

НОВИКОВА О.А.,

к.т.н., Первый Московский государственный медицинский университет имени И.М. Сеченова, г. Москва, Россия; e-mail: ol-novikova@bk.ru

ЕРМОЛОВ А.Е.,

МИРЭА – Российский технологический университет, г. Москва, Россия; e-mail: a.e.ermolov@mail.ru

СВЕРТОЧНАЯ НЕЙРОННАЯ СЕТЬ ДЛЯ ОБНАРУЖЕНИЯ НАРУШЕНИЙ СЕРДЕЧНОГО РИТМА

DOI: 10. 25881/18110193_2025_4_44

Аннотация. Целью исследования является разработка и оценка архитектуры нейронной сети для автоматизированного анализа электрокардиографических (ЭКГ) сигналов, позволяющей выявлять нарушения сердечного ритма.

Материалы и методы. Для обучения использованы открытые базы данных ЭКГ (34570 записей). Работа проводилась на основе данных шести стандартных отведений (I, II, III, aVR, aVL, aVF). Предобработка сигналов включала удаление полиномиального тренда, вейвлет-фильтрацию, медианную фильтрацию, сглаживание и нормализацию. Для классификации использовалась сверточная нейронная сеть, которая обрабатывает сигналы каждого из шести отведений по отдельности. Итоговое решение формируется методом взвешенного голосования с эмпирически определенными коэффициентами, отражающими вклад каждого канала на основе предварительного анализа метрик. В качестве референсного теста использовалась клиническая аннотация, выполненная врачами-кардиологами.

Результаты. Предложенная модель демонстрирует высокие показатели качества классификации: accuracy – 0,97 (95% ДИ 0,96-0,98), precision – 0,98 (95% ДИ 0,97-0,99), recall – 0,98 (95% ДИ 0,97-0,99), specificity – 0,94 (95% ДИ 0,92-0,96), F1-score – 0,98 (95% ДИ 0,97-0,99), ROC-AUC – 0,99 (95% ДИ 0,98-1,00), PR-AUC – 0,96 (95% ДИ 0,94-0,97).

Заключение. Полученные результаты подтверждают эффективность предложенного метода в задачах диагностики сердечно-сосудистых заболеваний. Предложенная методика может быть адаптирована для диагностики более широкого спектра сердечных заболеваний, что делает ее актуальной для внедрения в практическую кардиологию.

Ключевые слова: ЭКГ, классификация, сверточная нейронная сеть, обработка сигнала.

Для цитирования: Новикова О.А., Ермолов А.Е. Сверточная нейронная сеть для обнаружения нарушений сердечного ритма. Врач и информационные технологии. 2025; 4: 44-55. DOI: 10. 25881/18110193_2025_4_44.

NOVIKOVA O.A.,

PhD, I.M. Sechenov First Moscow State Medical University,
Moscow, Russia; e-mail: ol-novikova@bk.ru

ERMOLOV A.E.,

MIREA – Russian Technological University, Moscow, Russia; e-mail: a.e.ermolov@mail.ru

CONVOLUTIONAL NEURAL NETWORK FOR DETECTING CARDIAC ARRHYTHMIAS

DOI: 10. 25881/18110193_2025_4_44

Abstract. *The aim of the study is to develop and evaluate the architecture of a neural network for automated analysis of electrocardiographic (ECG) signals to detect cardiac arrhythmias.*

Materials and methods. Open ECG databases (34,570 records) were used for training. The study was conducted using data from six standard ECG leads (I, II, III, aVR, aVL, aVF). Signal preprocessing included polynomial trend removal, wavelet filtering, median filtering, smoothing, and normalization. A convolutional neural network, which processes signals from each of the six leads separately, was used for classification. The final decision is formed using a weighted voting method with empirically determined coefficients reflecting the contribution of each channel based on a preliminary analysis of metrics. A clinical annotation performed by cardiologists was used as a reference standard.

Results. The proposed model demonstrates high classification performance: accuracy – 0.97 (95% CI 0.96-0.98), precision – 0.98 (95% CI 0.97-0.99), recall – 0.98 (95% CI 0.97-0.99), specificity – 0.94 (95% CI 0.92-0.96), F1-score – 0.98 (95% CI 0.97-0.99), ROC-AUC – 0.99 (95% CI 0.98-1.00), PR-AUC – 0.96 (95% CI 0.94-0.97).

Conclusion. The obtained results confirm the effectiveness of the proposed method for diagnosing cardiovascular diseases. The proposed method can be adapted for diagnosing a wider range of cardiac diseases, making it relevant for implementation in practical cardiology.

Keywords: ECG, classification, convolutional neural network, signal processing.

For citation: Novikova O.A., Ermolov A.E. Convolutional neural network for detecting cardiac arrhythmias. Medical doctor and information technology. 2025; 4: 44-55. DOI: 10. 25881/18110193_2025_4_44.

ВВЕДЕНИЕ

Анализ электрокардиограммы (ЭКГ) является важнейшим инструментом диагностики сердечно-сосудистых заболеваний. Несмотря на то, что традиционные методы интерпретации ЭКГ широко применяются, визуальная оценка специалистом подвержена субъективности и требует значительных временных затрат. Современные подходы на основе машинного обучения и нейронных сетей позволяют автоматизировать этот процесс, обеспечивая более точное и быстрое выявление патологий [1].

Несмотря на большое количество существующих решений для автоматизированного анализа ЭКГ, большинство из них ориентированы на обобщенный анализ без учета диагностической значимости отдельных отведений, что ограничивает точность и интерпретируемость результатов. В этой связи особую актуальность приобретает разработка системы, способной индивидуально анализировать каждое из шести стандартных отведений с учетом их вклада в диагностический вывод.

Целью исследования является разработка и оценка архитектуры нейронной сети для автоматизированного анализа ЭКГ-сигналов, позволяющей обнаруживать нарушения сердечного ритма. Новизна исследования состоит в применении метода агрегирования результатов на основе взвешенного голосования по каждому отведению. Гипотеза исследования заключается в том, что такой подход улучшает диагностическую точность по сравнению с усреднением или одиночной моделью.

В качестве индексного теста рассматривается разработанная архитектура сверточной нейронной сети с раздельной обработкой каналов и взвешенным голосованием. В качестве референтного стандарта использовались экспертные аннотации (метки) из объединенного эталонного датасета, включающего вручную размеченные записи ЭКГ.

В ряде современных работ рассматриваются как технические, так и методические аспекты автоматизированного анализа ЭКГ. Шутов Д.В., Дроздов Д.В., Газашвили Т.М. и др. предложили регламентированный подход к формированию эталонных ЭКГ-датасетов, однако данный метод требует значительных ресурсов и обладает ограниченной масштабируемостью [2].

Zhang Y., Liu S., He Z. и др. разработали устойчивую к шуму сверточную нейросеть для классификации аритмий, однако ее применимость вне носимых устройств остается ограниченной [3]. Cheng J., Zou Q. и Zhao Y. представили гибридную архитектуру DCNN и BiLSTM, учитывающую пространственные и временные характеристики сигналов, но не проводили детальный анализ вклада отдельных отведений [4]. Maweu B.M., Dakshit S., Shamsuddin R. и др. разработали интерпретируемую модульную систему CEFES для анализа медицинских временных рядов, однако ее архитектура усложняет обучение модели на новых данных [5]. Андриков Д.А. и Курбанов С.В. исследовали возможности спектрального анализа одного периода ЭКГ с применением Фурье-преобразования для идентификации аритмий, но подобный подход чувствителен к артефактам и межиндивидуальной вариабельности [6]. Павлов А.Н., Руннова А.Е. и Храмов А.Е. сравнили эффективность вейвлет- и эмпирических мод для анализа нестационарных биофизических сигналов, при этом не предложили решений по интеграции этих методов в автоматизированные диагностические системы [7].

Предлагаемая модель ориентирована на применение в качестве инструмента поддержки принятия решений в первичном звене здравоохранения для предварительного выявления аритмий на основании стандартных ЭКГ-отведений.

МАТЕРИАЛЫ И МЕТОДЫ

Исследование имело ретроспективный характер. В работе использованы данные из пяти крупнейших баз электрокардиограмм: Shaoxing and Ningbo First Hospital ECG Database [8], PTB-XL ECG Dataset [9], Georgia 12-Lead ECG Challenge Database [10], China Physiological Signal Challenge 2018 [11], China 12-Lead ECG Challenge Database [12].

Shaoxing and Ningbo First Hospital ECG Database и China 12-Lead ECG Challenge Database содержат записи 12 отведений ЭКГ пациентов, обследованных в больницах Shaoxing People's Hospital и Ningbo First Hospital (Китай) в 2018–2021 гг. Данные получены на стандартном оборудовании (GE MUSE ECG System) у амбулаторных и стационарных пациентов с различными показаниями, включая профилактические осмотры.

PTB-XL ECG Dataset – база данных, собранная Немецким национальным исследовательским центром (Physikalisch-Technische Bundesanstalt) в 1989-1996 гг. Набор включает как лиц без выраженной кардиальной патологии, так и пациентов с широким спектром сердечно-сосудистых заболеваний, наблюдавшихся в амбулаторных и стационарных условиях.

Georgia 12-Lead ECG Challenge Database создан для PhysioNet Challenge 2020 и содержит многоканальные ЭКГ из Emory University Hospital (штат Джорджия, США), собранные в 2019-2020 гг. Записи получены в клинических условиях у пациентов с аритмиями, ишемией и другими патологиями. Популяция – стационарные пациенты.

China Physiological Signal Challenge 2018 (CPSC 2018) включает записи 12-отведений ЭКГ, собранных в 11 китайских больницах (амбулаторных и стационарных) в 2016–2018 гг.

Для всех наборов данных ЭКГ аннотации сделаны врачами-кардиологами и включают размеченные диагнозы систематизированной медицинской номенклатурой SNOMED CT. Критериями включения сигналов являлись: частота дискретизации 50 Гц и длительность 10 секунд. Масштаб амплитуды составлял 1000 дискрет на милливольт, что обеспечивает достаточное разрешение для анализа характерных элементов ЭКГ.

В качестве референсного теста использовалась клиническая аннотация, выполненная врачами-кардиологами, предоставленная в составе оригинальных ЭКГ-баз. Разметка в указанных наборах данных проходила процедуру двойной независимой оценки, причем согласованность экспертов подтверждена в документации к базам данных, что гарантирует достоверность аннотаций для использования в качестве эталона.

Экспериментальные исследования выполнены с использованием языка программирования Python 3.11.11. Для осуществления консолидации данных использовались библиотеки `os`, `pandas 2.2.2`, `scipy 1.13.1`, `numpy 1.26.4`.

Из всех записей выбраны отведения: I, II, III, aVR, aVL, aVF. Изучение этих шести каналов позволяет учитывать ключевые электрические характеристики сердца, обеспечивая стандартизированный подход к обработке данных.

Объединенный набор данных включает 34570 записей, сгруппированных по следующим диагнозам: синусовый ритм – 14419 шт., синусовая брадикардия – 9361 шт., синусовая тахикардия – 3980 шт., трепетание предсердий – 2628 шт., изменение волны Т – 1612 шт., синусовая аритмия – 1361 шт., блокада правой ножки пучка Гиса – 671 шт., ритм от искусственной стимуляции – 538 шт. Выборка формировалась последовательно: все записи, удовлетворяющие критериям включения и содержащие диагнозы из целевого списка, были включены в набор данных.

Предобработка данных ЭКГ играет важную роль в устранении шумов, трендов и других искажений, которые могут затруднить анализ и интерпретацию входной информации [13]. Для осуществления предобработки данных использовались библиотеки `scipy 1.13.1`, `numpy 1.26.4`, `ruwt 1.3.0`.

Для удаления тренда применялось полиномиальное аппроксимирование второй степени, позволяющее устранить искажения, вызванные внешними воздействиями или техническими шумами.

Далее применялось дискретное вейвлет-преобразование для фильтрации шума. Использовался метод Добеши 4-го порядка, который позволяет выделить важные особенности сигнала, сохраняя его временную локализацию. Дискретное вейвлет-преобразование (DWT) разбивает данные на несколько уровней и выделяет разные частотные компоненты [14].

Для подавления остаточного шума использовался метод пороговой обработки (thresholding), при котором мелкомасштабные коэффициенты обнуляются. Он позволяет эффективно избавиться от искажений в высокочастотных компонентах, не затрагивая важную информацию.

После вейвлет-фильтрации сигнал подавался медианной фильтрации, которая служит для устранения остаточного шума, не подавляя при этом значимые характеристики, такие как пиковые значения ЭКГ. Медианный фильтр заменяет значение каждого элемента сигнала на медиану значений в ее окрестности. Он позволяет удалить случайные шумы и сохранить более значимые составляющие данных [15].

Для дополнительного сглаживания сигнала применялся метод скользящего среднего. Этот

алгоритм позволяет уменьшить колебания временного ряда, что полезно для выделения более значимых составляющих [16].

Заключительный этап предобработки – нормализация сигнала в диапазоне [0,1], обеспечивающая стандартизацию входных данных и корректность дальнейшего анализа [17].

На рисунке 1 показан пример сигнала ЭКГ из отведения I до и после предобработки, для визуализации использовалась библиотека matplotlib 3.10.0.

Данные стратифицированы и разделены на обучающую (27656 записей, 80%) и тестовую (6914 записей, 20%) выборки. Для обеспечения репрезентативности и сбалансированности выборок была применена стратификация по ключевым демографическим и клиническим признакам: диагнозам пациентов, возрасту и полу.

Описательные статистики групп представлены в таблице 1, где M – среднее значение, а SD – стандартное отклонение.

Стратификация обеспечила сбалансированное распределение классов и демографических признаков, минимизируя возможные смещения.

В качестве индексного теста выступает разработанная сверточная нейронная сеть. Она представляет собой многослойную архитектуру, предназначенную для классификации результатов ЭКГ. Входные данные являются одномерными массивами длиной 5000 элементов. Архитектура разработана для извлечения ключевых признаков из ЭКГ-сигналов и классификации по восьми диагнозам, представленных в наборе данных: синусовый ритм, синусовая брадикардия, синусовая тахикардия, трепетание предсердий, изменение волны Т, синусовая аритмия,

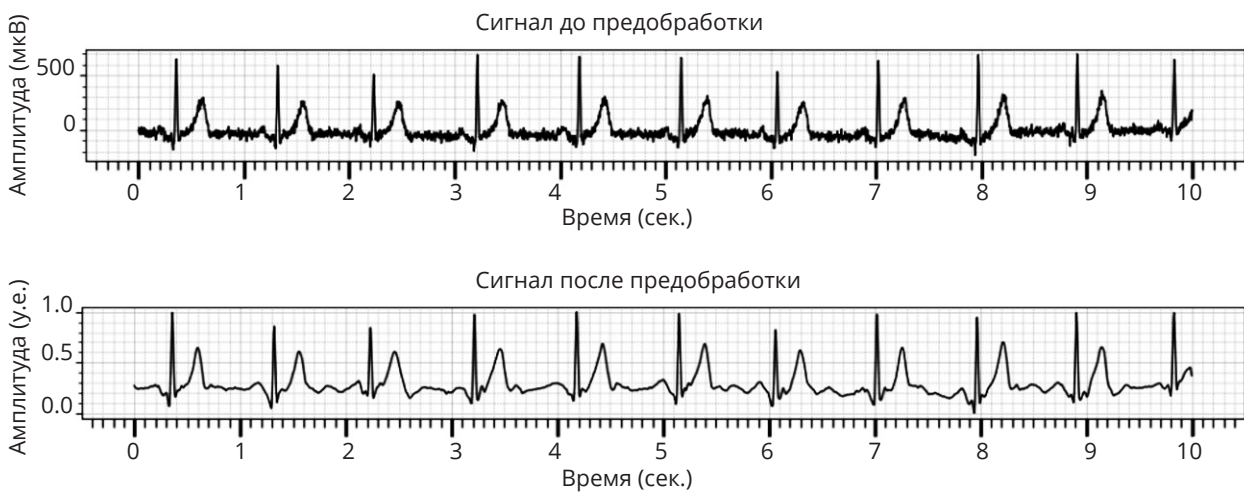


Рисунок 1 — Сигнал до и после обработки.

Таблица 1 — Описательные статистики групп в обучающей и тестовой выборках

Диагноз	Обучающая выборка			Тестовая выборка		
	Размер выборки	Возраст, лет (M±SD)	Женщины, %	Размер выборки	Возраст, лет (M±SD)	Женщины, %
Синусовый ритм	11 535	44,8±17,2	51,2%	2 884	45,0±17,3	51,0%
Синусовая брадикардия	7 489	54,3±16,1	48,6%	1 872	54,1±15,8	48,8%
Синусовая тахикардия	3 184	39,6±14,7	55,4%	796	39,4±14,5	55,6%
Трепетание предсердий	2 102	65,2±13,4	42,1%	526	65,5±13,1	42,4%
Изменение волны Т	1 290	49,5±17,5	50,7%	322	49,1±17,2	50,3%
Синусовая аритмия	1 089	36,8±12,6	53,2%	272	36,6±12,4	53,7%
Блокада правой ножки пучка Гиса	537	60,9±11,5	41,9%	134	60,4±11,2	42,5%
Ритм от искусственной стимуляции	430	71,6±9,8	47,0%	108	72,0±9,4	46,3%

блокада правой ножки пучка Гиса, ритм от искусственной стимуляции. Модель нейронной сети при прогнозировании диагнозов не имела доступа к истинным меткам, используемым в качестве референсного теста.

Модель включает в себя блоки сверточных слоев, остаточные соединения, операции агрегации и полносвязные слои [18]. На начальных этапах происходит последовательное извлечение признаков с увеличением глубины признакового пространства. В архитектуре используются регуляризация (L2), функция активации ReLU, пакетная нормализация, пулинг и Dropout [19], что способствует повышению устойчивости модели к переобучению. Остаточные блоки позволяют сохранить информацию от начальных

слоев и обеспечивают стабильное обучение более глубокой модели. Заключительный этап обработки включает глобальное усреднение и полносвязные слои, за которыми следует выходной слой с функцией softmax, преобразующий выход в вероятности по классам. Модель оптимизируется с помощью алгоритма AdamW, который обеспечивает адаптивное обновление весов с учетом весовой регуляризации [20].

Для реализации нейронной сети использовались библиотеки numpy 1.26.4, pandas 2.2.2, os, random, collections, sklearn 1.6.0, scipy 1.13.1, tensorflow 2.17.1. Вычисления осуществлялись на графическом процессоре Tesla T4.

Архитектура нейронной сети представлена на рисунке 2.

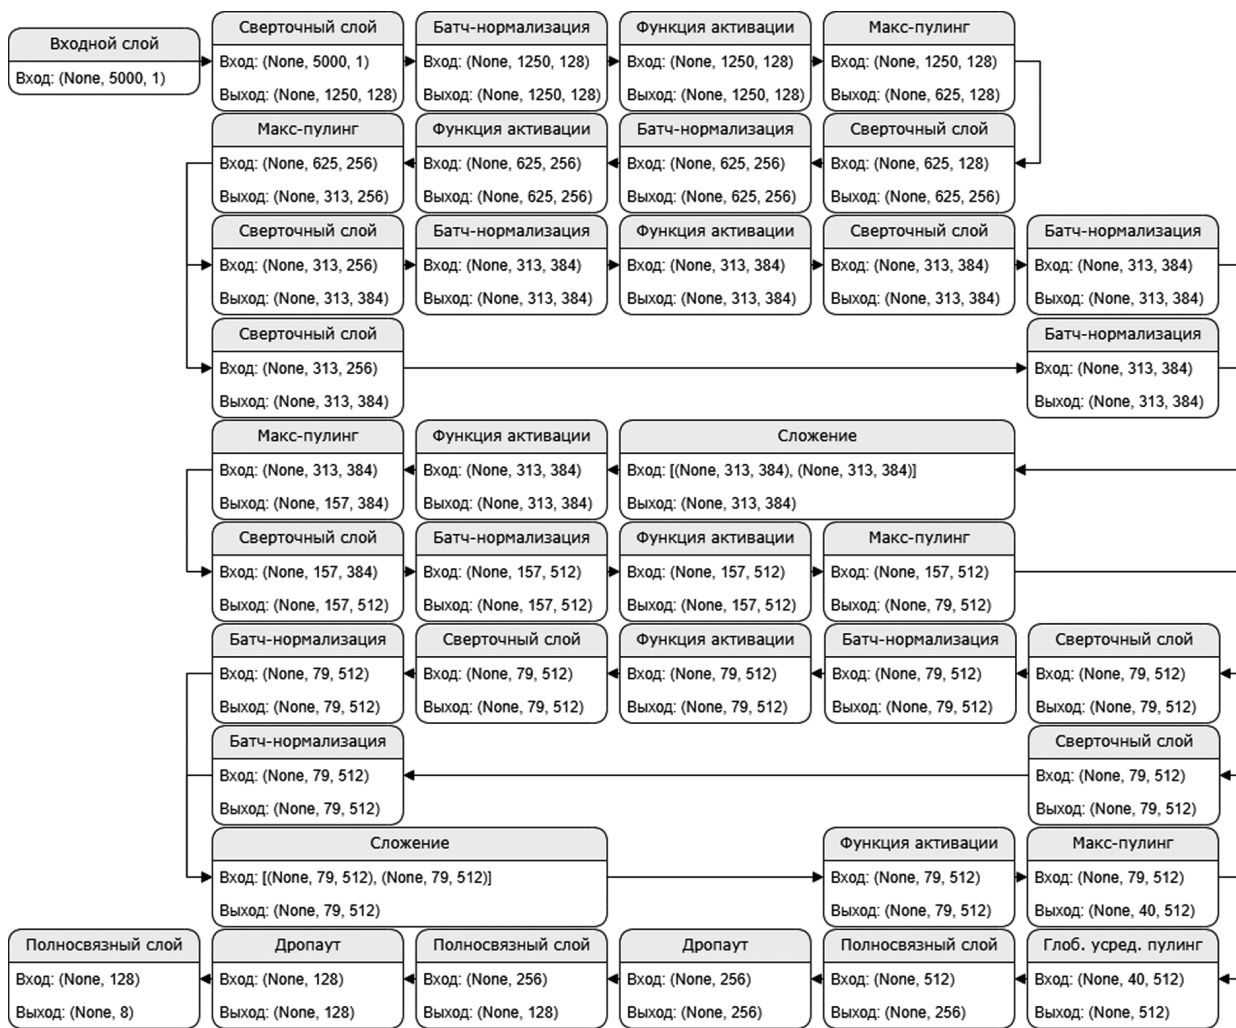


Рисунок 2 — Архитектура сверточной нейронной сети.

Предложенная нейронная сеть применена для анализа данных с каждого из стандартных отведений ЭКГ: I, II, III, aVR, aVL и aVF. Эти каналы представляют собой различные проекции электрической активности сердца, что позволяет модели учитывать разнообразие аспекты его функционального состояния.

Отведения обрабатывались как независимые одномерные ряды длиной 5000, подаваемые в модель. Это позволило извлечь как общие, так и специфические для определенного отведения паттерны.

Процесс обучения модели выполнен в течение 30 эпох – полных проходов по обучающему набору данных, в ходе которых сеть последовательно обновляла свои веса на основе обратного распространения ошибки. Валидация проводилась после каждой эпохи для оценки качества и предотвращения переобучения.

После получения прогноза для каждого отведения итоговый диагноз формировался методом взвешенного голосования, учитывающим результаты индивидуальной обработки каждого канала. Для улучшения точности каждому каналу присвоены веса, отражающие его диагностическую значимость. Для объединения результатов отведений использованы следующие веса: I – 0,1667; II – 0,1666; III – 0,1663; aVR – 0,1673; aVL – 0,1663; aVF – 0,1670. Веса определены с помощью численной оптимизации: на основе предсказаний моделей подбирались такие коэффициенты, которые максимизируют метрику precision с поправкой на преваленс дифференцируемых состояний в целевой популяции. Для этого использовался метод последовательного квадратичного программирования (SLSQP).

Взвешенное голосование реализовано следующим образом: для каждого из шести отведений модель формировала вектор вероятностей принадлежности к каждому из классов. Затем эти вероятности усреднялись с учетом весов отведений, определенных ранее. Итоговый прогноз по пациенту определялся как класс с максимальной суммарной взвешенной вероятностью. Например, если для некоторого пациента отведения I, II и III присвоили наивысшую вероятность классу A, aVR, aVL и aVF – классу B, то итоговый класс определялся на основе суммы произведений весов и вероятностей:

$$score_A = \sum_{i \in \{I, II, III\}} w_i \cdot P_i(A),$$

$$score_B = \sum_{j \in \{aVR, aVL, aVF\}} w_j \cdot P_j(B),$$

Предсказание присваивалось тому классу, для которого итоговый балл был максимальным.

Такой подход обеспечил объединение информации из всех отведений, учитывая различия в их диагностической значимости, что способствовало более точной классификации.

Оценка архитектуры включала анализ точности модели на основе ключевых метрик классификации: accuracy, precision, recall, specificity, F1-score, ROC-AUC и PR-AUC [21]. При этом для оценки применялась взвешенная средняя метрика, которая учитывает величины по всем классам с поправкой на преваленс дифференцируемых состояний в целевой популяции, обеспечивая единое глобальное значение. Для оценки статистической достоверности полученных метрик классификации были рассчитаны 95% доверительные интервалы методом бутстрепа с 1000 повторениями.

РЕЗУЛЬТАТЫ

Для оценки эффективности разработанной архитектуры сверточной нейронной сети была проведена серия экспериментов на тестовой выборке, включающей 6914 записей ЭКГ, соответствующих критериям включения.

На рисунке 3 изображена динамика метрик качества классификации для тестовой выборки в процессе обучения модели по 30 эпохам, визуализация выполнена с использованием библиотеки matplotlib 3.10.0.

В процессе обучения наблюдалось устойчивое увеличение значений метрик, отражающее улучшение качества классификации. К 30-й эпохе наблюдается стабилизация значений метрик, что свидетельствует о завершении фазы активного обучения и достижении устойчивого качества модели. Дополнительные эпохи не приводили к значимому улучшению, подтверждая оптимальность выбранного числа

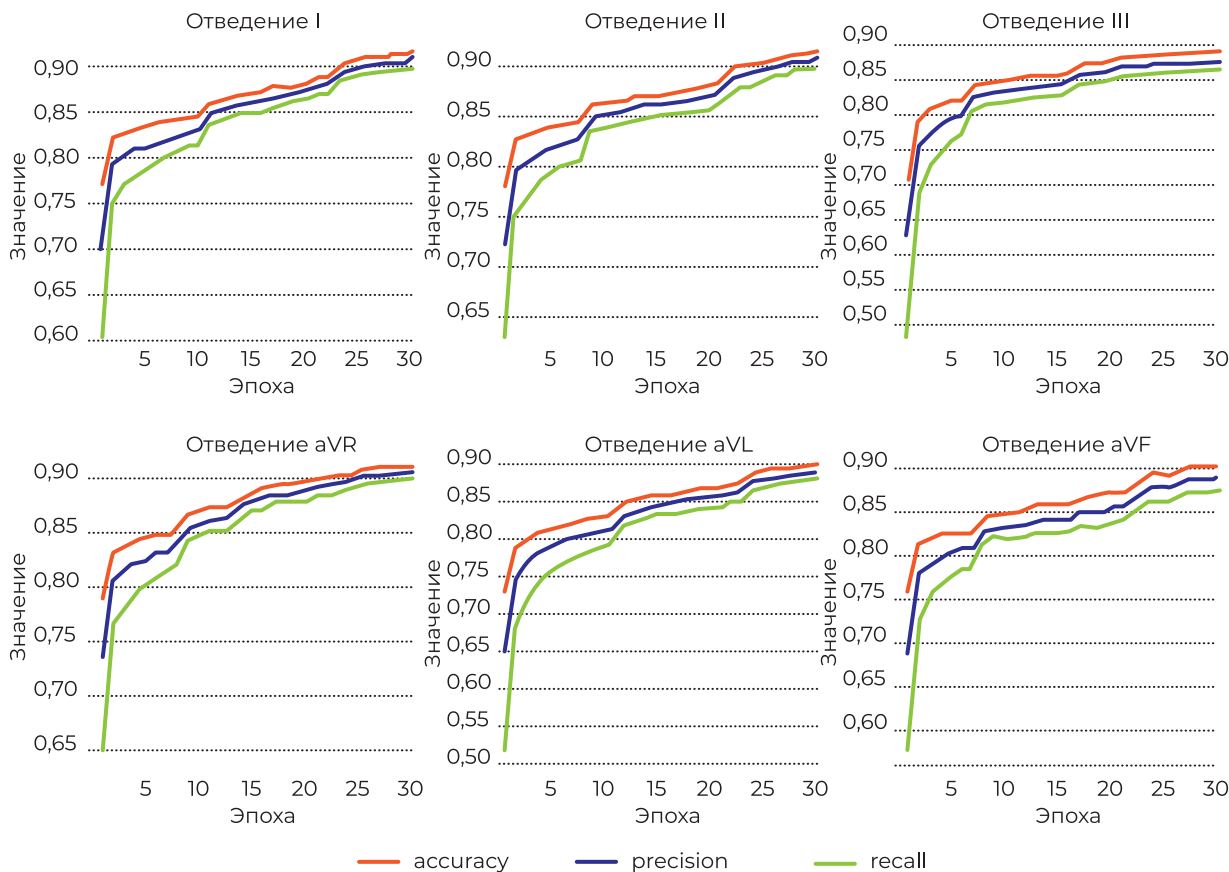


Рисунок 3 — Значения метрик для каждого отведения в зависимости от эпох обучения.

итераций. Модель достигает сбалансированных и высоких значений accuracy, precision и recall на финальных эпохах. Это подтверждает, что выбранная архитектура и параметры обучения обеспечивают эффективное решение диагностической задачи.

На рисунке 4 изображена динамика функции потерь в процессе обучения модели на 30 эпохах.

Функция потерь монотонно снижалась на всех отведениях, указывая на стабильную сходимость. На начальных этапах наблюдалось наиболее интенсивное снижение, соответствующее фазе активного обучения. Затем снижение замедлялось, указывая на приближение к минимуму функции потерь и стабилизацию обучения. Динамика функции потерь указывает на

успешное обучение модели и достаточную стабильность процесса оптимизации на всех отведениях.

В таблице 2 продемонстрированы значения метрик качества прогноза для тестовой выборки моделей каждого отведения, а также комбинации моделей в результате взвешенного голосования. Метрики рассчитаны с 95% доверительными интервалами. Для вычисления показателей использовалась библиотека sklearn 1.6.0.

Полученные результаты демонстрируют высокую точность, стабильность и воспроизводимость классификации, подтверждая потенциал предложенной модели для применения в автоматизированной диагностике сердечно-сосудистых заболеваний.

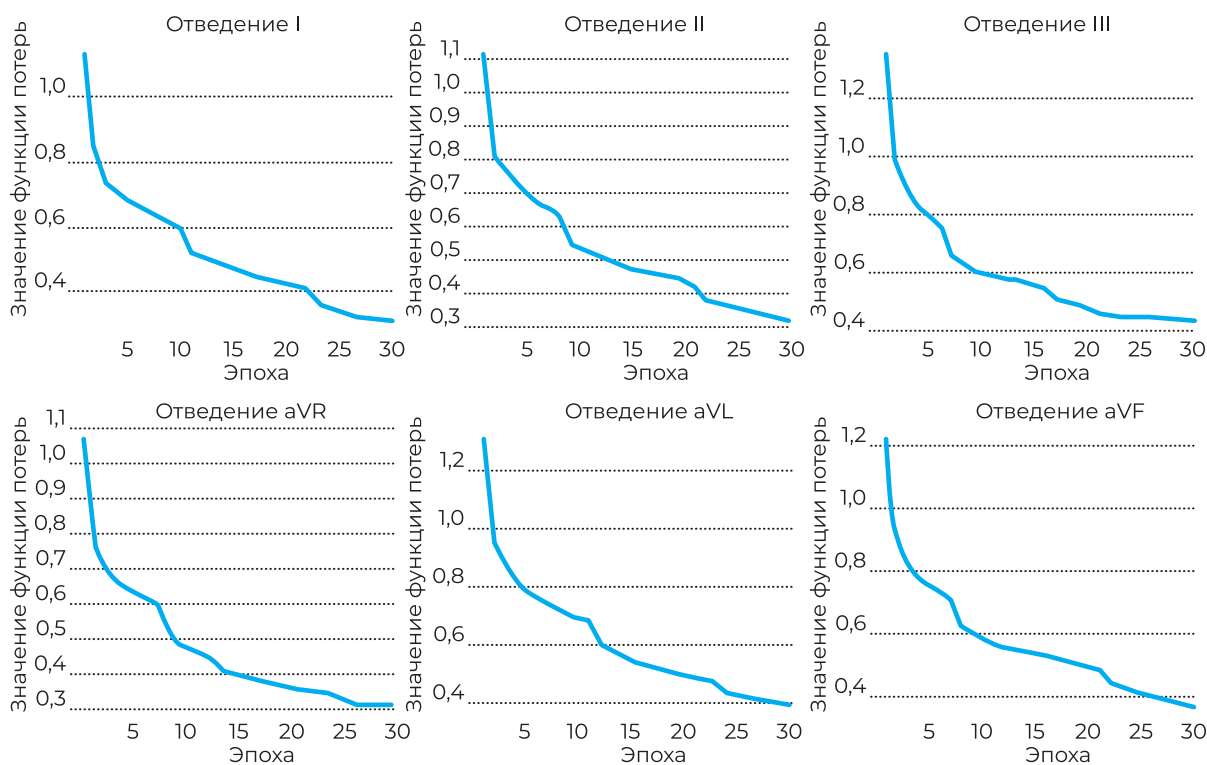


Рисунок 4 — Значения функции потерь для каждого отведения в зависимости от эпох обучения.

Таблица 2 — Значения метрик с 95% ДИ для моделей каждого отведения и их комбинации

Отведение	accuracy	precision	recall	specificity	F1-score	roc-auc	pr-auc
I	0,96 (0,95-0,97)	0,97 (0,96-0,98)	0,97 (0,96-0,98)	0,94 (0,92-0,96)	0,97 (0,96-0,98)	0,99 (0,98-1,00)	0,94 (0,92-0,96)
II	0,96 (0,95-0,97)	0,97 (0,96-0,98)	0,97 (0,96-0,98)	0,93 (0,91-0,95)	0,97 (0,96-0,98)	0,99 (0,98-1,00)	0,94 (0,92-0,96)
III	0,96 (0,95-0,97)	0,97 (0,96-0,98)	0,97 (0,96-0,98)	0,92 (0,90-0,94)	0,97 (0,96-0,98)	0,98 (0,97-0,99)	0,91 (0,89-0,93)
aVR	0,96 (0,95-0,97)	0,98 (0,97-0,99)	0,97 (0,96-0,98)	0,94 (0,92-0,96)	0,97 (0,96-0,98)	0,99 (0,98-1,00)	0,94 (0,92-0,96)
aVL	0,96 (0,95-0,97)	0,97 (0,96-0,98)	0,97 (0,96-0,98)	0,93 (0,91-0,95)	0,97 (0,96-0,98)	0,98 (0,97-0,99)	0,92 (0,90-0,94)
aVF	0,96 (0,95-0,97)	0,97 (0,96-0,98)	0,97 (0,96-0,98)	0,92 (0,90-0,94)	0,97 (0,96-0,98)	0,98 (0,97-0,99)	0,92 (0,90-0,94)
Комбинация	0,97 (0,96-0,98)	0,98 (0,97-0,99)	0,98 (0,97-0,99)	0,94 (0,92-0,96)	0,98 (0,97-0,99)	0,99 (0,98-1,00)	0,96 (0,94-0,97)

ОБСУЖДЕНИЕ

В настоящем исследовании разработана архитектура нейронной сети для автоматизированного анализа ЭКГ с использованием шести стандартных отведений (I, II, III, aVR, aVL, aVF). Существенным преимуществом предложенного подхода является использование метода взвешенного голосования, позволяющего учитывать диагностическую значимость каждого отведения и повышать точность и надежность классификации.

Исследование выполнено в формате диагностической модели оценки на ранее собранных ретроспективных и анонимизированных записях ЭКГ. Неблагоприятные события не наблюдались. Пропущенные значения в исходных данных отсутствовали. Дизайн исследования исключал контакт с пациентами и не требовал вмешательства в клинический процесс.

Достигнутые результаты превосходят показатели современных исследований, особенно в задачах многоклассовой классификации.

Согласно метаанализу Xie C., Wang Z., Yang C. и др., среднее значение показателя recall алгоритмов машинного обучения для выявления фибрилляции предсердий составило 0,97 (95% ДИ: 0,94–0,99), что ниже наших результатов и без учета многоклассовых метрик [22]. Метод, предложенный Fiorina L., Chemaly P., Cellier J. и др., использовал алгоритм глубокого обучения для анализа ЭКГ с носимых мониторов сердечного ритма и показал чувствительность 0,91 (95% ДИ: 0,85–0,95) и специфичность 0,95 (95% ДИ: 0,91–0,97), что уступает нашей модели [23]. Модель, представленная Hygrel T., Viberg F., Dahlberg E. и др., достигла ROC-AUC 0,80 (95% ДИ: 0,78–0,83) при предсказании пароксизмальной фибрилляции предсердий на основе одноканального ЭКГ, что заметно ниже нашей оценки [24]. В исследовании Barker J., Li X., Kotb A. и др. была предложена модель VA-ResNet-50 для стратификации риска желудочковых аритмий, показавшая accuracy 0,76 (95% ДИ: 0,66–0,87) и F1-score 0,79 (95% ДИ: 0,67–0,90), что значительно ниже наших результатов по ключевым метрикам [25]. Gruwez H., Barthels M., Haemers P. и др. валидировали ИИ-модель для обнаружения скрытой пароксизмальной фибрилляции предсердий на синусовом ЭКГ, достигнув accuracy 0,78 (95% ДИ: 0,78–0,79), ROC-AUC 0,87 (95% ДИ:

0,86–0,87) и PR-AUC 0,48 (95% ДИ: 0,46–0,50), что также существенно уступает нашей модели [26]. Наконец, в работе Gadaleta M., Harrington, Barnhill E. и др. модель глубокого обучения, обученная на ЭКГ без аритмий, предсказывала близкий эпизод фибрилляции предсердий с ROC-AUC 0,80 (95% ДИ: 0,79–0,81), что демонстрирует лишь умеренную дискриминацию относительно предложенного решения [27].

Таким образом, наша модель достигает более высоких значений по ключевым метрикам, чем большинство существующих решений, подтверждая надежность полученных оценок. Это достигается за счет использования клинически релевантных входных данных и демонстрации стабильности результатов в пределах доверительных интервалов.

Однако модель имеет ограничения. Она обучена на данных 6 стандартных отведений с частотой дискретизации 50 Гц, и ее эффективность на других частотах и другом количестве каналов требует проверки. Также модель не учитывает клинические или демографические данные пациента, что может ограничивать персонализированность предсказаний.

Практическая применимость модели заключается в возможности ее применения в клинической практике для автоматизированной диагностики, а также в использовании в портативных устройствах для домашнего мониторинга. Ожидается, что такая интеграция ускорит диагностику и уменьшит нагрузку на врачей.

В заключение, предложенный подход демонстрирует высокий потенциал для автоматизированного анализа ЭКГ, но требует дальнейших исследований для устранения ограничений и улучшения обобщаемости.

ЗАКЛЮЧЕНИЕ

В данной работе разработана и протестирована архитектура нейронной сети для анализа сигналов ЭКГ из шести стандартных отведений (I, II, III, aVR, aVL, aVF). Для повышения качества данных предобработка включала удаление полиномиального тренда, вейвлет-фильтрацию, медианную фильтрацию, сглаживание и нормализацию. Индивидуальная обработка данных каждого отведения и их последующее объединение методом взвешенного голосования позволили достичь высокой точности классификации

– accuracy: 0,97 (95% ДИ 0,96-0,98), precision: 0,98 (95% ДИ 0,97-0,99), recall: 0,98 (95% ДИ 0,97-0,99), specificity: 0,94 (95% ДИ 0,92-0,96), F1-score: 0,98 (95% ДИ 0,97-0,99), ROC-AUC: 0,99 (95% ДИ 0,98-1,00), PR-AUC: 0,96 (95% ДИ 0,94-0,97).

Результаты демонстрируют высокую диагностическую точность модели при автоматизированном анализе ЭКГ, что открывает перспективы ее применения в кардиологической практике. Методика обладает потенциалом масштабирования и может быть адаптирована для

классификации более широкого круга кардиологических патологий.

Разработка ориентирована на применение в популяции взрослых пациентов с подозрением на аритмии в условиях амбулаторного и стационарного наблюдения. Модель может быть интегрирована в клинические информационные системы, использована в телемедицинских решениях и системах длительного мониторинга (например, носимых устройствах), выступая в роли инструмента поддержки принятия врачебных решений.

ЛИТЕРАТУРА/REFERENCES

1. Zhang C, Li J, Guo P, et al. A configurable hardware-efficient ECG classification inference engine based on CNN for mobile healthcare applications. *Microelectronics Journal*. 2023; 141: 105969. doi: 10.1016/j.mejo.2023.105969.
2. Шутов Д.В., Дроздов Д.В., Газашвили Т.М. и др. Методические и нормативные аспекты создания набора данных ЭКГ для тестирования автоматизированных алгоритмов и систем искусственного интеллекта // *Врач и информационные технологии*. – 2021. – №4. – С. 4-15. [Shutov DV, Drozdov DV, Gazashvili TM, et al. Methodology and regulatory implications of ECG database formation for testing automated algorithms and AI systems. *Medical doctor and information technology*. 2021; 4: 4-15. (In Russ.)] doi: 1025881/18110193_2021_4_4.
3. Zhang Y, Liu S, He Z, et al. A CNN Model for Cardiac Arrhythmias Classification Based on Individual ECG Signals. *Cardiovasc Eng Technol*. 2022; 13(4): 548-447. doi: 10.1007/s13239-021-00599-8.
4. Cheng J, Zou Q, Zhao Y. ECG signal classification based on deep CNN and BiLSTM. *BMC Med Inform Decis Mak*. 2021; 21: 365. doi: 10.1186/s12911-021-01736-y.
5. Maweu BM, Dakshit S, Shamsuddin R, et al. CEFES: A CNN Explainable Framework for ECG Signals. *Artif Intell Med*. 2021; 115: 102059. doi: 10.1016/j.artmed.2021.102059.
6. Андриков Д.А., Курбанов С.В. Алгоритмическое обеспечение спектральной обработки кардиограмм // *Вестник Российского университета дружбы народов. Серия: Инженерные исследования*. – 2024. – Т.25. – №2. – С. 111-120. [Andrikov DA, Kurbanov SV. Algorithmic support for spectral processing of cardiograms. *RUDN Journal of Engineering Research*. 2024; 25(2): 111-120. (In Russ.)] doi: 10.22363/2312-8143-2024-25-2-111-120.
7. Павлов А.Н., Руннова А.Е., Храмов А.Е. Частотно-временной анализ нестационарных процессов: концепции вейвлетов и эмпирических мод // *Известия вузов. ПНД*. – 2011. – Т.19. – №2. – С.141-157. [Pavlov AN, Filatova AE, Hramov AE. Time-frequency analysis of nonstationary processes: concepts of wavelets and empirical modes. *Izvestiya vuzov. PND*. 2011; 19(2): 141-157. (In Russ.)] doi: 10.18500/0869-6632-2011-19-2-141-157.
8. Kaggle. Shaoxing and Ningbo Hospital ECG Database. Available at: <https://www.kaggle.com/datasets/bjoernjostein/shaoxing-and-ningbo-first-hospital-database>. Accessed January 2, 2025.
9. Kaggle. PTB-XL ECG dataset. Available at: <https://www.kaggle.com/datasets/khyeh0719/ptb-xl-dataset>. Accessed January 2, 2025.
10. Kaggle. Georgia 12-Lead ECG Challenge Database. Available at: <https://www.kaggle.com/datasets/bjoernjostein/georgia-12lead-ecg-challenge-database>. Accessed January 2, 2025.
11. Kaggle. China Physiological Signal Challenge in 2018. Available at: <https://www.kaggle.com/datasets/bjoernjostein/china-physiological-signal-challenge-in-2018>. Accessed January 2, 2025.
12. Kaggle. China 12-Lead ECG Challenge Database. Available at: <https://www.kaggle.com/datasets/bjoernjostein/china-12lead-ecg-challenge-database>. Accessed January 2, 2025.
13. Safdar M, Nowak R, Palka P. Pre-Processing techniques and artificial intelligence algorithms for electrocardiogram (ECG) signals analysis: A comprehensive review. *Computers in Biology and Medicine*. 2024; 170: 107908. doi: 10.1016/j.combiomed.2023.107908.

14. Lin M., Hong Y., Hong S., et al. Discrete Wavelet Transform based ECG classification using gcForest: A deep ensemble method. *Technol Health Care*. 2024; 32(S1): 95-105. doi: 10.3233/thc-248008.
15. Pal A, Rai H, Agarwal S, et al. Advanced Noise-Resistant Electrocardiography Classification Using Hybrid Wavelet-Median Denoising and a Convolutional Neural Network. *Sensors*. 2024; 24(21): 7033. doi: 10.3390/s24217033.
16. Mokhtari R, Belhaouari S, Kassoul K, et al. ECG Heartbeat classification using Progressive Moving Average Transform. *Research Square*. 2024; 10: 21203. doi: 10.1038/s41598-025-88119-9.
17. Yousuf A, Hafiz R, Riaz S, et al. Inferior Myocardial Infarction Detection from lead II of ECG: A Gramian Angular Field-based 2D-CNN Approach. *Electrical Engineering and Systems Science*. 2024; 2302: 13011. doi: 10.1109/lsens.2024.3450176.
18. Narotamo H, Dias M, Santos R, et al. Deep learning for ECG classification: A comparative study of 1D and 2D representations and multimodal fusion approaches. *Biomedical Signal Processing and Control*. 2024; 93: 106141. doi: 10.2139/ssrn.4555989.
19. Guo K, Wang S, Ma L, et al. ECG signals' detection using a Dropout Deep Convolutional Neural Network. *Research Square*. 2022; 10: 21203. doi: 10.21203/rs.3.rs-1591115/v1.
20. Liu C, Wan Z, Ouyang C, et al. Zero-Shot ECG Classification with Multimodal Learning and Test-time Clinical Knowledge Enhancement. *Electrical Engineering and Systems Science*. 2024; 2403: 06659. doi: 10.48550/arXiv.2403.06659.
21. Ebrahimi Z, Loni M, Daneshlab M, et al. A review on deep learning methods for ECG arrhythmia classification. *Expert Systems with Applications: X*. 2020; 7: 100033. doi: 10.1016/j.eswax.2020.100033.
22. Xie C, Wang Z, Yang C, et al. Machine Learning for Detecting Atrial Fibrillation from ECGs: Systematic Review and Meta-Analysis. *Rev Cardiovasc Med*. 2024; 25(1): 8. doi: 10.31083/j.rcm2501008.
23. Fiorina L, Chemaly P, Cellier J, et al. Artificial intelligence-based electrocardiogram analysis improves atrial arrhythmia detection from a smartwatch electrocardiogram. *Eur Heart J Digit Health*. 2024; 5(5): 535-541. doi: 10.1093/ehjdh/ztae047.
24. Hygrell T, Viberg F, Dahlberg E, et al. An artificial intelligence-based model for prediction of atrial fibrillation from single-lead sinus rhythm electrocardiograms facilitating screening. *EP Europace*. 25(4): 1332-1338. doi: 10.1093/europace/euad036.
25. Barker J, Li X, Kotb A, et al. Artificial intelligence for ventricular arrhythmia capability using ambulatory electrocardiograms. *European Heart Journal – Digital Health*. 5(3): 384-388. doi: 10.1093/ehjdh/ztae004.
26. Gruwez H, Barthels M, Haemers P, et al. Detecting Paroxysmal Atrial Fibrillation From an Electrocardiogram in Sinus Rhythm: External Validation of the AI Approach. *JACC: Clinical Electrophysiology*. 9(8): 1771-1782. doi: 10.1016/j.jacep.2023.04.008.
27. Gadaleta M, Harrington, Barnhill E, et al. Prediction of atrial fibrillation from at-home single-lead ECG signals without arrhythmias. *npj Digit. Med*. 6: 229. doi: 10.1038/s41746-023-00966-w.