

СВЕРТОЧНАЯ НЕЙРОННАЯ СЕТЬ ДЛЯ КЛАССИФИКАЦИИ ЭЛЕКТРОКАРДИОСИГНАЛОВ

Л. Ю. Кривоногов¹, С. Ф. Левин²,
И. С. Иномбоев³, Д. В. Папшев⁴

^{1, 2, 3, 4} Пензенский государственный университет, Пенза, Россия

¹leonidkrivonogov@yandex.ru, ²lvln.stanislav.01@mail.ru,

³ilhomdzoninomboev@gmail.com, ⁴rover_d@mail.ru

Аннотация. *Актуальность и цели.* Рассматривается разработка нейросетевого классификатора электрокардиосигналов (ЭКС). Автоматическая классификация освобождает кардиологов от трудоемкой и однообразной работы, сокращает время интерпретации электрокардиограмм. Целью исследования является разработка и оценка качества модели сверточной нейронной сети для автоматической классификации ЭКС в 12 стандартных отведениях для выявления наиболее распространенных и опасных состояний сердечно-сосудистой системы. *Материалы и методы.* Выбраны и обоснованы группы заболеваний для классификации. Предложена оригинальная модификация архитектуры сверточной нейронной сети 1D ResNet34. В качестве данных для обучения и тестирования модели были использованы ЭКГ-записи из общедоступной китайской базы физиологических сигналов CPSC Database. Обучение и оценка качества модели были реализованы методом 10-кратной кросс-валидации. *Результаты.* Оценка качества классификации электрокардиосигналов была проведена при помощи стандартных метрик. Средние значения точности (accuracy), меры F1 и AUC-ROC разработанного классификатора составляют 0,964, 0,832 и 0,975 соответственно. *Выводы.* Качество классификации электрокардиосигналов разработанной моделью соответствует мировому уровню и практически не уступает врачебному. Разработанный классификатор может быть интегрирован в различные системы электрокардиографической диагностики.

Ключевые слова: электрокардиография, классификация электрокардиосигналов, глубокое обучение, сверточные нейронные сети

Финансирование: работа выполнена в рамках гранта Российского научного фонда № 24-25-00404 от 29.12.2023 (URL: <https://rscf.ru/project/24-25-00404>).

Для цитирования: Кривоногов Л. Ю., Левин С. Ф., Иномбоев И. С., Папшев Д. В. Сверточная нейронная сеть для классификации электрокардиосигналов // Модели, системы, сети в экономике, технике, природе и обществе. 2024. № 4. С. 108–121. doi: 10.21685/2227-8486-2024-4-9

A CONVOLUTIONAL NEURAL NETWORK FOR ECG SIGNALS CLASSIFICATION

L.Yu. Krivonogov¹, S.F. Levin²,
I.S. Inomboev³, D.V. Papshev⁴

^{1, 2, 3, 4} Penza State University, Penza, Russia

¹leonidkrivonogov@yandex.ru, ²lvln.stanislav.01@mail.ru,

³ilhomdzoninomboev@gmail.com, ⁴rover_d@mail.ru

Abstract. *Background.* The article is devoted to the development of a neural network for ECG signals classification. Automatic classification of ECG signals frees cardiologists from laborious and monotonous work and reduces the time of ECG interpretation. The aim of the study is to create and evaluate a convolutional neural network model for automatic ECG signals classification in 12 standard leads to identify the most common and dangerous cardiovascular diseases. *Materials and methods.* Groups of diseases for classification were selected and substantiated. An original, modified architecture of the 1D ResNet34 convolutional neural network was proposed. ECG recordings from the publicly available Chinese CPSC Database were used to train and test the model. The training and evaluation of the model's performance were carried out using the 10-fold cross-validation method. *Results.* The performance of ECG signal classification was evaluated using standard metrics. The average values of accuracy, F1 score, and AUC-ROC for the developed classifier are 0.964, 0.832, and 0.975, respectively. *Conclusions.* The performance of the model corresponds to the world level of the best global achievements and is comparable to the expert-medical level. The developed ECG signal classifier can be integrated into various electrocardiographic diagnostic systems.

Keywords: electrocardiography, ECG signal classification, deep learning, convolutional neural networks

Financing: the work was carried out within the framework of the Russian Science Foundation grant № 24-25-00404 dated December 29, 2023 (URL: <https://rscf.ru/project/24-25-00404>).

For citation: Krivonogov L.Yu., Levin S.F., Inomboev I.S., Papshev D.V. A convolutional neural network for ECG signals classification. *Modeli, sistemy, seti v ekonomike, tekhnike, prirode i obshchestve* = *Models, systems, networks in economics, technology, nature and society*. 2024;(4):108–121. (In Russ.). doi: 10.21685/2227-8486-2024-4-9

Введение

Электрокардиография – широко распространенный, недорогой и абсолютно безопасный метод исследования сердца, позволяющий выявлять целый ряд опасных и угрожающих жизни состояний. С середины прошлого века предпринимаются попытки автоматизации электрокардиографических исследований. В первую очередь исследователей интересовала автоматическая интерпретация (классификация, расшифровка, анализ) электрокардиосигналов (ЭКС). Эта проблема чрезвычайно сложная, в полной мере она не решена до сих пор. В ее основе лежит биологическая природа ЭКС. Исследуемые электрокардиосигналы отличаются значительным разнообразием, высокой изменчивостью, непредсказуемостью, отсутствием явных границ между отдельными элементами. Кроме того, при регистрации ЭКС неизбежно присутствуют помехи различного вида и происхождения, искажающие и маскирующие диагностические признаки [1].

Первые алгоритмы автоматической интерпретации ЭКС либо формализовывали опыт традиционного врачебного ЭКГ-исследования, либо решали достаточно простые статистические задачи. В 1970–1980-е гг. были разработаны достаточно эффективные алгоритмы автоматической интерпретации/классификации ЭКС на основе выделения амплитудно-временных и частотных признаков, продукционных правил и деревьев решений. Такие детерминированные «жесткие» алгоритмы не всегда способны достаточно достоверно классифицировать сигналы физиологического происхождения. Даже

небольшое повышение качества подобных алгоритмов требует многократного увеличения их вычислительной сложности.

Еще в середине 1970-х гг. были сформулированы основные цели автоматизации электрокардиографических исследований [2], которые остаются актуальными и сегодня:

- освобождение врачей от трудоемкой и рутинной работы: измерения амплитудно-временных параметров ЭКС, подсчета различных элементов и диагностических фактов, формирования синдромальных заключений;
- сокращение материальных затрат, повышение производительности труда медицинского персонала;
- сокращение времени расшифровки ЭКС;
- применение современных математических и статистических методов, в принципе не реализуемых при «ручном» исследовании;
- использование признаков, не применяемых при «ручном» исследовании ЭКС из-за трудоемкости и сложности расчетов, несмотря на их высокую информативность;
- освобождение процесса принятия решения от субъективизма в трактовке получаемых результатов;
- возможность создавать архивы, базы данных, передавать ЭКС и результаты анализа по различным каналам связи.

Единственным способом сделать достижения мирового уровня в области электрокардиографии достоянием практического здравоохранения является массовое применение программных средств автоматической интерпретации ЭКС. При этом программные интерпретаторы ЭКС должны иметь высокую достоверность – на уровне экспертной группы врачей-кардиологов.

В настоящее время для интерпретации/классификации ЭКС широко используются методы машинного обучения, позволяющие создавать гибкие и эффективные алгоритмы. Авторами статьи был проведен обзор научных публикаций (начиная с 2018 г.), посвященных разработке методов и моделей для классификации ЭКС с применением различных технологий машинного обучения. Анализ публикаций [3–15] позволил сравнить значения метрик качества классификации, полученных при реализации различных проектов, и определить:

- перспективные технологии машинного обучения, применяемые для классификации ЭКС;
- базы ЭКГ-данных, используемые для обучения;
- количество и номенклатуру сформированных классов;
- количество и состав ЭКГ-отведений;
- количество и длительность эпизодов для обучения.

Основные результаты обзора были сведены в табл. 1.

В таблице для каждого из проектов приведена информация о применяемых базах данных, количестве ЭКГ-эпизодов для обучения и количестве классов, используемых в технологиях машинного обучения, а также значения метрик качества классификации. Все это позволяет получить определенное представление о современном уровне исследований в области автоматической классификации ЭКС.

Таблица 1

Основные технические решения и значения метрик качества автоматической классификации ЭКС

Авторы, год публикации, ссылка на источник	База данных/ Количество ЭКГ-эпизодов/ Количество классов	Используемые технологии	Значения метрик качества классификации				F1 Score
			Accuracy	Precision	Specificity	Sensitivity/ Recall	
Sannino G., De Pietro G., 2018 [3]	[16]/4576/2	DNN	0,99	–	0,986	0,995	–
Mena L. J. [et al.], 2018 [4]	[16]/8000/2	FFNN	0,97	–	0,966	1,00	–
Качаева Г. И., Мустафаев А. Г., 2018 [5]	[16]/458/5	MLP	–	–	0,89	0,71	–
Raghunath S. [et al.], 2019 [6]	Авторская/ 1 775 926/30	DNN	0,68	–	0,64	0,88	–
Hannun A.Y. [et al.], 2019 [7]	Авторская/ 91 232/12	1D CNN	–	0,85	0,97	0,83	0,83
Москаленко В. А. [и др.], 2019 [8]	Авторская/1652/9	SVM, DTC	0,629...0,951	–	0,629...0,951	0,667...1	0,81
Tseng L. [et al.], 2020 [9]	[16]/81/8	CWT, 2D CNN	0,97	–	–	0,99	–
Zhao Y. [et al.], 2020 [10]	[16]/8528/4	CWT, 2D CNN	0,871	–	–	–	0,865
Wu M. [et al.], 2021 [11]	[16]/48/5	1D CNN	0,97	0,97	0,99	0,97	–
Солиман Х., Сали С., 2023 [12]	[16]/549/9	CWT, 2D CNN (AlexNET)	0,837	0,727	–	–	0,71
Zhou F., Fang D., 2024 [13]	[16]/48/5	2D CNN	0,996	–	0,91	–	0,92
Eleyan A., Alboghbaish E., 2024 [14]	[16]/11790/5	FFT, CNN	0,976	–	–	–	–
Zhou F, Wang J. [et al.], 2024 [15]	[16]/1400/5	STFT, CNN	0,995	–	0,999	0,992	–

В подавляющем большинстве проектов применялись нейронные сети глубокого обучения (Deep Neural Network, DNN) и чаще всего сверточные нейронные сети (Convolutional Neural Networks, CNN), которые показали достаточно высокое качество классификации. Лишь в некоторых работах использованы другие технологии машинного обучения: нейронные сети прямого распространения (Feed-Forward Neural Network, FFNN), многослойный персептрон (MultiLayer Perceptron, MLP), метод опорных векторов (Support Vector Machine, SVM), классификация на основе дерева решений (Decision Tree Classifiers, DTC). В исследованиях [9, 10, 12, 14, 15] ЭКС с помощью преобразований Фурье (Fast Fourier Transform, FFT; Short-Time Fourier Transform, STFT) или непрерывного вейвлет-преобразования (Continuous Wavelet Transform, CWT) трансформируются в изображения, которые затем классифицируются сверточной нейронной сетью. Эффективность подобного подхода трудно оценить из-за многообразия и неоднозначности выбора вариантов преобразования сигналов в изображения. Кроме того, такое преобразование значительно увеличивает вычислительные затраты.

CNN – это разновидность глубоких многослойных нейронных сетей прямого распространения, наиболее эффективных для распознавания изображений. Основой таких сетей являются сверточные слои, обеспечивающие извлечение признаков из входных данных за счет операции свертки (конволюции) с множеством ядер различных фильтров. Кроме сверточных слоев CNN содержит слои объединения (pooling), уменьшающие размерность данных при сохранении важных признаков, и полностью связанные слои, обеспечивающие классификацию на основе извлеченных признаков.

1D CNN предназначены для обработки одномерных данных и способны автоматически извлекать признаки из сложных сигналов, таких как ЭКС. Они имеют модифицируемую архитектуру, которую можно настраивать под конкретные задачи и типы входных данных. Для обучения 1D CNN требуется большой объем качественно размеченных сигналов.

Целями исследования являются разработка и оценка качества модели сверточной нейронной сети для автоматической классификации 30-секундных записей ЭКС в 12 стандартных отведениях для выявления наиболее распространенных и опасных состояний сердечно-сосудистой системы.

Выбор и обоснование классов

Среди сердечно-сосудистых заболеваний широкое распространение имеет ишемическая болезнь сердца, а также различные нарушения сердечного ритма и проводимости [17, 18]. Данные группы заболеваний составляют более четверти всех госпитализаций кардиологических отделений и возникают не только у людей с патологиями, но и у большинства здоровых людей с тенденцией к развитию острых процессов. Именно они существенно повышают риск сердечно-сосудистых осложнений, вплоть до внезапной смерти, приводят к снижению качества жизни и инвалидности [17, 19].

На основании проведенного обзора и статистических данных, приведенных в [17–19], для реализации сверточной нейронной сети были выбраны девять классов: депрессия/элевация ST-сегмента (STD/STE), фибрилляция предсердий (AF), атриовентрикулярная блокада 1-й степени (I-AVB), блокады

левой/правой ножки пучка Гиса (LBBB/RBBB), преждевременное сокращение предсердий/желудочков (PAC/PVC) и нормальный синусовый ритм (NSR).

Разработка архитектуры нейронной сети для классификации ЭКС

Архитектура нейросетевого классификатора ЭКС была реализована как модификация архитектуры 1D ResNet34, которая является разновидностью сети ResNet, адаптированной для работы с одномерными данными [20].

Основой архитектуры ResNet (Residual Network) являются «остаточные» блоки (residual blocks), обеспечивающие обходное соединение быстрого доступа (identity shortcut connection) между входом и выходом слоя, что позволяет сети преодолевать проблему исчезающих градиентов при обучении методом обратного распространения ошибки. Соединение быстрого доступа не усложняет архитектуру сети и позволяет обучать чрезвычайно глубокие сети. Таким образом, архитектура ResNet позволяет относительно легко повышать качество классификации за счет увеличения глубины (количества слоев) [20].

При разработке нейросетевого классификатора ЭКС модель 1D ResNet34 была усовершенствована следующим образом (рис. 1).




Рис. 1. Архитектура нейросетевого классификатора ЭКС

При сохранении количества слоев (34) был изменен порядок входных сверточных (Conv1d) и субдискретизирующих (Max Pool) слоев. До перехода

сигнала в остаточный блок (Residual Block) чередующиеся восемь слоев урезаны до четырех и теперь включают в себя последовательно располагающиеся слои: сверточный (Conv1d), пакетной нормализации (BatchNorm1d), линейной активации (ReLU) и субдискретизирующий (Max Pool). Для извлечения значимых признаков и максимизации общей эффективности модели во время обучения принято решение использовать четыре семислойных остаточных блока с соединениями быстрого доступа.

В итоге остаточные блоки (Residual Blocks) содержат восемь сверточных слоев (Conv1d), восемь слоев пакетной нормализации (BatchNorm1d), четыре слоя Dropout (функции предотвращения переобучения) и восемь слоев ReLU (нелинейной функции активации).

После прохождения через остаточные блоки извлеченные признаки объединяются (процесс адаптивного максимального объединения) для выделения наиболее важной информации. Объединенные результаты передаются на полносвязный выходной слой (Dense) и сигмоидную функцию активации (Sigmoid).

На вход классификатора подаются 30-секундные записи ЭКС с частотой дискретизации 500 отс/с в 12 отведениях ($30 \times 500 \times 12 = 180\,000$ отсчетов), результат классификации – выбор одного из девяти классов.

Описание используемых данных для обучения и тестирования

В качестве данных для обучения и тестирования моделей машинного обучения для классификации ЭКС [3–15] чаще всего используют ЭКГ-записи различных баз данных ресурса PhysioNet [16]: Normal Sinus Rhythm RR Interval Database, MIT-BIH Arrhythmia Database, PTB Diagnostic ECG Database, Sudden Cardiac Death Holter Database и др. Их применение при создании классификатора ЭКС нецелесообразно по следующим причинам. Базы данных ресурса PhysioNet созданы в разное время (с 1970-х гг. по настоящее время), содержат ЭКГ-записи, зарегистрированные в разном количестве отведений (2, 12, 15) и оцифрованные с различными параметрами (частота дискретизации от 128 до 1000 отс/с, 11–16 разрядов квантования). Каждая из этих баз данных содержит десятки, реже сотни ЭКГ-записей, а для эффективного обучения CNN нужны тысячи обучающих примеров, поэтому одной базы данных явно недостаточно, а объединение нескольких разноформатных баз не всегда корректно.

На сегодняшний день при создании проектов в области классификации ЭКС целесообразно использовать общедоступные ЭКГ-данные различных конкурсных интернет-платформ по исследованию данных. Примерами таких онлайн-платформ являются kaggle.com от Google [21] и The China Physiological Signal Challenge (CPSC) 2018 [22]. Для обучения и тестирования разрабатываемой модели были использованы ЭКГ-записи базы физиологических сигналов CPSC Database, созданной в рамках проведения первого китайского конкурса по анализу физиологических сигналов. CPSC Database – база с открытым исходным кодом, что позволяет использовать ее для создания различных проектов в области автоматической классификации ЭКС. CPSC Database содержит 9831 ЭКГ-записей в 12 отведениях от 9458 пациентов (4655 женщин и 5176 мужчин). Частота дискретизации записей ЭКГ составляет 500 отс/с, длительность – от 6 до 60 с. Все данные представлены в формате .mat, с полной аннотацией и временными метками. Классы по аннотации соответствуют ранее

выбранным классам. Все записи были предварительно нормализованы для обеспечения стабильности работы модели.

Обучение модели

Обучение и оценка качества модели были реализованы методом 10-кратной кросс-валидации [23], который обеспечивает учет вариабельности данных и предотвращает переобучение модели. ЭКС базы CPSC были случайным образом разделены на десять приблизительно равных непересекающихся частей. В каждом раунде восемь из десяти частей использовались для обучения, одна часть – для валидации и одна часть – для тестирования. Метрики качества классификации рассчитывались для каждого из десяти раундов, а затем усреднялись. Подобный подход позволил получить более достоверную оценку качества модели [23].

Пороговые значения для каждого класса выбирались исходя из максимального значения меры F1, тем самым обеспечивая сбалансированное уменьшение ложноотрицательных и ложноположительных ошибок классификации. Обучение классификатора было остановлено на 39-й эпохе.

Конфигурация компьютера, использованного для создания и обучения модели:

- процессор Intel Core i3-10100 (4 ядра, 8 потоков, базовая частота 3,6 ГГц, максимальная частота до 4,3 ГГц);
- видеокарта NVIDIA GeForce GTX 1050 Ti (2 ГБ GDDR5);
- оперативная память 8 ГБ DDR4 (2666 МГц);
- HDD 500 ГБ;
- операционная система Windows 10.

Для ускорения обучения использовался графический процессор GPU. Разработка и обучение модели были реализованы в среде разработки Visual Studio Code (VSCode), которая предоставляет удобные инструменты для работы с кодом и обеспечивает интеграцию с различными библиотеками (включая TensorFlow и PyTorch) и фреймворками. VSCode поддерживает расширения для Python, что значительно упрощает работу с библиотеками для глубокого обучения, а также предоставляет возможности для отладки, автодополнения и организации рабочего процесса. Для создания и управления изолированными виртуальными средами использованы средства пакета Miniconda.

Результаты и обсуждение

Качество разработанной нейросетевой модели для классификации ЭКС было оценено посредством матриц ошибок (рис. 2) и стандартных метрик качества [24] (Accuracy, Precision, Recall, F1-score, AUC-ROC) по каждому из девяти классов. Кроме того, были получены усредненные по классам значения метрик (табл. 2).

Средние значения метрик AUC-ROC и Accuracy разработанного классификатора ЭКС превысили 0,96, а среднее значение меры F1 составило 0,832. Мера F1 является важнейшей метрикой в задачах классификации, когда необходим баланс между Precision и Recall (т.е. одинаково важно минимизировать ложноотрицательные и ложноположительные ошибки классификации). Мера F1 является средним гармоническим между Precision и Recall и традиционно

используется в качестве основной метрики при оценке качества классификации медицинских диагностических моделей.




Рис. 2. Матрицы ошибок по каждому из классов

Таблица 2

Метрики качества классификации ЭКС

Класс	Accuracy	Precision	Recall	F1-score	AUC-ROC
SNR	0,937	0,718	0,841	0,775	0,968
AF	0,978	0,914	0,941	0,928	0,991
IAVB	0,974	0,932	0,841	0,885	0,978
LBBB	0,993	0,917	0,880	0,898	0,975
RBBB	0,955	0,889	0,959	0,923	0,985
PAC	0,945	0,699	0,761	0,729	0,962
PVC	0,965	0,819	0,843	0,831	0,980
STD	0,949	0,848	0,744	0,793	0,963
STE	0,984	0,789	0,682	0,732	0,980
Усредненное по классам	0,964	0,836	0,832	0,832	0,975

Разработанная модель показала наилучшие результаты в классификации фибрилляции предсердий (класс AF) и блокады правой ножки пучка Гиса (класс RBBB) со значением меры F1 более 0,9. Однако значение меры F1 для классов STE и STD (элевация и депрессия сегмента ST) недостаточно высоко и составляет 0,732 и 0,793 соответственно. Кроме того, у модели возникают некоторые проблемы с классификацией PAC (преждевременное сокращение предсердий) и SNR (нормальный синусовый ритм). Эти же выводы можно сделать при изучении матриц ошибок для классов SNR, PAC, STD и STE, на которых видны достаточно большие значения ложноотрицательных результатов. Такие ошибки могут быть связаны с различиями в диагностике (и, соответственно, в разметке) этих классов врачами разных больниц.

Заключение

Сравнение разработанной модели с результатами других исследований в этой области демонстрирует высокое качество классификации ЭКС – на уровне лучших достижений. Если же сопоставлять проекты, обученные на одинаковых данных, то показательным будет сравнение с результатами участников конкурса China Physiological Signal Challenge 2018 [22]. Лишь один проект, занявший первое место, превышает разработанную модель по значению усредненной меры $F1 = 0,837$.

Исходя из различных метрик качества врачебной ЭКГ-диагностики, приведенных в статьях [7, 8], можно говорить о том, что качество классификации ЭКС разработанной моделью сопоставимо с врачебным (во всяком случае, по некоторым классам). При этом время классификации 30-секундной записи ЭКГ в 12 отведениях составляет менее 1 секунды, что значительно превышает способности любого врача-кардиолога.

По результатам разработки сверточной нейронной сети для классификации ЭКС получено свидетельство о государственной регистрации программы для ЭВМ [25].

Созданный классификатор ЭКС может быть применен в системах автоматической диагностики сердечно-сосудистых патологий, анализирующих электрокардиограммах, АРМ врача-кардиолога, медицинских интернет-сервисах. Примером подобного интернет-кардиосервиса является веб-приложение CardioAI, в которое интегрирован созданный классификатор. Приложение CardioAI разработано авторами статьи и размещено по адресу cardioai.istj.su. Веб-приложение позволяет вводить данные о пациенте, загружать mat-файлы ЭКГ (длительностью 30 с в 12 отведениях, с частотой дискретизации 500 отс/с, объемом не более 5Мб), обеспечивает их классификацию и выдачу компьютерного заключения.

Список литературы

1. Кривоногов Л. Ю. Система электрокардиографической диагностики критических состояний в условиях свободной активности пациента : дис. ... д-ра. техн. наук. Пенза, 2017. 412 с.
2. Чирейкин Л. В., Шурыгин Д. Я., Лабути В. К. Автоматический анализ электрокардиограмм. Л. : Наука, 1977. 248 с.
3. Sannino G., De Pietro G. A deep learning approach for ECG-based heartbeat classification for arrhythmia detection // Future Generation Computer Systems. 2018. Vol. 86.

- P. 446–455. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0167739X17324548?via%3Dihub> (дата обращения: 12.08.2024).
4. Mena L. J., Félix V. G., Ochoa A. [et al]. Mobile personal health monitoring for automated classification of electrocardiogram signals in elderly // *Computational and Mathematical Methods in Medicine*. 2018. Vol. 2018. P. 1–9. URL: <https://www.hindawi.com/journals/cmmm/2018/9128054/> (дата обращения: 12.08.2024).
5. Качаева Г. И., Мустафаев А. Г. Использование нейросетевых методов для автоматического анализа электрокардиограмм при диагностике заболеваний сердечно-сосудистой системы // *Вестник Дагестанского государственного технического университета. Технические науки*. 2018. № 45 (2). С. 114–124.
6. Raghunath S., Cerna A. E. U., Jing L. [et al]. Deep neural networks can predict mortality from 12-lead electrocardiogram voltage data. doi: 10.48550/arXiv.1904.07032
7. Hannun A. Y., Rajpurkar P., Haghpanahi M. [et al]. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network // *Nature Medicine*. 2019. Vol. 25, № 1. P. 65–69.
8. Москаленко В. А., Никольский А.В., Золотых Н. Ю. [и др.] Программный комплекс «Киберсердце-диагностика» для автоматического анализа электрокардиограмм с применением методов машинного обучения // *Современные технологии в медицине*. 2019. Т. 11, № 2. С. 86–91.
9. Tseng L., Tseng V. Predicting Ventricular Fibrillation Through Deep Learning. 2020. Vol. 8. P. 20. URL: <https://ieeexplore.ieee.org/document/9284455> (дата обращения: 12.08.2024).
10. Zhao Y., Cheng J., Zhang P., Peng X. ECG Classification Using Deep CNN Improved by Wavelet Transform // *Computers, Materials & Continua*. 2020. Vol. 64, № 3. P. 1615–1628. doi: 10.32604/cmc.2020.09938
11. Wu M., Lu Y., Yang W. A Study on Arrhythmia via ECG Signal Classification Using the Convolutional Neural Network // *Front Comput. Neurosci*. 2021. Vol. 14. P. 10. URL: https://www.researchgate.net/publication/348249676_A_Study_on_Arrhythmia_via_ECG_Signal_Classification_Using_the_Convolutional_Neural_Network (дата обращения: 12.08.2024).
12. Солиман Х., Сали С. Классификация аритмий с использованием предварительно обученной модели глубокого обучения с бинарными изображениями сегментированной ЭКГ // *Известия вузов России. Радиоэлектроника*. 2023. Т. 26, № 2. С. 120–127.
13. Zhou F., Fang D. Multimodal ECG heartbeat classification method based on a convolutional neural network embedded with FCA // *Sci Rep*. 2024. Vol. 14. P. 8804. doi: 10.1038/s41598-024-59311-0
14. Eleyan A., Alboghbaish E. Electrocardiogram Signals Classification Using Deep-Learning-Based Incorporated Convolutional Neural Network and Long Short-Term Memory Framework // *Computers*. 2024. Vol. 13. С. 55. doi: 10.3390/computers13020055
15. Zhou F., Wang J. Heartbeat classification method combining multi-branch convolutional neural networks and transformer // *iScience*. 2024. Vol. 27. P. 109307. doi: 10.1016/j.isci.2024.109307
16. The Research Resource for Complex Physiologic Signals. URL: <https://physionet.org> (дата обращения: 12.08.2024).
17. Беленков Ю. Н., Терновой С. К. Функциональная диагностика сердечно-сосудистых заболеваний. М. : ГЭОТАР-Медиа, 2017. 976 с.
18. Моисеева В. С., Мартынова А. И., Мухина Н. А. Внутренние болезни : учебник : в 2 т. М. : ГЭОТАР-Медиа, 2012. Т. 1. 590 с.
19. Затонская Е. В., Матюшин Г. В., Гоголашвили Н. Г. [и др.]. Эпидемиология аритмий (обзор данных литературы) // *Сибирское медицинское обозрение*. 2016. № 3. С. 5–16.

20. He K., Zhang X., Ren S. [et al]. Deep Residual Learning for Image Recognition. doi: 10.48550/arXiv.1512.03385
21. Kaggle. URL: <https://www.kaggle.com>
22. The China Physiological Signal Challenge 2018. URL: <http://2018.icbeb.org/Challenge.html> (дата обращения: 25.06.2024).
23. Lyashenko V., Jha A. Cross-Validation in Machine Learning: How to Do It Right. URL: <https://neptune.ai/blog/author/vladimirlyashenko> (дата обращения: 12.08.2024).
24. Bajaj A. Performance Metrics in Machine Learning [Complete Guide]. URL: <https://neptune.ai/blog/performance-metrics-in-machine-learning-complete-guide> (дата обращения: 12.08.2024).
25. Свидетельство № 2046604262 о государственной регистрации программы для ЭВМ. Программа классификации электрокардиосигналов на основе сверточной нейронной сети / Кривоногов Л. Ю., Левин С. Ф., Иномбоев И. С. ; зарег. в реестре программ для ЭВМ 07.05.2024.

References

1. Krivonogov L.Yu. *The system of electrocardiographic diagnosis of critical conditions in conditions of free activity of the patient*. DSc dissertation. Penza, 2017:412. (In Russ.)
2. Chireykin L.V., Shurygin D.Ya., Labutin V.K. *Avtomaticheskiy analiz elektrokardiogram = Automatic analysis of electrocardiograms*. Leningrad: Nauka, 1977:248. (In Russ.)
3. Sannino G., De Pietro G. A deep learning approach for ECG-based heartbeat classification for arrhythmia detection. *Future Generation Computer Systems*. 2018;86:446–455. Available at: <https://www.sciencedirect.com/science/article/abs/pii/S0167739X17324548?via%3Dihub> (accessed 12.08.2024).
4. Mena L.J., Félix V.G., Ochoa A. et al. Mobile personal health monitoring for automated classification of electrocardiogram signals in elderly. *Computational and Mathematical Methods in Medicine*. 2018;2018:1–9. Available at: <https://www.hindawi.com/journals/cmmm/2018/9128054/> (accessed 12.08.2024).
5. Kachaeva G.I., Mustafaev A.G. The use of neural network methods for automatic analysis of electrocardiograms in the diagnosis of diseases of the cardiovascular system. *Vestnik Dagestanskogo gosudarstvennogo tekhnicheskogo universiteta. Tekhnicheskie nauki = Bulletin of Dagestan State Technical University. Technical sciences*. 2018;(45):114–124. (In Russ.)
6. Raghunath S., Cerna A.E.U., Jing L. et al. *Deep neural networks can predict mortality from 12-lead electrocardiogram voltage data*. doi: 10.48550/arXiv.1904.07032
7. Hannun A.Y., Rajpurkar P., Haghpanahi M. et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine*. 2019;25(1):65–69.
8. Moskalenko V.A., Nikol'skiy A.V., Zolotykh N. Yu. et al. The Cybercardiogram Diagnostics software package for automatic analysis of electrocardiograms using machine learning methods. *Sovremennye tekhnologii v meditsine = Modern technologies in medicine*. 2019;11(2):86–91. (In Russ.)
9. Tseng L., Tseng V. *Predicting Ventricular Fibrillation Through Deep Learning*. 2020;8:20. Available at: <https://ieeexplore.ieee.org/document/9284455> (accessed 12.08.2024).
10. Zhao Y., Cheng J., Zhang P., Peng X. ECG Classification Using Deep CNN Improved by Wavelet Transform. *Computers, Materials & Continua*. 2020;64(3):1615–1628. doi: 10.32604/cmc.2020.09938
11. Wu M., Lu Y., Yang W. A Study on Arrhythmia via ECG Signal Classification Using the Convolutional Neural Network. *Front Comput. Neurosci*. 2021;14:10. Available at: https://www.researchgate.net/publication/348249676_A_

- Study_on_Arrhythmia_via_ECG_Signal_Classification_Using_the_Convolutional_Neural_Network (accessed 12.08.2024).
12. Soliman Kh., Sali S. Classification of arrhythmias using a pre-trained deep learning model with binary images of segmented ECG. *Izvestiya vuzov Rossii. Radioelektronika = Proceedings of Russian universities. Radio electronics*. 2023;26(2):120–127. (In Russ.)
 13. Zhou F., Fang D. Multimodal ECG heartbeat classification method based on a convolutional neural network embedded with FCA. *Sci Rep*. 2024;14:8804. doi: 10.1038/s41598-024-59311-0
 14. Eleyan A., Alboghbaish E. Electrocardiogram Signals Classification Using Deep-Learning-Based Incorporated Convolutional Neural Network and Long Short-Term Memory Framework. *Computers*. 2024;13:55. doi: 10.3390/computers13020055
 15. Zhou F., Wang J. Heartbeat classification method combining multi-branch convolutional neural networks and transformer. *iScience*. 2024;27:109307. doi: 10.1016/j.isci.2024.109307
 16. *The Research Resource for Complex Physiologic Signals*. Available at: <https://physionet.org> (accessed 12.08.2024).
 17. Belenkov Yu.N., Ternovoy S.K. *Funktsional'naya diagnostika serdechno-sosudistyykh zabolevaniy = Functional diagnostics of cardiovascular diseases*. Moscow: GEOTAR-Media, 2017:976. (In Russ.)
 18. Moiseeva V.S., Martynova A.I., Mukhina N.A. *Vnutrennie bolezni: uchebnik: v 2 t. = Internal diseases : textbook : in 2 volumes*. Moscow: GEOTAR-Media, 2012;1:590. (In Russ.)
 19. Zatonskaya E.V., Matyushin G.V., Gogolashvili N.G. et al. Epidemiology of arrhythmias (review of literature data). *Sibirskoe meditsinskoe obozrenie = Siberian Medical Review*. 2016;(3):5–16. (In Russ.)
 20. He K., Zhang X., Ren S. et al. *Deep Residual Learning for Image Recognition*. doi: 10.48550/arXiv.1512.03385
 21. *Kaggle*. Available at: <https://www.kaggle.com>
 22. *The China Physiological Signal Challenge 2018*. Available at: <http://2018.icbeb.org/Challenge.html> (accessed 25.06.2024).
 23. Lyashenko V., Jha A. *Cross-Validation in Machine Learning: How to Do It Right*. Available at: <https://neptune.ai/blog/author/vladimirlyashenko> (accessed 12.08.2024).
 24. Bajaj A. *Performance Metrics in Machine Learning [Complete Guide]*. Available at: <https://neptune.ai/blog/performance-metrics-in-machine-learning-complete-guide> (accessed 12.08.2024).
 25. *Svidetel'stvo № 2046604262 o gosudarstvennoy registratsii programmy dlya EVM. Programma klassifikatsii elektrokardiosignalov na osnove svertochnoy neyronnoy seti = Certificate No. 2046604262 on state registration of a computer program. A program for classifying electrocardiosignals based on a convolutional neural network*. Krivonogov L.Yu., Levin S.F., Inomboev I.S.; reg. in the computer program registry 07.05.2024. (In Russ.)

Информация об авторах / Information about the authors

Леонид Юрьевич Кривоногов
 доктор технических наук, доцент,
 профессор кафедры медицинской
 кибернетики и информатики,
 Пензенский государственный университет
 (Россия, г. Пенза, ул. Красная, 40)
 E-mail: leonidkrivonogov@yandex.ru

Leonid Yu. Krivonogov
 Doctor of technical sciences,
 associate professor,
 professor of the sub-department
 of medical cybernetics
 and computer science,
 Penza State University
 (40 Krasnaya street, Penza, Russia)

Станислав Федорович Левин

врач-ординатор,
Пензенский государственный университет
(Россия, г. Пенза, ул. Красная, 40)
E-mail: lvin.stanislav.01@mail.ru

Stanislav F. Levin

Resident,
Penza State University
(40 Krasnaya street, Penza, Russia)

Илхомджон Сулхиддинович Иномбоев

студент,
Пензенский государственный университет
(Россия, г. Пенза, ул. Красная, 40)
E-mail: ilhomdzoninomboev@gmail.com

Ihomjon S. Inomboev

Student,
Penza State University
(40 Krasnaya street, Penza, Russia)

Дмитрий Викторович Папшев

старший преподаватель кафедры
медицинской кибернетики
и информатики,
Пензенский государственный университет
(Россия, г. Пенза, ул. Красная, 40)
E-mail: rover_d@mail.ru

Dmitry V. Papshev

Senior lecturer of the sub-department
of medical cybernetics
and computer science,
Penza State University
(40 Krasnaya street, Penza, Russia)

**Авторы заявляют об отсутствии конфликта интересов /
The authors declare no conflicts of interests.**

Поступила в редакцию/Received 10.10.2024

Поступила после рецензирования/Revised 11.12.2024

Принята к публикации/Accepted 17.12.2024