSIS USING MACHINE
LEARNING METHODS
(literature review)

N.O. KUZNETSOVA, A.M. ALEKSEEVA, F.E. MAMEDZADE, V.P. SEDOV, F.YU. KOPYLOV,
A.L. SYRKIN, P.SH. CHOMAKHIDZE

*Federal State Budgetary Educational Institution of Higher Education "Sechenov University (First Moscow State
Medical University named after I. M. Sechenov) of the Ministry of Health of the Russian Federation",
Bolshaya Pirogovskaya St., 2, Bld. 4, Moscow, 119991, Russia*

Abstract. In developed countries, the prevalence of valvular heart diseases is 2.5%. The importance of early detection of heart defects is emphasized, as it can reduce the number of patients with advanced stages of the disease and allow for timely conservative and/or surgical treatment, especially considering the nonspecific nature of symptoms and clinical manifestations of most heart defects, which often appear only at later stages of the disease. With the development of artificial intelligence, particularly machine learning techniques, new methods for screening heart disease diagnosis have emerged. Over the past 4 years, several clinical studies have demonstrated the potential of detecting heart defects (such as aortic stenosis, mitral and aortic insufficiency) through the analysis of standard electrocardiograms using artificial intelligence. This review presents the latest global scientific advancements on this topic and discusses the prospects and possibilities for the use and implementation of the described technologies.

Keywords: aortic stenosis, mitral insufficiency, aortic insufficiency, screening, electrocardiogram, machine learning, artificial intelligence.

Введение. В развитых странах распространенность клапанных заболеваний сердца составляет 2,5 % [13, 20, 28]. Позднее выявление данной патологии может привести к тяжелым осложнениям, включая сердечную недостаточность и аритмии [28]. Исследования показывают, что умеренная или тяжелая форма пороков сердца (ПС) обнаруживается у 11-13 % лиц старше 75 лет, при этом более половины из них не диагностированы [8, 19]. Среди пороков сердца наиболее распространенными являются аортальный стеноз (АС) и митральная регургитация (МР), за которыми следуют аортальная регургитация (АР), митральный стеноз (МС), пролапс митрального клапана и первичная трикуспидальная регургита-

ция [22]. Заболевания аортального клапана составляют 61 % всех случаев смерти от ПС, заболевания митрального клапана – 15 % [3].

Поскольку ПС могут достаточно быстро прогрессировать с течением времени и, зачастую, проявляются клинически лишь на поздних стадиях, когда риск операции значимо возрастает, важным является их раннее выявление, коррекция физических нагрузок, уровня артериального давления, легочной гипертензии, а также своевременное хирургическое лечение. Надо отметить, что аускультативная картина позволяет выявить ПС далеко не всегда [4, 15]. Специфичность жалоб тоже не высока [2]. В метаанализе, опубликованном в 2022 году было показано, что средняя чувствительность в выявлении различных ПС при аускультации пациентов составила 66.8 % при средней специфичности 79.4 %, что недостаточно для эффективного скрининга [6].

Золотым стандартом выявления пороков сердца остается трансторакальная и, в ряде случаев, чреспищеводная *эхокардиография* (ЭхоКГ) [9,26]. Однако ЭхоКГ не может выступать в роли скринингового инструмента для широкой популяции из-за цены исследования, невысокой пропускной способности, оператор-зависимости и субъективности, а также ограниченного числа ЭхоКГ-сканеров. Напротив, наиболее доступным, широко используемым и недорогим диагностическим инструментом в кардиологии является *электрокардиограмма* (ЭКГ) [7]. При анализе ЭКГ врачом, без применения специальных математических технологий, диагностическая точность ЭКГ низка и данный метод не упоминается как диагностически значимый в действующих клинических рекомендациях [7, 22, 28].

Обработка сигнала ЭКГ с помощью искусственного интеллекта, сложного математического моделирования позволяет выявить даже небольшие изменения морфологии ЭКГ комплексов и частотного спектра сигнала ЭКГ, недоступные врачу при визуальном анализе записи. На сегодняшний день, при обработке 12-канальной ЭКГ с помощью методов *искусственного интеллекта* (ИИ) и компьютерного зрения можно выявить нарушения ритма сердца, острый коронарный синдром, кардиомиопатии, систолическую и диастолическую дисфункцию миокарда, электролитные нарушения (гиперкалиемию), анемию, гипергликемию [7]. Кроме того, говоря о потенциальном применении ЭКГ для широкого скрининга, современные портативные устройства позволяют регистрировать одноканальные записи ЭКГ без участия медицинского персонала. По одноканальной записи ЭКГ с помощью ИИ уже возможно определение нарушений ритма сердца, а также систолической и диастолической дисфункций левого желудочка с высокой точностью [1, 16]. Применение глубокого машинного обучения и сверточных нейронных сетей, позволило обеспечить более точную и оптимизированную диагностику, в частности кардиальной патологии [10, 23].

Обзор исследований по выявлению пороков сердца при анализе ЭКГ методами искусственного интеллекта. В 2023 году опубликован метаанализ оценки эффективности моделей на основе ИИ в выявлении пороков сердца по 12-канальной ЭКГ. Проверялись базы данных (*PubMed, MEDLINE, Embase, Scopus и Cochrane*) до 2023 года. В анализ вошли 10 исследований, в которых использовались данные 12-канальных ЭКГ 713 537 пациентов. Распределение по статьям было следующее: выявление аортального стеноза ($n = 6$), митральной регургитации ($n = 4$), аортальной регургитации ($n = 3$), митрального стеноза ($n = 1$), пролапса митрального клапана ($n = 2$) и трикуспидальной регургитации ($n = 1$). Для анализа 12-канальной в покое ЭКГ в 9 исследованиях использовались модели сверточных нейронных сетей, в одном исследовании сочетались: метод опорных векторов, логистическая регрессия и многослойный перцептрон. Показатели диагностической точности 12-канальной ЭКГ с анализом ИИ в выявлении различных ПС представлены в табл. 1.

Таблица 1

Усредненные показатели диагностической точности анализа 12-канальной ЭКГ с применением ИИ в выявлении пороков сердца. Данные метаанализа [22]

Тип порока сердца	Диагностическая точность	Чувствительность	Специфичность	Положительная прогностическая точность	Отрицательная прогностическая точность
Все пороки	81 %	83 %	72 %	13 %	99 %
Аортальный стеноз	86 %	88 %	71 %	12 %	99 %
Митральная недостаточность 2-3 степени	86 %	88 %	69 %	23 %	97 %

Мы провели собственный анализ литературы по возможностям выявления различных пороков сердца при анализе 12-канальной и одноканальной ЭКГ в базах данных *MEDLINE*, *Cochrane Library* по *ScienceDirect*, *Scopus* and *Reaxys*. Проанализированы данные, опубликованные до 1 сентября 2024г. Условиями поиска являлись слова «искусственный интеллект», «глубокое обучение», «машинное обучение», «клапанные пороки сердца», «электрокардиограмма», «аортальный стеноз», «митральная недостаточность», «аортальная недостаточность», «митральный стеноз», «трикуспидальная недостаточность», а также их использование в различных комбинациях. Критериями отбора статей было:

- использование искусственного интеллекта/машинного обучения для выявления пороков сердца;
- использование данных одноканальной и/или 12-канальной ЭКГ для выявления пороков сердца;
- получение как минимум одного достоверного результата (чувствительность, специфичность, диагностическая точности или *AUC* при *ROC* анализе);
- число пациентов не менее 100;
- возраст пациентов 18 лет старше.

Оценка статей проводилась двумя независимыми экспертами по указанным критериям.

Далее представлены работы, отвечающие указанным критериям отбора, в которых авторы использовали сложное машинное обучение или искусственный интеллект.

Cohen-Shelly M. с коллегами выполнили работу по выявлению умеренного и тяжелого аортального стеноза при анализе электрокардиограммы с помощью ИИ (ИИ-ЭКГ). За 30-летний период из базы данных клиники Майо было отобрано 258 607 пациентов [средний возраст составил $63 \pm 16,3$ года; женщин – 122 790 (48 %)], которым было выполнено ЭхоКГ и ЭКГ. По данным ЭхоКГ умеренный и тяжелый АС был выявлен у 9723 (3,7 %) пациентов, изолировано тяжелый АС имели 2,6 %. Цифровая 12 канальная ЭКГ была снята в течение не более 180 дней до проведения ЭхоКГ. У 169 252 (65 %) и 232 724 (90 %) ЭКГ и ЭХОКГ были с разницей в 1 и 30 дней. Пациенты посредством случайной выборки были распределены на 3 группы: обучение модели – 129 788 (50 %), валидация модели 25 893 (10 %), тестовая группа – 102 926 (40 %). Была разработана модель сверточной нейронной сети, реализованной на *Python*.

В тестовой группе ИИ выявил 3833 (3,7 %) пациентов с АС с площадью под кривой (*AUC*) 0,85. Чувствительность, специфичность и точность составили 78 %, 74 % и 74 %, соответственно. У пациентов с АГ и без нее *AUC* рассчитывался отдельно и составил 0,81 и 0,88, соответственно. У пациентов без каких-либо сопутствующих заболеваний [$n = 31\ 484$ (31 %)] *AUC* - 0,89. Эффективность модели увеличивалась, когда к модели добавлялись возраст и пол (*AUC* 0,87), что в дальнейшем увеличивалось до 0,90 у пациентов без артериальной гипертензии (чувствительность 75 %, специфичность 88 %).

Интересным является результат о том, что пациенты с ложноположительными показателями по ЭКГ имели в два раза больший риск развития умеренного или тяжелого АС за 15 лет наблюдения по сравнению с истинно отрицательными (отношение рисков 2,18, 95 % доверительный интервал 1,90-2,50). Исследование продемонстрировало, что использование сверточных нейронных сетей при анализе ЭКГ может успешно идентифицировать пациентов со средне-тяжелым и тяжелым АС с высокими показателями (*AUC* 0,85) [5].

В последующие годы проводилась дальнейшая работа над созданной *Cohen-Shelly M.* с коллегами моделью. Так, в 2023 году опубликована работа, в которой изучалось выявление корреляций между определением АС и отдельными эхокардиографическими и электрокардиографическими параметрами. Исследование проводилось на пациентах, включенных изначально в группу тестирования: 102 926 пациента ($63,0 \pm 16,3$ года, 52 % мужчин), из них 28 464 (27,7 %) были идентифицированы как положительные по ИИ-ЭКГ (т.е. имели умеренный или тяжелый АС). Ишемическая болезнь сердца, пожилой возраст, гипертония, мерцательная аритмия, диабет и сердечная недостаточность были более распространены в группе с положительным ИИ-ЭКГ, чем в группе с отрицательным результатом ($P < 0,001$). Была выявлена положительная корреляция между моделью и длительностью *QRS* ($\rho = 0,25$, $R^2 = 0,08$, $P < 0,001$), интервалом *PR* ($\rho = 0,25$, $R^2 = 0,03$, $P < 0,001$) и *QTc* ($\rho = 0,23$, $R^2 = 0,05$, $P < 0,001$). Однако эти корреляции оказались довольно слабыми [12].

Еще одна статья опубликована при анализе все той же модели на основе ИИ для выявления умеренного и тяжелого АС, разработанной *Cohen-Shelly M.* с коллегами [5]. Проведено исследование, оценивающее влияние спектра заболевания на эффективность теста. Были разработаны две модели из двух отдельных когорт пациентов: когорта полного спектра, сравнивающая тяжелый АС с любым не тяжелым АС, и когорта экстремального спектра, сравнивающая тяжелый АС с отсутствием АС вообще. Была оценена эффективность модели. У 258 607 пациентов были действительные пары ЭКГ и эхокардиография (разница между исследованиями менее 180 дней). Площадь под кривой *AUC* составила 0,87 и 0,91 для моделей полного спектра и экстремального спектра, соответственно. Чувствительность и специфичность для модели полного спектра составили 80 % и 81 %, тогда как для модели экстремального спектра она составила 84 % и 84 %, соответственно. При применении ИИ-ЭКГ, полученной из когорты экстремаль-

ного спектра, к пациентам в когорте полного спектра чувствительность, специфичность и площадь под кривой снизились до 83 %, 73 % и 0,86 [24].

Группой исследователей (*Kwon* и соавторы) был проведен ряд многоцентровых ретроспективных исследования по выявлению ПС по 12-канальной ЭКГ и применением методов ИИ. Всего были изучены данные 56 689 ЭКГ от 43 051 участников для выявления АС. Внутренняя валидация алгоритма была выполнена на 16 % ЭКГ, внешняя валидация – на 28 % ЭКГ из различных медицинских центров. В качестве прогностических переменных использовались демографические данные (возраст, пол, вес и рост, индекс массы тела), характеристики 12-канальной ЭКГ (частота сердечных сокращений, наличие фибрилляции или трепетания предсердий, интервал QT , скорректированный интервал QT (QTc), продолжительность QRS , ось зубца R и ось зубца T) и необработанные данные 12-канальной ЭКГ с частотой 500 Гц. Был разработан алгоритмы на основе глубокого машинного обучения, сочетающий модель «Многослойный перцептрон» (МП) и Сверточную Нейронную Сеть (СНС). С помощью карты чувствительности было определено, какая часть ЭКГ оказала наиболее существенное влияние на принятие решений алгоритма. Дополнительный алгоритм на основе глубокого обучения был разработан с использованием данных одного отведения (2-го стандартного) из того же набора данных. В выявлении аортального стеноза AUC ансамблевого алгоритма, сочетающего МП и СНС, составила 0,884 (95 % ДИ, 0,880–0,887), чувствительность 80 %, специфичность 81,4 %, диагностическая точность 81,4 %. Это значительно больше, чем у СНС (0,825; 95 % ДИ, 0,821–0,829, чувствительность 80 %, специфичность 68,9 %), МП (0,800; 95 % ДИ, 0,792–0,808, чувствительность 80 %, специфичность 69,8 %). При внешней проверке на 10 865 пациентах AUC данного алгоритма составила 0,861 (95 % ДИ, 0,858–0,863) чувствительность 80 %, специфичность 78,3 % и диагностическая точность 78,3 %; AUC СНС (0,816; 95 % ДИ, 0,812–0,819) при чувствительности 80 %, специфичности 67,9 %; AUC МП (0,807; 95 % ДИ, 0,800–0,815) при чувствительности 80 %, специфичности 70,3 %. Отрицательное прогностическое значение достигло 99 %. Отдельный анализ по различным отведениям ЭКГ показал наибольшие значения AUC ансамблевого алгоритма во 2-м стандартном отведении – 0,845 (95 % ДИ, 0,841–0,848). Карта чувствительности показала, что для определения наличия значимого АС для алгоритма важным является зубец T в отведениях $VI-V4$ [18].

Для выявления умеренной и тяжелой митральной недостаточности *Kwon* и соавторы разработали алгоритмы как для 12-канальной ЭКГ, так и для каждого отведения ЭКГ по отдельности. Использовались данные 59 844 ЭКГ от 27 376 пациентов. Во время внутренней и внешней валидации AUC для выявления умеренной и тяжелой МР по 12-канальной ЭКГ составила 0,816 и 0,877. При внутренней валидации и внешней валидации чувствительность и специфичность составили 90 % и 53,3 %, 90,1 % и 66,9 %, соответственно. При анализе одноканальной ЭКГ (2го стандартного отведения): внутренняя валидация AUC 0,758, чувствительность 90 %, специфичность 40,8 %, внешняя валидации – AUC 0,850, чувствительность 90,1 %, специфичность 56 %. Карта чувствительности показала значимость параметров зубцов P и T у пациентов с МР и морфологические параметры комплекса QRS для пациентов без МР. Кроме этого, был проведен анализ вероятности развития МР в течение 27 месяцев после инициального обследования: среди 3157 лиц, не страдавших значимой МР, но которых ИИ определил как лиц, имеющих высокий риск, у 218 пациентов развилась МР 2-3 степени в течение периода наблюдения [17].

Ограничением исследований *Kwon* и соавторов является его проведение на корейской популяции и отсутствие внешней проверки. Исследования показали, что алгоритм, основанный на глубоком обучении, продемонстрировал высокую точность выявления значимого АС с использованием как 12-канальной, так и одноканальной ЭКГ [17, 18].

В работе *E. Nata* с соавторами изучалась классификация стеноза аортального клапана с использованием данных ЭКГ путем глубокого обучения. Были отобраны пациенты, которым ЭХОКГ была проведена в течение трех месяцев после регистрации ЭКГ. В обучающей группе было 128 ЭКГ, в валидационной группе – 44, в тестовой – 44. В этом исследовании изображения 12-канальной ЭКГ и отдельно 4 отведений (I , aVL , $V5$ и $V6$) анализировались с помощью сверточной нейронной сети с применением *Gradient-weighted Class Activation Mapping (Grad-CAM)* к обученной СНС. В выявлении аортального стеноза была показана диагностическая точность 12-канальной записи: *Accuracy* 12-канальной ЭКГ – 79,5 %, 4-х канальной – 77,3 %; *Precision* для 12-канальной ЭКГ – 84,2 % и 77,3 % для 4-канальной ЭКГ, Чувствительность 72,7 % и 77,3 %, *F1-score* 78 % и 77,3 %, соответственно [11].

В работе *Vaid A.* и др. также изучались возможности выявления аортального стеноза любой степени и митральной недостаточности значимой степени (умеренной и тяжелой) с применением ИИ для анализа ЭКГ, а также с использованием компьютерных алгоритмов обработки неструктурированных текстов, в том числе протоколов ЭхоКГ нестандартного и не цифрового типа. ЭКГ и ЭхоКГ регистрировались с разницей 0 ± 7 дней. В модель были включены демографические данные (возраст и пол пациента), а также извлеченные параметры: скорректированный интервал QT , интервал PR , частота волн P и частота комплексов QRS . Была разработана комбинированная нейронная сеть, состоящая из *многослойного перцептрона (MLP)*, соединенного с сверточной нейронной сетью *Efficientnet*. Для разработки модели для выявления аортального стеноза использовали 617 338 пар Эхо-ЭКГ от 128 628 пациентов. AUC составила

0,89 (95 % ДИ: 0,88-0,89) при внутреннем тестировании и 0,86 (95 % ДИ: 0,85-0,87) при внешней проверке. В выявлении значимой митральной недостаточности показатель AUC составил 0,88 (95 % ДИ: 0,88-0,89) при внутреннем тестировании и 0,81 (95 % ДИ: 0,80-0,82) при внешней проверке [27].

В другом исследовании, проведенном в США, были разработаны модели глубокого обучения *ValveNet*, позволяющие выявлять умеренный или тяжелый АС, АН 2-3 степени и значимую (2-3 степени) митральную недостаточность. Всего было отобрано 77 163 пациентов, у которых было 260811 пар 12-канальной ЭКГ-эхокардиограмм. Записи были разделены на группы: обучающая ($n=43165$), валидационная ($n = 12950$) и тестовая ($n = 21048$; в которой 7,8 % имели порок сердца: АС, АН или МН). Проводилась внешняя проверка на независимом наборе данных ($n = 3194$, среди которой 14,5 % пациентов имели указанные ПС. Входными данными моделей являлись нативный цифровой код ЭКГ (12 отведений, 10 секунд, 250 Гц, 30 000 точек данных на ЭКГ), а также демографические и табличные данные, относящиеся к ЭКГ (ритм, частота сердечных сокращений, интервал PR, длительность QRS , QT/QTc , QTc , угол отклонения электрической оси сердца от горизонтальной оси, пол и возраст пациентов). Точность моделей глубокого обучения в выявлении аортального стеноза составила: AUC 0,88 (95 % ДИ: 0,87-0,90); в определении МН 2-3 степени AUC 0,83 (95 % ДИ: 0,81-0,85), AUC 0,77 при внешней проверке. Точность моделей глубокого обучения отдельно для АН 2-3 степени составила: AUC 0,77 (95 % ДИ: 0,72-0,81), при внешней проверке – AUC : 0,65. Анализ подгрупп показывает, что модель одинаково хорошо работает вне зависимости от пола, этнической принадлежности и расы, но имеет меньшую точность у пожилых пациентов и лиц с расширенным комплексом QRS . Авторами не указаны значения чувствительности и специфичности [8].

Sawano S. с коллегами разработали алгоритм на основе искусственного интеллекта для выявления значимой (умеренной и тяжелой) аортальной регургитации по 12-канальной ЭКГ. Проанализировано 29 859 ЭКГ и эхокардиографии, из которых 412 имели АР 2-3 степени. Между ЭКГ и ЭХОКГ было не более 28 дней. Данные были случайным образом разделены на обучающий набор данных [19 136 пар от 10 460 пациентов (64,1 %)], проверочный [4 687 пар от 2 615 пациентов (15,7 %)] и тестовый [6 036 пар от 3 269 пациентов (20,2 %)]. Была разработана нейронная сеть с несколькими входами, которая включала *двумерную сверточную нейронную сеть (2D-CNN)*, использующую необработанные данные 12-канальной ЭКГ, и *глубокую нейронную сеть (FC-CNN)*, использующую обработанную ЭКГ (частота сердечных сокращений, наличие мерцательной аритмии, интервал RR , интервал PR , длительность QRS , интервал QT , QTc , ось QRS и ось зубца P , возраст и пол). Для модели с несколькими входами точность составила 82,3 % (95 % ДИ, 81,3-83,3 %), чувствительность – 53,5 % (95 % ДИ, 43,3-63,5 %), а специфичность – 82,8 % (95 % ДИ, 81,8-83,8 %). AUC глубокой нейронной сети с несколькими входами составила 0,802; [95 % ДИ, 0,762-0,837], что было значительно больше, чем у двухмерной CNN (0,734; 95 % ДИ, 0,679-0,783; $p < 0,001$) и у других моделей машинного обучения (модель логистической регрессии, случайного леса, многослойного перцептрона и *light GBM*). AUC многовходовой модели был значительно ниже без информации о наличии фибрилляции предсердий (0,763; 95 % ДИ, 0,717-0,804; $p = 0,002$). При этом отведения $V5$, aVL и I были наиболее чувствительными для обнаружения значительной АР: AUC 0,744; 0,727 и 0,723, соответственно. Среди ограничений следует отметить, что исследование было одноцентровое и не проводилась проверка с помощью внешних данных, а также не проводился анализ этиологии АР. Несмотря на то, что метод *Grad-CAM* продемонстрировал, что многовходовая модель фокусировалась на комплексе QRS в отведениях I и aVL , не было показано, какие именно части комплекса QRS необходимы для диагностики значимой АР [21].

Одним из наиболее крупных исследований по определению значимой структурной патологии как клапанного аппарата, так и миокарда по 12-канальной ЭКГ была работа *Ulloa-Cerna AE* и соавторов. Была разработана модель машинного обучения *rECHOmmend* на основе данных ЭКГ для выявления пациентов с высоким риском развития следующих патологий: умеренные или тяжелые клапанные пороки (аортальный стеноз; аортальная регургитация; митральный стеноз; митральная регургитация; и трикуспидальная регургитация), сниженная фракция выброса левого желудочка (<50 %), а также утолщение межжелудочковой перегородки более, чем на 15 мм). Для построения алгоритмов было использовано 2 232 130 ЭКГ от 484 765 пациентов. ЭХОКГ выполнялась в течение непосредственно после регистрации 12-канальной ЭКГ, а также через год. Были разработаны 9 моделей, в которых учитывались различные комбинации входных данных (демографические характеристики, лабораторные показатели, структурированные результаты и измерения ЭКГ), а также кривые напряжения ЭКГ. Обучение модели проходило на в клинике *Geisinger Medical Center* (США), а внешнее в 10 других независимых клинических центрах США. Авторы сосредоточили свое внимание на моделях, включающих только возраст, пол и ЭКГ-данные, поскольку этот набор входных данных легко получить при скрининговом применении модели. Показатель AUC при ROC анализе достиг 0,91. Кроме этого была продемонстрирована прогностическая точность модели: 11 % пациентов были классифицированы ИИ как пациенты высокого риска развития значимой структурной патологии сердца. Оказалось, что среди них у 41 % (4,5 % от общего числа пациентов) развилось истинное, подтвержденное эхокардиографией, заболевание в течение 1 года. При этом

отрицательная прогностическая ценность модели составила 96,2 %. При анализе комбинированной конечной точки (ПС + дисфункция и/или гипертрофия миокарда) модель обладала высокой чувствительностью (90 %) и специфичностью (73 %). Многоцентровая проверка показала результаты, схожие с перекрестной проверкой, с совокупной площадью под *ROC* кривой 0,91. Таким образом, разработанная модель машинного обучения «*rECHOmmend*» может предсказывать клинически значимую клапанную патологию, сниженную фракцию выброса левого желудочка или утолщение межжелудочковой перегородки с *AUC*, 0,91, основываясь только на данных 12-канальной ЭКГ, возрасте и поле пациентов. Это позволяет выявлять лиц с повышенным риском развития значимой структурной патологии сердца. Однако пока данная модель не апробирована и нет данных об ее клиническом использовании как скринингового метода [25].

В опубликованном в 2024 г. ретроспективном исследовании *Kalmady S.V.* и др. также анализировалась большая база 12-канальных ЭКГ для выявления 15 сердечно-сосудистых диагнозов, в том числе аортального и митрального стеноза. Было включено 1 605 268 ЭКГ от 244 077 пациентов. Средний возраст пациентов составил $65,8 \pm 17,3$ года, 56,7 % из них были мужчины. Разделение группы было на 60 % для обучения и 40 % - проверка алгоритмов. Кроме параметров ЭКГ учитывались возраст и пол пациентов. Было использовано: глубокое обучение на основе *ResNet*, а также модели *градиентно-усиленных древовидных ансамблей (XGB)*. В выявлении АС *AUC* составил 85,996, *F1 score* 8, 084, специфичность 82, 817, *precision* 4, 287, точность (accuracy) 82,686. В выявлении митрального стеноза: *AUC* составил 90,228, *F1 score* 1,129, специфичность 87,289, *precision* 0,568, точность (accuracy) 87, 280. Данное исследование имеет два существенных ограничения: наличие структурной и клапанной патологии сердца констатировалось из медицинской документации, а не при ЭХОКГ, проведенной в рамках данной работы; кроме того, внешняя проверка разработанного алгоритма не проводилась [22].

Таким образом, результаты представленных работ, которые кратко отражены в табл. 2, определяют высокие диагностические возможности стандартной 12-канальной ЭКГ в выявлении значимых ПС.

Таблица 2

Возможности выявления различных пороков сердца при анализе 12-канальной электрокардиограммы

Исследование	Тип выявляемого порока сердца	Метод искусственного интеллекта	<i>AUC</i>	Параметры диагностической и прогностической точности	Количество пациентов
<i>Cohen-Shelly M.</i> и др. [5]	Умеренный или тяжелый АС	СНС	0,85	Ч = 78 %, С = 74 %, Т = 74 %.	129 788
		СНС + пол и возраст	0,87	не указано	
		СНС + пол и возраст + нет АГ	0,90	Ч = 75 %, С = 88 %	
<i>Kwon</i> и др. [18]	Умеренный или тяжелый АС	СНС, МП (12-канальная ЭКГ)	0,861	Ч = 80 %, С = 78,3 %, Т = 78,3 %	43 051
		СНС, МП (2-канальная ЭКГ)	0,821	не указано	
<i>Kwon JM</i> и др. [17]	Выявление умеренной и тяжелой МР	СНС 12-канальная ЭКГ	0,877	Ч = 90,1 %, С = 66,9 %	24 202
		СНС 1-канальная ЭКГ	0,850	Ч = 90,1 %, С = 56 %	

<i>Elias P.</i> и др [8]	Умеренный или тяжелый АС	СНС	0,88	не указано	43 165
	АН 2-3 степени	СНС	0,77	не указано	
	МН 2-3 степени	СНС	0,83	не указано	
	Любой из указанных	СНС	0,84	Ч = 78 % С = 73 %	
<i>E. Hata</i> и др [11].	Выявление АС различной степени	СНС 12-канальная ЭКГ	0.68	T = 79.5 % Ч = 72.7 % Precision=84.2 %	128
		СНС 4-канальная ЭКГ	0.62	T = 77.3 % Ч = 77.3 % Precision=77.3 %	
<i>Ulloa-Cerna AE</i> и др. [25]	Умеренный или тяжелый АС (данные ЭКГ +пол +возраст)	СНС 12-канальная ЭКГ	0.908	Ч = 90 % С =75.7 %	434 220
	Умеренный или тяжелый АН (данные ЭКГ +пол +возраст)		0.849	Ч = 90 % С = 58.9 %	
	Умеренный или тяжелый МС (данные ЭКГ +пол +возраст)		0.918	Ч = 90 % С = 79.4 %	
	Умеренная или тяжелая МН (данные ЭКГ +пол +возраст)		0.911	Ч = 90 % С = 76.4 %	
	Умеренная или тяжелая ТН (данные ЭКГ +пол +возраст)		0.915	Ч = 90 % С = 76.9 %	
<i>Vaid A</i> и др. [27]	Умеренный или тяжелый АС	МП + СНС- <i>Efficientnet</i>	0.86	Ч = 92 % С = 63 %	АС- 128 628
	Умеренная или тяжелая МН		0.81	Ч = 83 % С = 63 %	МН- 123 096

<i>Sawano S.</i> и др. [21]	Выявление умеренной и тяжелой АР	<i>2D CHC + FC-DNN</i>	0,802	T = 82,3 % Ч = 53,5 % С = 82,8 %	10 460
<i>Kalmady S.V.</i> и др. [14]	АС	<i>ResNet XGB</i>	0,859	T = 82,6 % С = 82,8 %	146 446
	МС		0,902	T = 87,3 % С = 87,3 %	

Примечание: CHC – Сверточная нейронная сеть, МП – многослойный перцептрон, АС – аортальный стеноз, АН – аортальная недостаточность, МН – митральная недостаточность, МР – митральная регургитация, ч – чувствительность, с – специфичность, т – точность *FC-DNN* – глубокая нейронная сеть

Кроме данных исследований нам повстречались работы, которые демонстрируют возможности выявления ПС не по ЭКГ, а по другим кардиомеханическим сигналам. В одной из работ использовались сигналы, полученные с помощью неинвазивных носимых инерционных датчиков: акселерометра и гироскопа. Были проанализированы данные 21 пациента с АС и 13 пациентов без АС. Проводилось вейвлет-преобразование сигналов, по данным которого были построены алгоритмы машинного обучения: дерево решений, случайный лес, многослойная нейронная сеть перцептрона и *XGBoost*. Была разработана *двухмерная сверточная нейронная сеть (2D-CHC)*, использующая данные вейвлет-преобразования с использованием специально разработанной архитектуры и *CHC* на основе *Mobile Net* посредством трансферного обучения. Полученные результаты показывают хорошую точность: модель «дерево решений» – $AUC=0,87$, «случайный лес» – $AUC=0,96$, нейронная сеть – $AUC=0,91$ и *XGBoost* – $AUC=0,95$. С помощью структуры *2D-CHC* трансферное обучение *Mobile Net* показывает точность по *ROC* кривой с $AUC=0,91$, а специально созданный классификатор показывает $AUC=0,89$ [12]. В других подобных работах, демонстрировались возможности выявления АС по данным сейсмо- и гирокардиограммы с высокой точностью: показатели чувствительности и специфичности превышали 95 %, однако не небольшом клиническом материале, что требует дальнейших исследований в данном направлении [25].

Заключение. Искусственный интеллект значительно меняет современный мир, и его огромный потенциал в области медицины, безусловно, является вызовом для науки и здравоохранения [7]. В последнее десятилетие наблюдается растущий интерес к применению ИИ в диагностике сердечно-сосудистой патологии. Проанализированные исследования продемонстрировали возможности и потенциал ИИ /машинного обучения, используемых для анализа ЭКГ, в выявлении различных пороков сердца. Наибольшее количество опубликованных работ основано на выявлении аортального стеноза с помощью ЭКГ: AUC 0,85-0,93. Определение митральной недостаточности 2-3 степени продемонстрировало: AUC – 0,816- 0,877 при 12-канальной ЭКГ, AUC – 0,758-0,850 при анализе одноканальной ЭКГ. Выявление АР: точность составила 82,3 %, чувствительность – 53,5 %, специфичность – 82,8 %, AUC 0,802. При выявлении комбинированных пороков сердца диагностическая точность ряда алгоритмов превышала 80 %. Кроме параметров нативной ЭКГ в нескольких исследованиях важным являлся учет дополнительных параметров: *ValveNet* использовал демографические данные, *rECHOmmend* включал возраст и пол, а исследование *Kwon* с коллегами включало характеристики ЭКГ, демографические и антропометрические данные.

Полученные результаты продемонстрировали большой потенциал использования ИИ в качестве скринингового алгоритма для выявления групп лиц с ПС, которым будет рекомендовано дальнейшее дообследование. Однако остаются открытые вопросы: Можно ли созданные модели экстраполировать на все группы пациентов (по расовой принадлежности, с различной коморбидностью и т.п.)? Применимы ли алгоритмы на ЭКГ, полученных на разных аппаратах? Таких вопросов, безусловно, много. Все они подчеркивают необходимость проведения многоцентровых валидационных проспективных исследований, а также пилотных исследований по внедрению алгоритмов с целью дальнейшего анализа.

Уже сейчас мы вступаем в эру «Цифровой кардиологии», и будущее с использованием ИИ и машинного обучения выглядит многообещающим.

Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации в рамках государственной поддержки создания и развития научного центра мирового уровня «Цифровой биодизайн и персонализированное здравоохранение» № 075-15-2022-304.

Исследование выполнено при финансовой поддержке гранта правительства Москвы (исследовательский проект № 0803-6/23).

Литература

1. Сагирова Ж. Н., Кузнецова Н. О., Суворов А. Ю. Оценка систолической функции левого желудочка с помощью одноканального ЭКГ-монитора с функцией фотоплетизмографии на основе моделей машинного обучения. // Кардиология и сердечно-сосудистая хирургия. 2023. №16(1). P. 46-55
2. Abe Y. Screening for aortic stenosis using physical examination and echocardiography. // Journal of Echocardiography. 2021. №19(2). P. 80-85. doi: 10.1007/s12574-020-00511-8.
3. Aluru J.S., Barsouk A., Saginala K., Valvular Heart Disease Epidemiology. // Medical sciences (Bazel). 2022. №10(2). P. 32. doi: 10.3390/medsci10020032.
4. Chiang S.J., Daimon M., Miyazaki S. When and how aortic stenosis is first diagnosed: A single-center observational study. // Journal of Cardiology. 2016. №68(4). P. 324-8. doi: 10.1016/j.jjcc.2015.10.007.
5. Cohen-Shelly M., Attia Z.I., Friedman P.A. Electrocardiogram screening for aortic valve stenosis using artificial intelligence. // European Heart Journal. 2021. №42(30). P. 2885-2896. doi: 10.1093/eurheartj/ehab153.
6. Davidsen A.H., Andersen S., Halvorsen P.A. Diagnostic accuracy of heart auscultation for detecting valve disease: a systematic review. // British Medical Journal. Open 2023. №13. P. e068121. doi:10.1136/bmjopen-2022-068121.
7. Di Costanzo A., Spaccarotella C.A.M., Esposito G. An Artificial Intelligence Analysis of Electrocardiograms for the Clinical Diagnosis of Cardiovascular Diseases: A Narrative Review. // Journal of Clinical Medicine 2024. № 13. P. 1033. doi: 10.3390/jcm13041033.
8. Elias P., Poterucha T.J., Rajaram V. Deep Learning Electrocardiographic Analysis for Detection of Left-Sided Valvular Heart Disease. // Journal of the American College of Cardiology 2022. №80(6). P. 613-626. doi: 10.1016/j.jacc.2022.05.029.
9. Hagendorff, A., Knebel, F., Helfen. Expert consensus document on the assessment of the severity of aortic valve stenosis by echocardiography to provide diagnostic conclusiveness by standardized verifiable documentation. // Clinical Research in Cardiology 2020. № 109. P. 271–288.
10. Haq I.U., Haq I., Xu B. Artificial intelligence in personalized cardiovascular medicine and cardiovascular imaging. // Cardiovascular Diagnosis and Therapy 2021. №11(3). P. 911-923. doi: 10.21037/cdt.2020.03.09.
11. Hata E., Seo C., Nakayama M. Classification of Aortic Stenosis Using ECG by Deep Learning and its Analysis Using Grad-CAM. In 42nd Annual International Conferences of the IEEE Engineering in Medicine and Biology Society: Enabling Innovative Technologies for Global Healthcare, EMBC 2020. // Institute of Electrical and Electronics Engineers Inc. 2020. p. 1548-1551. 9175151. (Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS). doi: 10.1109/EMBC44109.2020.9175151.
12. Ito S., Cohen-Shelly M., Attia Z.I. Correlation between artificial intelligence-enabled electrocardiogram and echocardiographic features in aortic stenosis. // European Heart Journal - Digital Health. 2023. №4(3). P. 196-206. doi: 10.1093/ehjdh/ztad009.
13. Iung B., Vahanian A. Epidemiology of acquired valvular heart disease. // Canadian Journal of Cardiology. 2014. №30(9). P. 962-70. doi: 10.1016/j.cjca.2014.03.022.
14. Kalmady S.V., Salimi A., Sun W. Development and validation of machine learning algorithms based on electrocardiograms for cardiovascular diagnoses at the population level. // Npj Digital Medicine. 2024. №7(1). P. 133. doi: 10.1038/s41746-024-01130-8.
15. Kattoor A.J., Shanbhag A., Abraham A., et al. Clinical Context and Detection of the Murmur of Advanced Aortic Stenosis. // Southern Medical Journal. 2018. №111(4). P. 230-234. doi: 10.14423/SMJ.0000000000000791.
16. Kuznetsova N., Sagirova Zh., Suворov A. A screening method for predicting left ventricular dysfunction based on spectral analysis of a single-channel electrocardiogram using machine learning algorithms. // Biomedical Signal Processing and Control. 2023. Vol. 86. P. 105219. doi 10.1016/j.bspc.2023.105219.
17. Kwon J.M., Kim K.H., Akkus Z. Artificial intelligence for detecting mitral regurgitation using electrocardiography. // J Electrocardiol. 2020. №59. P. 151-157. doi: 10.1016/j.jelectrocard.2020.02.008.
18. Kwon J.M., Lee S.Y., Jeon K.H. Deep Learning-Based Algorithm for Detecting Aortic Stenosis Using Electrocardiography. // Journal of the American Heart Association. 2020. №9(7). P. e014717. doi: 10.1161/JAHA.119.014717.
19. Patterson T., Adams H., Allen C. Indirect Annuloplasty to Treat Functional Mitral Regurgitation: Current Results and Future Perspectives. // Frontiers in Cardiovascular Medicine 2019. №6. P. 60. doi: 10.3389/fcvm.2019.00060.
20. Santangelo G., Bursi F., Faggiano A. The Global Burden of Valvular Heart Disease: From Clinical Epidemiology to Management. // Journal of Clinical Medicine 2023. №12(6). P. 2178. doi: 10.3390/jcm12062178.

21. Sawano S., Kodera S., Katsushika S. Deep learning model to detect significant aortic regurgitation using electrocardiography. // *Journal of Cardiology* 2022. №79(3). P. 334-341. doi: 10.1016/j.jjcc.2021.08.029.
22. Singh S., Chaudhary R., Bliden K.P. Meta-Analysis of the Performance of AI-Driven ECG Interpretation in the Diagnosis of Valvular Heart Diseases. // *The American journal of cardiology*. 2024. №213. P. 126-131. doi: 10.1016/j.amjcard.2023.12.015.
23. Sun X., Yin Y., Yang Q. Artificial intelligence in cardiovascular diseases: diagnostic and therapeutic perspectives. // *European Journal of Medical Research*. 2023. №28(1). P. 242. doi: 10.1186/s40001-023-01065-y.
24. Tseng A.S., Shelly-Cohen M., Attia I.Z. Spectrum bias in algorithms derived by artificial intelligence: a case study in detecting aortic stenosis using electrocardiograms. // *European Heart Journal - Digital Health*. 2021. №2(4). P. 561-567. doi: 10.1093/ehjdh/ztab061.
25. Ulloa-Cerna A.E., Jing L., Pfeifer J.M. rECHOmmend: An ECG-Based Machine Learning Approach for Identifying Patients at Increased Risk of Undiagnosed Structural Heart Disease Detectable by Echocardiography. *Circulation*. 2022. №146(1). P. 36-47. doi: 10.1161/CIRCULATIONAHA.121.057869.
26. Vahanian A., Beyersdorf F., Praz F. ESC/EACTS Scientific Document Group. 2021 ESC/EACTS Guidelines for the management of valvular heart disease. // *European Heart Journal* 2022. №43(7). P. 561-632. doi: 10.1093/eurheartj/ehab395.
27. Vaid A., Argulian E., Lerakis S. Multi-center retrospective cohort study applying deep learning to electrocardiograms to identify left heart valvular dysfunction. // *Communications medicine (London)*. 2023. №3(1). P. 24. doi: 10.1038/s43856-023-00240-w.
28. Writing Committee Members, Otto C.M., Nishimura R.A. ACC/AHA guideline for the management of patients with valvular heart disease: A report of the American College of Cardiology/American Heart Association Joint Committee on Clinical Practice Guidelines. // *The Journal of Thoracic and Cardiovascular Surgery*. 2021. №162(2). P. e183-e353. doi: 10.1016/j.jtcvs.2021.04.002.

References

1. Sagirova Zh. N., Kuznecova N. O., Suvorov A. Yu. Ocenka sistolicheskoy funktsii levogo zheludochka s pomoshch'yu odnokanal'nogo EKG-monitora s funkciej fotopletizmografii na osnove modelej mashinnogo obucheniya. *Kardiologiya i serdechno-sosudistaya hirurgiya*. 2023;16(1): 46-55. Russian.
2. Abe Y. Screening for aortic stenosis using physical examination and echocardiography. *Journal of Echocardiography*. 2021;19(2):80-85. doi: 10.1007/s12574-020-00511-8.
3. Aluru JS, Barsouk A, Saginala K, et al. Valvular Heart Disease Epidemiology. *Medical sciences (Bazel)*. 2022 Jun 15;10(2):32. doi: 10.3390/medsci10020032.
4. Chiang SJ, Daimon M, Miyazaki S, et al. When and how aortic stenosis is first diagnosed: A single-center observational study. *Journal of Cardiology*. 2016 Oct;68(4):324-8. doi: 10.1016/j.jjcc.2015.10.007.
5. Cohen-Shelly M, Attia ZI, Friedman PA, et al. Electrocardiogram screening for aortic valve stenosis using artificial intelligence. *European Heart Journal*. 2021 Aug 7;42(30):2885-2896. doi: 10.1093/eurheartj/ehab153.
6. Davidsen AH, Andersen S, Halvorsen PA, et al. Diagnostic accuracy of heart auscultation for detecting valve disease: a systematic review. *British Medical Journal. Open* 2023;13:e068121. doi:10.1136/bmjopen-2022-068121.
7. Di Costanzo A, Spaccarotella CAM, Esposito G. et al. An Artificial Intelligence Analysis of Electrocardiograms for the Clinical Diagnosis of Cardiovascular Diseases: A Narrative Review. *Journal of Clinical Medicine* 2024, 13, 1033. doi: 10.3390/jcm13041033.
8. Elias P, Poterucha TJ, Rajaram V, et al. Deep Learning Electrocardiographic Analysis for Detection of Left-Sided Valvular Heart Disease. *Journal of the American College of Cardiology* 2022 Aug 9;80(6):613-626. doi: 10.1016/j.jacc.2022.05.029.
9. Hagendorff A, Knebel, F, Helfen, et al. Expert consensus document on the assessment of the severity of aortic valve stenosis by echocardiography to provide diagnostic conclusiveness by standardized verifiable documentation. *Clinical Research in Cardiology* 2020, 109, 271–288.
10. Haq IU, Haq I, Xu B. Artificial intelligence in personalized cardiovascular medicine and cardiovascular imaging. *Cardiovascular Diagnosis and Therapy* 2021;11(3):911-923. doi: 10.21037/cdt.2020.03.09.
11. Hata E, Seo C, Nakayama M, et al. Classification of Aortic Stenosis Using ECG by Deep Learning and its Analysis Using Grad-CAM. In 42nd Annual International Conferences of the IEEE Engineering in Medicine and Biology Society: Enabling Innovative Technologies for Global Healthcare, EMBC 2020. Institute of Electrical and Electronics Engineers Inc. 2020. p. 1548-1551. 9175151. (Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS). doi: 10.1109/EMBC44109.2020.9175151.
12. Ito S, Cohen-Shelly M, Attia ZI, et al. Correlation between artificial intelligence-enabled electrocardiogram and echocardiographic features in aortic stenosis. *European Heart Journal - Digital Health*. 2023 Feb 8;4(3):196-206. doi: 10.1093/ehjdh/ztd009.
13. Iung B, Vahanian A. Epidemiology of acquired valvular heart disease. *Canadian Journal of Cardiology*. 2014 Sep;30(9):962-70. doi: 10.1016/j.cjca.2014.03.022.
14. Kalmady SV, Salimi A, Sun W, et al. Development and validation of machine learning algorithms based on electrocardiograms for cardiovascular diagnoses at the population level. *Npj Digital Medicine*. 2024 May 18;7(1):133. doi: 10.1038/s41746-024-01130-8.

15. Kattoor AJ, Shanbhag A, Abraham A, et al. Clinical Context and Detection of the Murmur of Advanced Aortic Stenosis. *Southern Medical Journal*. 2018 Apr;111(4):230-234. doi: 10.14423/SMJ.0000000000000791.

16. Kuznetsova N, Sagirova Zh, Suvorov A. et al. A screening method for predicting left ventricular dysfunction based on spectral analysis of a single-channel electrocardiogram using machine learning algorithms. *Biomedical Signal Processing and Control*. 2023. – Vol. 86. – P. 105219. – doi 10.1016/j.bspc.2023.105219.

17. Kwon JM, Kim KH, Akkus Z, et al. Artificial intelligence for detecting mitral regurgitation using electrocardiography. *J Electrocardiol*. 2020 Mar-Apr;59:151-157. doi: 10.1016/j.jelectrocard.2020.02.008.

18. Kwon JM, Lee SY, Jeon KH, et al. Deep Learning-Based Algorithm for Detecting Aortic Stenosis Using Electrocardiography. *Journal of the American Heart Association*. 2020 Apr 7;9(7):e014717. doi: 10.1161/JAHA.119.014717.

19. Patterson T, Adams H, Allen C. et al. Indirect Annuloplasty to Treat Functional Mitral Regurgitation: Current Results and Future Perspectives. *Frontiers in Cardiovascular Medicine* 2019 May 17;6:60. doi: 10.3389/fcvm.2019.00060.

20. Santangelo G, Bursi ., Faggiano A, et al. The Global Burden of Valvular Heart Disease: From Clinical Epidemiology to Management. *Journal of Clinical Medicine* 2023 Mar 10;12(6):2178. doi: 10.3390/jcm12062178.

21. Sawano S, Kodera S, Katsushika S, et al. Deep learning model to detect significant aortic regurgitation using electrocardiography. *Journal of Cardiology* 2022 Mar;79(3):334-341. doi: 10.1016/j.jcc.2021.08.029.

22. Singh S, Chaudhary R, Bliden KP. et al. Meta-Analysis of the Performance of AI-Driven ECG Interpretation in the Diagnosis of Valvular Heart Diseases. *The American journal of cardiology*. 2024 Feb 15;213:126-131. doi: 10.1016/j.amjcard.2023.12.015.

23. Sun X, Yin Y, Yang Q, et al. Artificial intelligence in cardiovascular diseases: diagnostic and therapeutic perspectives. *European Journal of Medical Research*. 2023 Jul 21;28(1):242. doi: 10.1186/s40001-023-01065-y.

24. Tseng AS, Shelly-Cohen M, Attia IZ, et al. Spectrum bias in algorithms derived by artificial intelligence: a case study in detecting aortic stenosis using electrocardiograms. *European Heart Journal - Digital Health*. 2021 Jul 14;2(4):561-567. doi: 10.1093/ehjdh/ztab061.

25. Ulloa-Cerna AE, Jing L, Pfeifer JM, et al. rECHOmmend: An ECG-Based Machine Learning Approach for Identifying Patients at Increased Risk of Undiagnosed Structural Heart Disease Detectable by Echocardiography. *Circulation*. 2022 Jul 5;146(1):36-47. doi: 10.1161/CIRCULATIONAHA.121.057869.

26. Vahanian A, Beyersdorf F, Praz F, et al. ESC/EACTS Scientific Document Group. 2021 ESC/EACTS Guidelines for the management of valvular heart disease. *European Heart Journal* 2022 Feb 12;43(7):561-632. doi: 10.1093/eurheartj/ehab395. Erratum in: *Eur Heart J*. 2022 Jun 1;43(21):2022. doi: 10.1093/eurheartj/ehac051. PMID: 34453165.

27. Vaid A, Argulian E, Lerakis S, et al. Multi-center retrospective cohort study applying deep learning to electrocardiograms to identify left heart valvular dysfunction. *Communications medicine (London)*. 2023 Feb 14;3(1):24. doi: 10.1038/s43856-023-00240-w.

28. Writing Committee Members; Otto CM, Nishimura RA, et al. 2020 ACC/AHA guideline for the management of patients with valvular heart disease: A report of the American College of Cardiology/American Heart Association Joint Committee on Clinical Practice Guidelines. *The Journal of Thoracic and Cardiovascular Surgery*. 2021 Aug;162(2):e183-e353. doi: 10.1016/j.jtcvs.2021.04.002.

Библиографическая ссылка:

Кузнецова Н.О., Алексеева А.М., Мамедзаде Ф.Э., Седов В.П., Копылов Ф.Ю., Сыркин А.Л., Чомахидзе П.Ш. Скрининг пороков сердца при анализе электрокардиограммы с помощью методов машинного обучения (обзор литературы) // Вестник новых медицинских технологий. Электронное издание. 2025. №1. Публикация 1-6. URL: <http://www.medtsu.tula.ru/VNMT/Bulletin/E2025-1/1-6.pdf> (дата обращения: 04.02.2025). DOI: 10.24412/2075-4094-2025-1-1-6. EDN KNFSNS*

Bibliographic reference:

Kuznetsova NO, Alekseeva AM, Mamedzade FE, Sedov VP, Kopylov FYu, Syrkin AL, Chomakhidze PSh. Skrining porokov serdca pri analize elektrokardiogrammy s pomoshch'yu metodov mashinnogo obucheniya (obzor literatury)[Screening of heart defects in electrocardiogram analysis using machine learning methods (literature review)]. *Journal of New Medical Technologies, e-edition*. 2025 [cited 2025 Feb 04];1 [about 11 p.]. Russian. Available from: <http://www.medtsu.tula.ru/VNMT/Bulletin/E2025-1/1-6.pdf>. DOI: 10.24412/2075-4094-2025-1-1-6. EDN KNFSNS

* номера страниц смотреть после выхода полной версии журнала: URL: <http://medtsu.tula.ru/VNMT/Bulletin/E2025-1/e2025-1.pdf>

**идентификатор для научных публикаций EDN (eLIBRARY Document Number) будет активен после выгрузки полной версии журнала в eLIBRARY