

Классификация аритмий с использованием предварительно обученной модели глубокого обучения с бинарными изображениями сегментированной ЭКГ

Х. Солиман^{1,2}✉, С. Сали^{1,2}

¹ Санкт-Петербургский государственный электротехнический университет "ЛЭТИ" им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия

² Университет Тишрин, Латакия, Сирия

✉ khsoliman@stud.etu.ru

Аннотация

Введение. Аритмия, или нерегулярное сердцебиение, возникает, когда электрическая система сердца дезорганизована или не синхронизирована, и может вызвать инсульты, внезапную сердечную смерть и другие осложнения. Автоматизированная классификация аритмий с использованием глубокого обучения сэкономила бы время и энергию при внедрении в систему поддержки принятия решений в больницах.

Цель работы. Изучение эффективности улучшения классификации аритмий после использования двоичных изображений сегментированных сигналов электрокардиограммы (ЭКГ) с комбинациями ортогональных и поверхностных сигналов.

Материалы и методы. В данной статье изучается классификация аритмий с использованием двоичных изображений поверхностных и ортогональных сигналов ЭКГ. Маркировка данных автоматизируется с использованием языка программирования Python, для всех сигналов реализуется предварительная обработка, а затем полученные сигналы наносятся на график и сегментируются в 2-секундных окнах. Эти сегменты сохраняются как изображения RGB, затем преобразуются в двоичные изображения, где сигнал белый, а фон черный. Предварительно обученная модель Alexnet используется для классификации девяти классов, где каждая поверхностная ЭКГ и ортогональное отведение классифицируются отдельно.

Результаты. Производительность модели оценивается по средней точности, прецизионности, F1-score и матрице путаницы всех лидов. Результаты параллельной классификации ЭКГ в 12 отведениях лучше, чем для ортогональных отведений, и все отведения с точностью, прецизионностью и F1-score равны 0.84, 0.78 и 0.71 соответственно.

Заключение. Производительность модели оценивалась для трех случаев: 12 поверхностных отведений ЭКГ, ортогональных отведений и всех отведений. Вычисленные средние значения показателей (точность, прецизионность и оценка F1) для каждого случая показывают, что использования 12 поверхностных отведений ЭКГ достаточно для классификации девяти различных типов аритмии с использованием двоичных изображений сегментов ЭКГ.

Ключевые слова: классификация аритмий, модель Alexnet, бинарные изображения, глубокое обучение, поверхностная ЭКГ, ортогональные отведения

Для цитирования: Солиман Х., Сали С. Классификация аритмий с использованием предварительно обученной модели глубокого обучения с бинарными изображениями сегментированной ЭКГ // Изв. вузов России. Радиоэлектроника. 2023. Т. 26, № 2. С. 120–127. doi: 10.32603/1993-8985-2023-26-2-120-127

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Статья поступила в редакцию 14.11.2022; принята к публикации после рецензирования 17.03.2023; опубликована онлайн 28.04.2023

Classification of Arrhythmias Using a Pre-trained Deep Learning Model with Binary Images of Segmented ECG

Hanadi Solieman^{1,2}✉, Salar Sali^{1,2}

¹ Saint Petersburg Electrotechnical University, St Petersburg, Russia

² Tishreen University, Latakia, Syria

✉ khsoliman@stud.etu.ru

Abstract

Introduction. Arrhythmia or irregular heartbeat occur when the heart's electrical system is disorganized or out of sync, which may cause strokes, sudden cardiac death, and other complications. The introduction of an automated classification of arrhythmias based on deep learning could facilitate the decision-making process by saving time and labor resources.

Aim. To study the performance of a modified arrhythmia classification improved by using binary images of segmented ECG signals with combinations of orthogonal and surface signals.

Materials and methods. This article studies an arrhythmia classification based on binary images of surface and orthogonal ECG signals. The data labeling was automated using the Python programming language. Initially, all signals are subjected to preprocessing followed by their plotting and segmenting in 2-second windows. Next, those segments are saved as RGB images followed by their conversion into binary images, where the signal is white, and the background is black. Finally, the pre-trained Alexnet model is used to classify nine classes, where each surface ECG and orthogonal lead is classified separately.

Results. The performance of the model is evaluated by the mean accuracy, precision, F1-score, and confusion matrix of all leads. The results of a parallel classification of 12 lead ECG are better than those for the orthogonal leads. All leads with accuracy, precision, and F1-score equal to 0.84, 0.78, and 0.71, respectively.

Conclusion. The performance of the model was evaluated for three cases: 12 surface ECG leads, orthogonal leads, and all leads. The calculated mean values of accuracy, precision, and F1-score for each case confirmed the sufficiency of the 12-lead surface ECG for classifying nine different types of arrhythmia using binary images of ECG segments.

Keywords: arrhythmia classification, Alexnet model, binary images, deep learning, surface ECG, orthogonal leads

For citation: Solieman H., Sali S. Classification of Arrhythmias Using a Pre-trained Deep Learning Model with Binary Images of Segmented ECG. Journal of the Russian Universities. Radioelectronics. 2023, vol. 26, no. 2, pp. 120–127. doi: 10.32603/1993-8985-2023-26-2-120-127

Conflict of interest. The authors declare no conflicts of interest.

Submitted 14.11.2022; accepted 17.03.2023; published online 28.04.2023

Введение. Аритмия, или нерегулярное сердцебиение, возникает, когда электрическая система сердца дезорганизована или не синхронизирована. Люди с аритмией страдают от быстрого, медленного или нерегулярного сердцебиения. Изучение аритмии имеет важное значение, поскольку она может увеличить частоту инсультов, внезапной сердечной смерти и их осложнений [1]. В 2019 г. около 17.9 млн человек в мире умерли от сердечно-сосудистых заболеваний, причем 85 % случаев были вызваны инсультом и сердечным приступом. Более трех четвертей смертей от сердечно-сосудистых заболеваний приходится на страны с низким и средним уровнями дохода. Процент преждевременных смер-

тей (до 70 лет) от сердечно-сосудистых заболеваний составил 32 % от общемирового уровня смертности [2], что указывает на абсолютную необходимость автоматизированного выявления и классификации аритмии.

Недавние исследования включали использование алгоритмов глубокого обучения для достижения надежной диагностики аритмии на основе зарегистрированных сигналов электрокардиограммы (ЭКГ) как в базах данных Physikalisch-Technische Bundesanstalt (РТВ) [3], так и MIT-BIH [4]. В этих исследованиях использовались различные методы предварительной обработки сигналов и архитектура модели глубокого обучения, включая различные алгоритмы.

Классификация аритмий с использованием предварительно обученной модели глубокого обучения с бинарными изображениями сегментированной ЭКГ
Classification of Arrhythmias Using a Pre-trained Deep Learning Model with Binary Images of Segmented ECG

В [5] сигнал ЭКГ был разложен на 9 типов сигналов с использованием различных частот вейвлет-преобразования на основе результатов исследования в [6] с последующей фильтрацией шума и повторным восстановлением сигналов. 24-слойная сверточная нейронная сеть извлекла признаки, а затем классифицировала данные, чтобы получить оценку F1 в 86.46 %. Несмотря на то, что вейвлет-преобразование является мощным инструментом, у него есть 3 серьезных недостатка: чувствительность к сдвигу; плохая направленность и отсутствие информации о фазе [7]. Таким образом, предварительная обработка в данном исследовании выбиралась из соображений наименьшей стоимости и удобства реализации в мобильном приложении или в системе реального времени.

Учитывая недавние достижения в использовании генеративных состязательных сетей (Generative Adversarial Network, GAN) в различных приложениях для генерации искусственных данных [8, 9], исследователи предложили сбалансировать данные в наборе данных MIT-BIH с использованием GAN [10], так как несбалансированные данные приводят к снижению точности. Их целью было создание модели, которая определяет 15 классов. После балансировки данных с помощью GAN производительность улучшилась. Оценка классификации по матрице путаницы показывает точность выше 98 %, прецизионность выше 90 %, специфичность выше 97.4 % и чувствительность выше 97.7 %. Тем не менее, генерация искусственного сигнала ЭКГ исключила бы персонализацию сердечно-сосудистой системы для каждого человека.

В [11] использовалась функция фокальных потерь (*англ.* Focal Loss) для решения проблемы несбалансированных данных, которую внедрили в MIT-BIH и повысили оценку F1-score до 0.79. Такой подход лучше, поскольку данные представляют собой биомедицинские сигналы, что позволяет избежать манипулирования данными.

Тренинг по трансфертному обучению был предложен Кубой и Тимом [12], поскольку для обучения сверточной нейронной сети (Convolutional Neural Networks, CNN) для классификации сигналов ЭКГ требуется много ан-

нотированных выборок, чего трудно достичь. Сначала были предварительно обработаны данные в зависимости от большего общедоступного набора данных, затем точно настроена сеть с небольшими данными для классификации фибрилляции предсердий. Этот метод улучшил производительность CNN. В [13] база данных MIT-BIH по злокачественной желудочковой эктопии [14] использовалась для классификации данных на основе риска нарушения для здоровья и жизни пациента. Были оценены 6 выбранных классов: опасная аритмия, требующая срочной реанимации; ранняя форма опасных для жизни аритмий; опасные для жизни желудочковые аритмии; потенциально опасные желудочковые аритмии; наджелудочковые аритмии; нормальный ритм, где каждый класс содержал 90 основных фрагментов по 2 с каждый. Алгоритмами, использованными для классификации аритмии по спектральному описанию, были взвешенные K-ближайшие соседи (K-Nearest Neighbors, KNN), линейный дискриминантный анализ (Linear Discriminant Analysis, LDA) и метод ближайшей выпуклой оболочки (Linear Programming based Nearest Convex Hull, LP-NCH), машина опорных векторов (Support Vector Machines, SVM) и методы нейронной сети.

Точность отнесения группы опасных аритмий – трепетания желудочков (Ventricular Flutter, VFL), фибрилляции желудочков (Ventricular Fibrillation, VFIB), желудочковой тахикардии (Ventricular Tachycardia, VT) – к фону альтернативной аритмии была самой высокой при использовании SVM (94.8 %). В процессе классификации опасных аритмий на катастрофические VFL, VFIB и опасные для жизни VT наивысшая точность снизилась до 82.2 %, в то время как чувствительность не превышала 77.2 %. Эффективность не повышалась при использовании алгоритмов нейронной сети, где показатель точности не превышал 93.7 % при использовании полностью подключенной нейронной сети. В [15] сгруппировали 5 классов базы данных РТВ, где были классифицированы 50 из 549 записей. Сгруппированными классами были инфаркт миокарда, аритмия, блокада ветвей пучка, кардиомиопатии и здоровый контроль. Сначала каждая запись была разделена на сегменты продолжительностью

в 1 с, за которыми последовали фрагменты продолжительностью в 2 и 3 с. Затем каждый сегмент был преобразован в скалограммы с использованием непрерывного вейвлет-преобразования (Continuous Wavelet Transform, CWT). Наконец, предварительно обученная модель Alexnet была использована для классификации результирующих сегментов продолжительностью 1, 2 и 3 с на 5 классов. Наилучшие результаты были получены с помощью 3-секундных скалограмм, где оценка F1, отзыв, точность и безошибочность составили 0.9809, 0.98, 0.9818 и 0.98 соответственно.

Материалы и методы. Исследование заключается в преобразовании девяти классов сигналов ЭКГ в двоичные изображения, а затем в разработке модели глубокого обучения для их классификации.

В данной статье использовалась база данных РТВ, предоставленная Национальным институтом метрологии Германии. Она содержит 549 записей о 290 здоровых добровольцах и пациентах с различными заболеваниями сердца: 81 женщина (средний возраст 61.6 год) и 209 мужчин (средний возраст 55.5 лет). Каждая запись содержит 15 измеренных сигналов; 12 стандартных отведений (i, ii, iii, avr, avl, avf, v1, v2, v3, v4, v5, v6) и 3 ЭКГ в отведениях Франка (vx, vy, vz). Сигнал был оцифрован таким образом, что в каждую секунду было 1000 отсчетов. Подробное клиническое резюме было представлено в заголовочном файле (.hea), в то время как значения сигнала ЭКГ были представлены в файле (.dat). Сигналы в этой базе данных соответствуют девяти классам сердечных заболеваний: разное, миокардит, порок клапанов сердца, гипертрофия миокарда, дисритмия, блокада ветвей пучка, кардиомиопатия/сердечная недостаточность, инфаркт миокарда и здоровый контроль [3]. Выбор этой базы данных основан на большом количестве предоставленных записей. Эти записи включали лиц обоих полов, здоровых или пациентов с различными заболеваниями сердца.

Подготовка данных состоит из четырех этапов: автоматической маркировки необработанных данных; предварительной обработки полученных сигналов; разделения каждого на не-

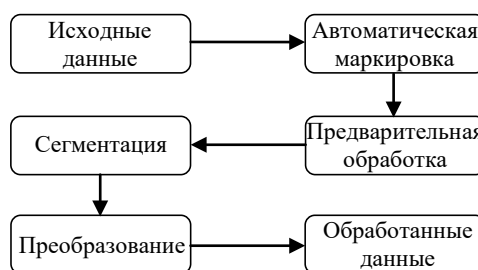


Рис. 1. Этапы подхода к предварительной обработке данных

Fig. 1. Stages of the data preprocessing approach

сколько небольших сигналов; преобразования каждого в изображение (рис. 1).

Автоматическая маркировка данных обусловлена большим количеством записей в базе данных, ручная обработка которых сложна и отнимает много времени. Вначале все файлы (.hea), содержащие диагноз, были собраны в одну папку. Затем все файлы сканировались один за другим с автоматическим поиском названия записи и диагноза. Использование библиотеки ОС на Python позволило быстро перебирать файлы папки. Таблица Excel была создана с использованием библиотеки "xlsxwriter", которая содержала 2 столбца: первый – название записи, а второй – сам диагноз. Класс был назван в честь диагноза, и в то же время номер строки соответствовал количеству записей. Таким образом, как название каждой записи, так и диагноз были найдены автоматически.

Все записи в формате (.mat) были собраны в одну папку после успешного завершения предыдущего шага, и были созданы папки с названиями классов. Библиотека Excel использовалась для чтения файла .xls, созданного на первом шаге, который содержал 2 столбца (имя записи и имя класса). Процесс перемещения файлов (.mat) из основной папки во вложенные папки был следующим: название записи считывалось из первого столбца, а диагноз – из второго. Таким образом, было известно, какая запись (файл .mat) соответствует какой папке (имя класса). Это сворачивание было выполнено с использованием библиотеки shutil, которая позволяла переносить файлы между папками. Наконец, все строки были переданы, и все файлы (.mat) были перемещены из основной папки в 9 вложенных папок.




Рис. 2. Результат предварительной обработки сигнала: *a* – до обработки; *b* – после обработки

Fig. 2. Preprocessing a signal: *a* – before preprocessing; *b* – after preprocessing

Метод предварительной обработки данных состоит из двух этапов. Первый – это нормализация амплитуды сигнала, а второй – сглаживание сигнала. Для сглаживания каждого сигнала был применен усредненный фильтр. Сигнал до и после предварительной обработки показан на рис. 2.

Сегментация сигналов. Продолжительность записей базы данных РТВ составляет от 15 до 60 с. Таким образом, каждая запись была разделена на 15–30 сегментов продолжительностью 2 с. Сегментация была необходима для увеличения размера выборки и уменьшения размера изображений в качестве окончательной формы данных перед подачей в модель. Выбор 2-секундной сегментации был основан на исследовании [13], независимо от того, что авторы [15] получили лучшие результаты с 3-секундной сегментацией, используя другую технику преобразования изображений. Пример сегментации 6-секундного сигнала на 2-секундные сегменты показан на рис. 3.

Преобразование сигналов в изображения. На этом этапе сегментированные сигналы были сохранены в виде изображений RGB. Затем эти изображения были преобразованы в двоичные, где фон черный, а объект белый. Пример сигнала до и после преобразования показан на рис. 4. После этого шага данные были готовы к вводу в модель глубокого обучения.




Рис. 3. Результат сегментации 4-секундного сигнала на два 2-секундных сегмента: *a* – первый сегмент; *b* – второй сегмент

Fig. 3. Segmentation of a 4-seconds signal into two 2-seconds segments: *a* – the first segment; *b* – the second segment




Рис. 4. Результат преобразования предварительно обработанного сигнала ЭКГ в двоичное изображение

Fig. 4. Conversion of a preprocessed ECG signal to a binary image

Архитектура модели Alexnet. Архитектура предварительно обученной модели Alexnet в данном исследовании состоит из восьми уровней. Первый и второй слой представляют собой сверточный слой со слоем максимального объединения, в то время как слои с 3-го по 5-й представляют собой 3 сверточных слоя с одним слоем максимального объединения, а слои с 6-го по 8-й – 2 полностью связанных скрытых слоя с одним полностью подключенным выходным слоем. Функция активации линейного блока выпрямителя (Rectified Linear Unit, ReLU) использовалась для всех слоев, кроме выходного, где использовался softmax. Количество эпох и размер партии составили 80 и 64 соответственно.

Результаты и обсуждение. Производительность модели оценивалась с помощью набора показателей для случаев использования поверхностных выводов, ортогональных выводов и всех выводов. Учитывая, что каждый тип канала классифицировался отдельно, было рассчитано среднее значение для каждого случая классификации (таблица).

Показатели оценки эффективности модели для каждого изученного случая при классификации аритмий

The evaluation metrics of the model's performance of each studied case for arrhythmia classification

Показатели оценки	12 поверхностных отведений ЭКГ	Ортогональные отведения	Все отведения
Точность	0.84273	0.83195	0.83726
Прецизионность	0.78493	0.69964	0.72694
F1-score	0.71508	0.76427	0.73794

Это исследование показало наилучшую точность, а также прецизионность в случае поверхностных отведений ЭКГ. Хотя точность ненамного выше, чем у ортогональных отведений, она более надежна, поскольку была рассчитана на основе 12 отведений, в то время как для отведений Фрэнка она была основана только на трех зацепках. С другой стороны, оценка F1-score для ЭКГ отведений Франка была наилучшей и превышала точность в случае 12 поверхностных отведений.

Закключение. Цель описанного исследования была достигнута с помощью базы данных РТВ для классификации девяти типов аритмии. Вначале для автоматической маркировки изображений использовался язык программирования Python. Затем MATLAB Simulink был использован для предварительной обработки и

сегментации сигналов на 2-секундные фрагменты и сохранения их в изображениях RGB. Далее с помощью Python RGB-изображения преобразовывались в двоичные. Наконец, предварительно обученная модель Alexnet использовалась для классификации изображений в Google Colab, где каждый ЭКГ-канал классифицировался отдельно. Методика отсева была внедрена для уменьшения переобучения. Производительность модели оценивалась для трех случаев: 12 поверхностных отведений ЭКГ, ортогональных отведений и всех отведений. Вычисленные средние значения показателей (точность, прецизионность и F1-score) для каждого случая показывают, что использования 12 поверхностных отведений ЭКГ достаточно для классификации девяти различных типов аритмии.

Список литературы

1. Smoot K. Heart Rhythm and Arrhythmias // Johns Hopkins Medicine. URL: https://www.hopkinsmedicine.org/heart_vascular_institute/cardiovascular-research/heart-rhythm-and-arrhythmias.html (дата обращения 22.10.2022)
2. Cardiovascular diseases (CVDs) // World Health Organization. URL: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)) (дата обращения 24.10.2022)
3. Bousseljot R. D., Kreisler D., Schnabel A. The PTB Diagnostic ECG Database. doi: 10.13026/C28C71. URL: <https://physionet.org/content/ptbdb/> (дата обращения 15.10.2022)
4. Moody G., Mark R. MIT-BIH Arrhythmia Database. doi: 10.13026/C2F305. URL: <https://physionet.org/content/mitdb/> (дата обращения 15.10.2022)
5. ECG Classification Using Deep CNN Improved by Wavelet Transform / Y. Zhao, J. Cheng, P. Zhang, X. Peng // Computers, Materials & Continua. 2020. Vol. 64, № 3. P. 1615–1628. doi: 10.32604/cmc.2020.09938
6. Ari S., Das M. K., Chacko A. ECG signal enhancement using S-Transform // Computers in Biology and Medicine. 2013. Vol. 43, № 6. P. 649–660. doi: 10.1016/j.combiomed.2013.02.015
7. Fernandes F. C. A., van Spaendonck R. L. C., Burrus C. S. A new framework for complex wavelet transforms // IEEE Transactions on Signal Processing. 2003. Vol. 51, № 7. P. 1825–1837. doi: 10.1109/TSP.2003.812841
8. Yi X., Walia E., Babyn P. Generative adversarial network in medical imaging: A review // Medical Image Analysis. 2019. Vol. 58. P. 101552. doi: 10.1016/j.media.2019.101552
9. Synthesizing electronic health records using improved generative adversarial networks / M. K. Baowaly, Ch.-Ch. Lin, Ch.-L. Liu, K.-T. Chen // J. of the American Medical Informatics Association. 2019. Vol. 26, № 3. P. 228–241. doi: 10.1093/jamia/ocy142
10. Generalization of Convolutional Neural Networks for ECG Classification Using Generative Adversarial Networks / A. M. Shaker, M. Tantawi, H. A. Shedeed, M. F. Tolba // IEEE Access. 2020. Vol. 8. P. 35592–35605. doi: 10.1109/ACCESS.2020.2974712
11. Automated arrhythmia classification using depthwise separable convolutional neural network with focal loss / Y. Li, M. Jiang, L. Wei, J. Zhang, Zh. Wang, B. Wei, L. Xia // Biomedical Signal Processing and Control. 2021. Vol. 69. P. 102843. doi: 10.1016/j.bspc.2021.102843
12. Weimann K., Conrad T. O. F. Transfer learning for ECG classification // Sci Rep. 2021. Vol. 11, № 1. P. 5251. doi: 10.1038/s41598-021-84374-8
13. ECG Database for Evaluating the Efficiency of Recognizing Dangerous Arrhythmias / L. A. Manilo,

A. P. Nemirko, E. G. Evdakova, A. A. Tatarinova // Proc. of the 2021 IEEE Ural-Siberian Conf. on Computational Technologies in Cognitive Science, Genomics and Biomedicine. 2021. P. 120–123. doi: 10.1109/CSGB53040.2021.9496029

14. ECG Fragment Database for the Exploration of Dangerous Arrhythmia / A. Nemirko, M. Manilo, A. Tatarinova, B. Alekseev, E. Evdakova. doi: 10.13026/kpfg-xs25. URL: <https://physionet.org/content/>

ecg-fragment-high-risk-label/1.0.0/ (дата обращения 15.10.2022)

15. Ba Mahel A. S., Harold N., Solieman H. Arrhythmia Classification Using Alexnet Model Based on Orthogonal Leads and Different Time Segments // Proc. of the 2022 Conf. of Russian Young Researchers in Electrical and Electronic Engineering. 2022. P. 1312–1315. doi: 10.1109/ElConRus54750.2022.9755708

Информация об авторах

Солиман Ханади – бакалавр по направлению "Электромеханика – мехатроника" (2018, университет Тишрин, Сирия), магистр по направлению "Биотехнические системы и технологии" (2020), аспирантка 3-го года, ассистент кафедры биотехнических систем Санкт-Петербургского государственного электротехнического университета "ЛЭТИ" им. В. И. Ульянова (Ленина), ассистент университета Тишрин. Автор более 10 научных публикаций. Сфера научных интересов – медицинское приборостроение; медицинская информатика; обработка и анализ биомедицинских сигналов и данных.

Адрес: Санкт-Петербургский государственный электротехнический университет "ЛЭТИ" им. В. И. Ульянова (Ленина), ул. Профессора Попова, д. 5 Ф, Санкт-Петербург, 197022, Россия

E-mail: khsoliman@stud.etu.ru

<https://orcid.org/0000-0002-9868-8960>

Сали Салар – бакалавр по направлению "Электромеханика – мехатроника" (2020, университет Тишрин, Сирия), магистрант 2-го года кафедры биотехнических систем Санкт-Петербургского государственного электротехнического университета "ЛЭТИ" им. В. И. Ульянова (Ленина), ассистент университета Тишрин. Сфера научных интересов – медицинское приборостроение; медицинская информатика; обработка и анализ биомедицинских сигналов и данных.

Адрес: Санкт-Петербургский государственный электротехнический университет "ЛЭТИ" им. В. И. Ульянова (Ленина), ул. Профессора Попова, д. 5 Ф, Санкт-Петербург, 197022, Россия

E-mail: ssali@stud.etu.ru

<https://orcid.org/0000-0001-5000-3259>

References

1. Smoot K. Heart Rhythm and Arrhythmias. Johns Hopkins Medicine. Available at: https://www.hopkinsmedicine.org/heart_vascular_institute/cardiovascular-research/heart-rhythm-and-arrhythmias.html (accessed 22.10.2022)

2. Cardiovascular diseases (CVDs). World Health Organization. Available at: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)) (accessed 24.10.2022)

3. Bousseljot R. D., Kreiseler D., Schnabel A. The PTB Diagnostic ECG Database. doi: 10.13026/C28C71. Available at: <https://physionet.org/content/ptbdb/> (accessed 15.10.2022)

4. Moody G., Mark R. MIT-BIH Arrhythmia Database. doi: 10.13026/C2F305. Available at: <https://physionet.org/content/mitdb/> (accessed 15.10.2022)

5. Zhao Y., Cheng J., Zhang P., Peng X. ECG Classification Using Deep CNN Improved by Wavelet Transform. Computers, Materials & Continua. 2020, vol. 64, no. 3, pp. 1615–1628. doi: 10.32604/cmc.2020.09938

6. Ari S., Das M. K., Chacko A. ECG Signal Enhancement Using S-Transform. Computers in Biology and Medicine. 2013, vol. 43, no. 6, pp. 649–660. doi: 10.1016/j.compbiomed.2013.02.015

7. Fernandes F. C. A., van Spaendonck R. L. C., Burrus C. S. A New Framework for Complex Wavelet Transforms. IEEE Transactions on Signal Processing. 2003, vol. 51, no. 7, pp. 1825–1837. doi: 10.1109/TSP.2003.812841

8. Yi X., Walia E., Babyn P. Generative Adversarial Network in Medical Imaging: A review. Medical Image Analysis. 2019, vol. 58, p. 101552. doi: 10.1016/j.media.2019.101552

9. Baowaly M. K., Lin Ch.-Ch., Liu Ch.-L., Chen K.-T. Synthesizing Electronic Health Records Using Improved Generative Adversarial Networks. J. of the American Medical Informatics Association. 2019, vol. 26, no. 3, pp. 228–241. doi: 10.1093/jamia/ocy142

10. Shaker A. M., Tantawi M., Shedeed H. A., Tolba M. F. Generalization of Convolutional Neural Networks for ECG Classification Using Generative Adversarial Networks. IEEE Access. 2020, vol. 8, pp. 35592–35605. doi: 10.1109/ACCESS.2020.2974712

11. Lu Y., Jiang M., Wei L., Zhang J., Wang Zh., Wei B., Xia L. Automated Arrhythmia Classification Using Depthwise Separable Convolutional Neural Network with Focal Loss. Biomedical Signal Processing and Control. 2021, vol. 69, p. 102843. doi: 10.1016/j.bspc.2021.102843

12. Weimann K., Conrad T. O. F. Transfer Learning for ECG Classification. *Sci Rep.* 2021, vol. 11, no. 1, p. 5251. doi: 10.1038/s41598-021-84374-8

13. Manilo L. A., Nemirko A. P., Evdakova E. G., Tatarinova A. A. ECG Database for Evaluating the Efficiency of Recognizing Dangerous Arrhythmias. *Proc. of the 2021 IEEE Ural-Siberian Conf. on Computational Technologies in Cognitive Science, Genomics and Biomedicine.* 2021, pp. 120–123. doi: 10.1109/CSGB53040.2021.9496029

14. Nemirko A., Manilo L., Tatarinova A., Alekseev B., Evdakova E. ECG Fragment Database for the Exploration of Dangerous Arrhythmia. doi: 10.13026/kpfg-xs25. Available at: <https://physionet.org/content/ecg-fragment-high-risk-label/1.0.0/> (accessed 15.10.2022)

15. Ba Mahel A. S., Harold N., Solieman H. Arrhythmia Classification Using Alexnet Model Based on Orthogonal Leads and Different Time Segments. *Proc. of the 2022 Conf. of Russian Young Researchers in Electrical and Electronic Engineering.* 2022, pp. 1312–1315. doi: 10.1109/EIConRus54750.2022.9755708

Information about the authors

Hanadi Solieman, Bachelor in Electromechanics – Mechatronics (2018, Tishreen University, Syria), Master in Bioengineering Systems and Technologies (2020), 3rd year Postgraduate student, Assistant at the Department of Bioengineering Systems of Saint Petersburg Electrotechnical University. Assistant at the Mechatronics program for Distinguished at Tishreen University. The author of more than 10 scientific publications. Area of expertise: medical instrumentation; medical informatics; processing and analysis of biomedical signals and data.

Address: Saint Petersburg Electrotechnical University, 5 F, Professor Popov St., St Petersburg 197022, Russia
E-mail: khsoliman@stud.etu.ru
<https://orcid.org/0000-0002-9868-8960>

Salar Sali, Bachelor in Electromechanics – Mechatronics (2020, Tishreen University, Syria), 2nd year Master's student at the Department of Bioengineering Systems of Saint Petersburg Electrotechnical University. Area of expertise: medical instrumentation; medical informatics; processing and analysis of biomedical signals and data.

Address: Saint Petersburg Electrotechnical University, 5 F, Professor Popov St., St Petersburg 197022, Russia
E-mail: ssali@stud.etu.ru
<https://orcid.org/0000-0001-5000-3259>
