

Санкт-Петербургский государственный университет

Математическое обеспечение и администрирование информационных систем

Системное программирование

Швыркова Александра Алексеевна

Диагностика сердечно-сосудистых заболеваний по ЭКГ на библиотеке MIRF

Курсовая работа

Научный руководитель:  
доц. к.т.н. Ю. В. Литвинов

Санкт-Петербург  
2020

# Оглавление

Введение	3
1. Постановка задачи	6
2. Обзор существующих решений	7
3. Описание решения	9
Заключение	17
Список литературы	19

# Введение

## 1. ЭКГ-данные

На сегодняшний день электрокардиограмма является самым распространенным видом выявления сердечно-сосудистых заболеваний. С помощью неё можно получить сведения о нарушениях возбудимости и проводимости мышечных волокон сердца, а также судить о наличии изменений в миокарде и гипертрофии отделов сердца.

ЭКГ представляет из себя запись электрических потенциалов сердца, возникающих при его работе. Эту информацию получают с помощью электродов, которые размещают на поверхности тела. Разность потенциалов между двумя электродами называется отведением. Всего существует 12 отведений — 3 стандартных, 3 усиленных и 6 грудных [14]. На ЭКГ здорового человека можно выделить 5 зубцов: P, Q, R, S, T, и соответствующие сегменты между ними (Рис. 1).




Рис. 1: Зубцы и сегменты в ЭКГ-сигналах [2].

Протокол расшифровки ЭКГ содержит множество пунктов и подразумевает ручное высчитывание длин сегментов и амплитуд зубцов. Но даже аккуратный подсчёт этих параметров не всегда позволяет точно поставить диагноз. Одним из примеров является ишемия миокарда, которая характеризуется увеличением ампли-

туды зубца T [20]. Это изменение часто имеет слабовыраженный характер, что может привести к неверной диагностике заболевания и, как следствие, к неправильному лечению. Человеческий фактор является распространенной причиной врачебной ошибки [21].

## 2. Medical Image Research Framework

MIRF — библиотека для разработки приложений, обрабатывающей медицинские данные, в частности, медицинские изображения. В основе библиотеки лежит архитектура Pipes&Filters. Она подразумевает последовательное преобразование наборов данных. Фильтры выполняют преобразования входных данных, а конвейеры служат соединителями для потока преобразовываемых данных.

MIRF делится на два глобальных пакета. Пакет Core состоит из абстрактных классов и интерфейсов для данных и фильтров. Пакет Features содержит реализации для хранения и обработки конкретных форматов медицинских снимков — DICOM и Nifti. Также в этом пакете есть классы для удобной работы с pdf-отчетами. Все классы для данных наследуют абстрактный класс Data, который хранит метаинформацию об обследовании и пациенте в виде списка атрибутов. На данный момент в MIRF обрабатываемыми данными являются медицинские изображения, которые хранятся с помощью классов MedImage и ImageSeries.

Для преобразования данных используется шаблонный интерфейс Algorithm с единственным методом execute. В качестве фильтров используются экземпляры PipelineBlock, AlgorithmHostBlock, соединяющие классы, которые реализуют упомянутый интерфейс.

Все блоки соединяются в конвейер. Интерфейс PipelineKeeper помогает отслеживать состояние блоков, кэшировать некоторые объекты, а также задавать локальный или удаленный репозиторий, в котором будут храниться промежуточные данные.

Схема классов, которые используются при разработке любого приложения с помощью MIRF, представлена на Рис.2.

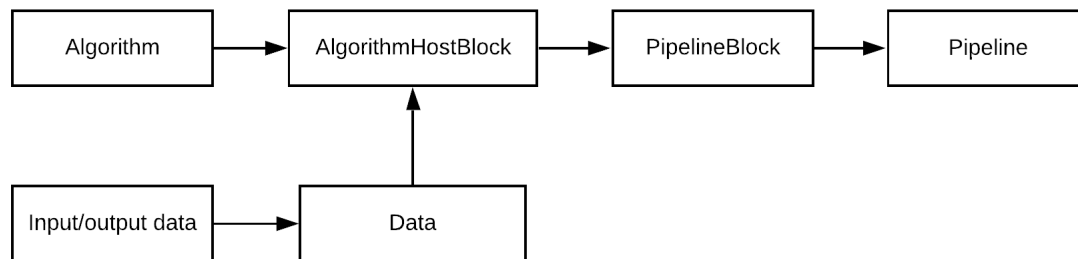


Рис. 2: Классы из пакета Core.

Тема сердечно-сосудистых заболеваний очень актуальна на сегодняшний день, поэтому в рамках данной курсовой работы было решено расширить библиотеку MIRF функционалом для работы с ЭКГ-сигналами. Помимо создания новых блоков и конвейеров, задача интересна тем, что ЭКГ-данные — это сигналы, а не изображения, что подразумевает создание нового типа данных в библиотеке.

# 1. Постановка задачи

Целью данной работы является расширение библиотеки MIRF возможностью обрабатывать ЭКГ-сигналы и распознавать различные заболевания с их помощью. Для достижения этой цели были поставлены следующие задачи:

- изучить существующие алгоритмы фильтрации и классификации ЭКГ-сигналов, выявить их достоинства и недостатки;
- Выбрать, реализовать и обучить свёрточную нейронную сеть для классификации ЭКГ-сигналов;
- реализовать блоки для предобработки и классификации ЭКГ-сигналов, а также генерации pdf-отчётов в MIRF;
- объединить блоки в единый конвейер.

## 2. Обзор существующих решений

Инструменты, работающие с ЭКГ-сигналами, можно разделить на полноценные продуктовые решения и на отдельные алгоритмы, решающие конкретную задачу классификации ЭКГ-данных.

К первой категории можно отнести такие приложения как:

- **Cardiologs** — приложение для диагностики сердечно-сосудистых заболеваний с помощью AI-решений. Имеет хороший интерфейс, хорошую точность прогнозов, но на данный момент доступен лишь узкому кругу медицинских компаний.
- **KardiaMobile** — приложение для распознавания трёх видов аритмий. Доступно только на коммерческой основе.

Ко второй категории можно отнести различные алгоритмы классификации болезней по ЭКГ. Среди них можно выделить два класса.

Алгоритмы из первого класса работают с цифровыми данными, извлекая морфологические и амплитудно-временные характеристики, такие как длины сегментов, расположение зубцов. Затем эта информация передается в классификатор. В качестве классификатора может выступать метод опорных векторов [12], [11], метод k-ближайших соседей [13] или метод, основанный на линейном дискриминантном анализе [6].

Второй класс алгоритмов работает с изображениями, полученными из сигналов, которые затем подаются на вход глубоким нейронным сетям. Нейронные сети способны строить иерархии признаков и выявлять неявные зависимости, благодаря чему они хорошо справляются с такой сложной задачей, как классификация ЭКГ-сигналов. Сверточные нейронные сети характеризуются размерностью входных данных. Например, 1D-сверточные нейронные сети работают с временными рядами, а 2D — с изображениями. В [16] используется 2D-сверточная нейронная сеть, которая работает с электрокардиограммой, как с набором единичных ударов, извлеченными из целого ЭКГ-обследования. Каждый удар сжимается до 128x128 пикселей. Точность этой модели

достигает 99% и, она способна распознавать 8 классов. В [7] используется распознающая 4 класса 1D-сверточная нейронная сеть с точностью около 97%.



## 3. Описание решения

### 1. Данные

В свободном доступе мало подходящих баз данных, — они либо содержат малое количество сигналов, либо плохо аннотированы. Рассматривались две самые полные и общедоступные базы данных: PTB Diagnostic ECG Database [5] и MIT-BIH Arrhythmia Database [10]. Выбор был сделан в пользу второго варианта, так как там содержится больше единичных ударов и больше выборка по различным клиническим случаям (7 видов аритмий + здоровые удары в MIT-BIH, в то время как PTB — база данных, преимущественно содержащая инфаркт миокарда).

### 2. Представление ЭКГ-сигналов

Реализован класс `EcgData`, наследующий класс `MirfData`, чтобы иметь возможность передавать его между блоками внутри пайплайна. Он содержит поле `attributes` типа `AttributeCollection`, в котором хранится нужная метаинформация и сами сигналы.

Так как атрибутов много, и они не обязаны одновременно присутствовать у экземпляра класса `EcgData`, был создан класс `EcgAttributes`, который определяет возможные поля и их вид с помощью класса из пакета `Core` — `DataAttributeMockup`. Они могут добавляться в коллекцию атрибутов класса `EcgData`.

Атрибуты, которые могут быть созданы для ЭКГ-сигнала:

- набор сигналов,
- набор отфильтрованных сигналов,
- набор присутствующих отведений,
- набор контрольных сумм,
- формат кодировки сигнала,
- значение усиления сигнала,

- частота семплирования сигналов (количество значений в секунду),
- количество значений в сигнале,
- число, отвечающее за изолинию (условный ноль по оси ординат).

### 3. Чтение ЭКГ-сигналов

ЭКГ-сигналы хранятся в виде двух файлов: заголовочного файла с метаинформацией и файла с отведениями.

Для чтения ЭКГ-сигналов был реализован класс `EcgReader`, который декодирует байтовое представление сырых данных и приводит его к формату экземпляра класса `EcgData`. В классе присутствуют методы для декодирования из двух форматов ЭКГ-сигналов:

- 212 — значение отсчёта хранится в виде 12-битного числа. В трёх подряд идущих байтах хранятся одновременные значения двух отведений
- 16 — значение отсчёта хранится в виде 16-битного знакового числа. Подряд идут все одновременно записанные отсчеты всех исследуемых отведений по два байта на каждый отсчет. Биты расположены по правилу `LittleEndian`, где в начале хранится наименее значимый байт

Для корректной раскодировки данных в заголовочном файле хранятся начальные значения и контрольные суммы для каждого отведения, их несовпадение при считывании приводит к вы抛су исключения `EcgFormatException`.

### 4. Фильтрация

ЭКГ-сигнал является электрическим сигналом, поэтому подвержен различным помехам, таким как белый шум и шум гуляющей изолинии.

Дискретный белый шум — это последовательность некоррелирующих друг с другом чисел. Причиной таких шумов при снятии электрокардиограммы может быть электрическая активность мышц тела, а также плохой контакт электродов с кожей.

ЭКГ-сигнал является нестационарным сигналом, поэтому многие стандартные методы фильтрации (например, преобразование Фурье) не могут быть использованы.

Для очистки ЭКГ-сигнала от белого шума используются различные методы: адаптивная фильтрация, вейвлет-преобразование, фильтрация Савицкого-Голая. Дискретное вейвлет-преобразование дает лучшие результаты фильтрации. Это подтверждается сравнительным анализом этих алгоритмов, представленным в [1].

В основе этого подхода лежат вейвлеты — функции особой формы, которые локализованы по времени и частоте. С помощью этих функций сигнал раскладывается на детализирующие и аппроксимирующие коэффициенты, где часть коэффициентов убирается фильтрами с определенными порогами. Затем сигнал восстанавливается из новых коэффициентов с помощью обратного преобразования [18]. В основном, для фильтрации используют функции из семейств *Symlet* и *Daubechies*, ввиду их большой внешней схожести с QRS-комплексом. *Symlet* показывает лучший результат, чем другие семейства [1]. В связи с этим были выбраны функции *Symlet*. Выбор порогового значения выполняется с помощью метода *rigorous SURE*, а масштабирование детализирующих коэффициентов, которые меньше порогового значения, выполняет *soft thresholding* функция. Это самые распространенные параметры дискретного вейвлет-преобразования для фильтрации ЭКГ-сигналов, и они дают наилучшие результаты (см [3], [1]).

Второй вид шума — шум гуляющей изолинии. Его причиной служит дыхание или телодвижения человека. Метод, который используется в [4], был выбран потому что он хорошо сохраняет важ-

ные клинические детали. Этот метод основан на идее, что чистый ЭКГ-сигнал и шум гуляющей изолинии — это две независимые части.

Так как Matlab имеет мощные библиотеки для работы с вейвлетами, было решено реализовать очистку с их помощью. Фильтрация небольшого промежутка второго отведения представлена на Рис. 3.




Рис. 3: Фильтрация ЭКГ-сигнала.

Этап очистки от шумов не должен влиять на результаты дальнейшей классификации. Это обусловлено тем фактом, что фильтрация может случайно сгладить, например, T-зубец, так как его частота иногда очень близка к частоте шума гуляющей изолинии. Поэтому фильтрация в разрабатываемом конвейере нужна только для того, чтобы передавать в pdf-отчет отфильтрованный сигнал.

## 5. Извлечение ударов

На входе нам подаётся цельный сигнал, состоящий из множества ударов. Классификация же работает с отдельными ударами из этого сигнала, поэтому требуется алгоритм для их извлечения.

Был реализован класс `EcgBeatExtractor`, который содержит алгоритм Пана-Томкинсона [8]. Был выбран этот алгоритм так как, он имеет высокую точность распознавания R-зубцов (см. [9]). Его идея состоит в том, чтобы сначала последовательно применить фильтры: фильтр низких частот, фильтр высоких частот, дифференцирование, возведение в квадрат, нахождение среднего. Они усиливают значения, относящиеся к QRS-комплексу, и подавляют остальные компоненты (например, шумы, P- и T-зубцы). Затем ищутся локальные экстремумы, которые идентифицируются как R-зубцы.

Во избежание неверной интерпретации локального экстремума как R-зубца, их значения сравниваются с порогами, которые вычисляются в процессе прохождения по ЭКГ-сигналу.

Пример извлечения ударов представлен на Рис. 4.




Рис. 4: До и после извлечения ударов из ЭКГ-сигнала

## 6. Классификация

В качестве классификатора были выбраны свёрточные нейронные сети. Исследования, проведенные в работах [16], [7], демонстрируют эффективность и преимущество данного подхода в сравнении с другими методами, которые рассматривались в обзоре существующих решений.

Было решено взять готовую архитектуру нейронной сети из статьи [16], так как она имеет высокую точность.

Выбранная база данных ЭКГ-сигналов содержит 14 видов нарушений сердечного ритма. Из них было выбрано 7 клинически важных видов аритмий, а также все здоровые удары. Каждый выбранный удар принадлежит одному из восьми классов: normal beat, right bundle branch block beat, left bundle branch block beat, premature ventricular contraction beat, paced beat, atrial premature contraction beat, ventricular flutter wave beat, and ventricular escape beat. В аннотационных файлах, которые были составлены по диагнозам от врачей, они сокращены до NOR, RBB, LBB, PVC, PAB, APC, VFW and VEB соответственно. Всего было извлечено 100852 отдельных удара.

	Тип слоя	Размерность выхода
0	Input	(128, 128, 1)
1	Conv2D	(128, 128, 64)
	ELU	
	Batch normalization	
2	Conv2D	(128, 128, 64)
	ELU	
	Batch normalization	
3	MaxPooling	(64, 64, 64)
4	Conv2D	(64, 64, 128)
	ELU	
	Batch normalization	
5	Conv2D	(64, 64, 128)
	ELU	
	Batch normalization	
6	MaxPooling	(32, 32, 128)
7	Conv2D	(32, 32, 256)
	ELU	
	Batch normalization	
8	Conv2D	(32, 32, 256)
	ELU	
	Batch normalization	
9	MaxPooling	(16, 16, 256)
10	Dense	(2048)
	ELU	
	Batch normalization	
	Dropout	
11	Dense softmax	(8)

Таблица 1: Архитектура модели из [16].

Из-за неравномерного распределения по классам, где более 50% ударов относятся к здоровым, была произведена аугментация изображений, относящихся к аритмиям, а именно, были осуществлены различные сдвиги изображений вдоль осей абсцисс и ординат.

Перед тем, как отдать изображения модели, они приводятся к размеру  $128 \times 128$ , а также переводятся в чёрно-белый формат.

Модель имеет 11 слоев, включающих Conv2D, MaxPooling, Dense. Согласно выбранной статье, функция активации ELU показала лучшие результаты, нежели более распространённая RELU, поэтому в данной модели использован первый вариант. Архитектура нейронной сети изображена в Таб. 1.

В медицине важны такие понятия, как истинно положительные (True Positive), ложно положительные (False Positive), истинно отрицательные (True Negative) и ложно отрицательные (False Negative) диагнозы. Поэтому были взяты метрики, основанные на этих значениях. Они считаются как среднее значение по всем классам:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} * 100\%$$

$$\text{Specificity} = \frac{TN}{FP+TN} * 100\%$$

$$\text{Sensitivity} = \frac{TP}{FN+TP} * 100\%$$

$$\text{Positive Predictive Value} = \frac{TP}{TP+FP} * 100\%$$

С помощью этих метрик можно сравнить решения (Таб. 2).

Классификатор	Accuracy	Specificity	Sensitivity	PPV
Из данной курсовой	95.6	94.3	98.7	87.7
Acharya et al. [17]	93.4	91.6	96.0	97.8
Kiranyaz et al. [15]	99.0	98.9	93.9	90.6
Jiang and Kong [19]	98.8	99.4	94.3	95.8

Таблица 2: Сравнение моделей

## 7. Конвейер

Все блоки соединяются в единый конвейер, схема которого представлена на Рис. 5.

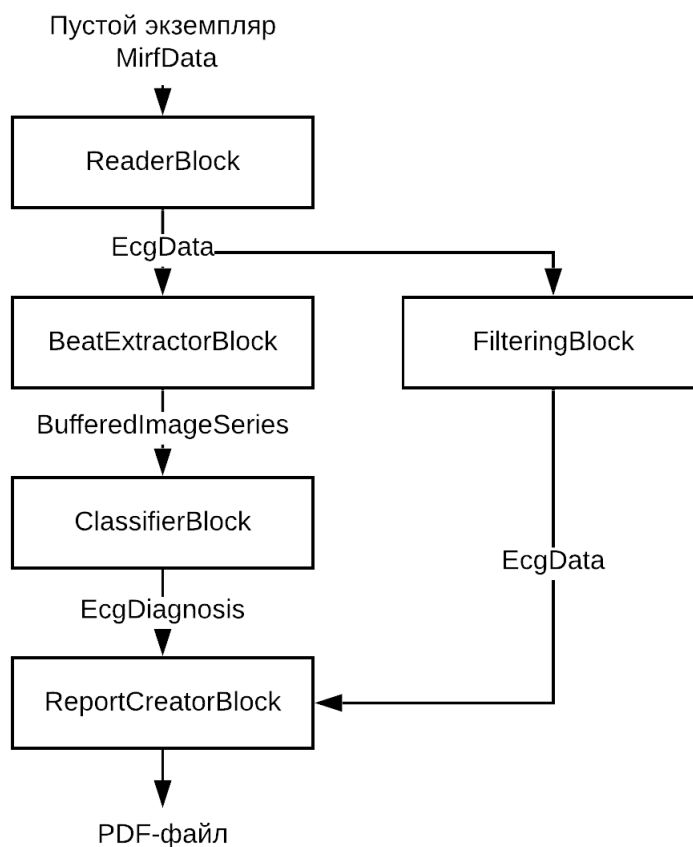


Рис. 5: Конвейер обработки ЭКГ-сигнала.

Результатом работы конвейера является сгенерированный pdf-файл с краткой информацией о пациенте, небольшим промежуточком второго отведения и диагнозом. Пример такого отчёта приведен на Рис. 6.



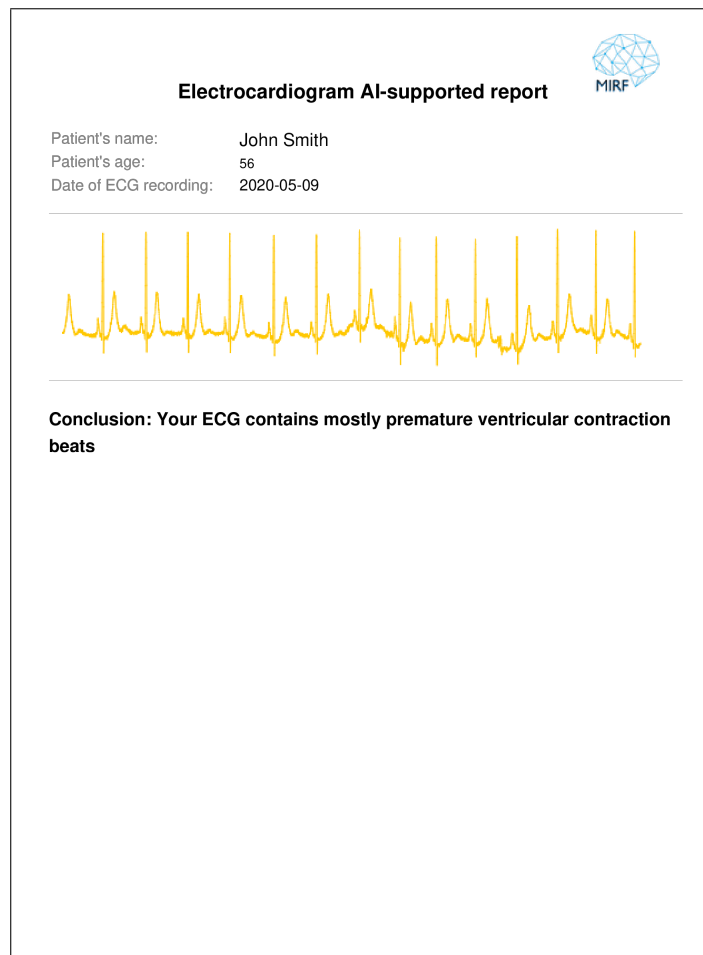


Рис. 6: Пример отчёта, который выдаёт программа.

## Заключение

В ходе выполнения данной курсовой работы были получены следующие результаты:

- исследованы проблемы фильтрации и классификации ЭКГ-данных, выбраны подходы, которые являются одними из лучших в своей области;
- реализована готовая архитектура нейронной сети, произведено обучение модели;
- реализован классы для хранения отведений и метаинформации, а также методы чтения и декодирования сырых данных из файлов;
- реализованы блоки для чтения, фильтрации, классификации

ЭКГ-данных, а также блок извлечения ударов из сигналов;

- блоки объединены в единый конвейер, результатом работы которого является pdf-файл с диагнозом.

Код проекта: <https://github.com/alexeevna/MIRF2/tree/ashvyrkova>

## Список литературы

- [1] AlMahamdy Mohammed, Riley H. Bryan. Performance Study of Different Denoising Methods for ECG Signals // Procedia Computer Science. — 2014. — Vol. 37. — P. 325 – 332.
- [2] Ali Isin Selen Ozdalili. Cardiac arrhythmia detection using deep learning // Procedia Computer Science. — Vol. 120. — P. 268 – 275.
- [3] Aqil Mounaim, Jbari Atman, Bourouhou Abdennasser. ECG Signal Denoising by Discrete Wavelet Transform // International Journal of Online Engineering (iJOE). — 2017. — Vol. 13. — P. 51.
- [4] B. Mozaffary, M. A. Tinati. ECG Baseline Wander Elimination using Wavelet Packets // World Academy of Science, Engineering and Technology. — 2005. — P. 14-16.
- [5] Boussejot R, Kreisler D, Schnabel, A. Nutzung der EKG-Signaldatenbank CARDIODAT der PTB über das Internet // Biomedizinische Technik. — Band 40. — Ergänzungsband 1. — 1995. — S.317.
- [6] DeChazal, P., O'Dwyer, M., Reilly, R. B.. Automatic Classification of Heartbeats Using ECG Morphology and Heartbeat Interval Features. // IEEE Transactions on Biomedical Engineering – Volume 51 – Issue: 7 – July 2004 – P.1196 - 1206.
- [7] Jian LiuEmail authorShuang SongGuozhong SunYu Fu. Classification of ECG Arrhythmia Using CNN, SVM and LDA// Artificial Intelligence and Security – 2019 – P.191-201.
- [8] Jiapu Pan, Willis J. Tompkinson. A Real-Time QRS Detection Algorithm // IEEE Transactions on Biomedical Engineering. – Volume BME-32. – Issue 3. – 1985.
- [9] Liu, Feifei and Wei, Shoushui and Li, Yibin and Jiang, Xinge and Zhang, Zhimin and Zhang, Ling and Liu, Chengyu. The Accuracy on

- the Common Pan-Tompkins Based QRS Detection Methods Through Low-Quality Electrocardiogram Database // Journal of Medical Imaging and Health Informatics. — 2017. — Vol. 7. — P. 1039–1043.
- [10] Moody GB, Mark RG. The impact of the MIT-BIH Arrhythmia Database // IEEE Engineering in Medicine and Biology Magazine. — May-June 2001. — Vol.20 — Issue 3. — P.45-50.
- [11] Nasiri JA, Naghibzadeh M, Yazdi HS. ECG arrhythmia classification with support vector machines and genetic algorithm // UKSim European Symposium on Computer Modeling and Simulation. — 2009. — P.187-192.
- [12] Osowski S, Hoai LT, Markiewicz T. Support vector machine-based expert system for reliable heartbeat recognition // IEEE Transactions on Biomedical Engineering — Volume 51. — Issue: 4. — April 2004 — P.582-589.
- [13] Park, J., Lee, K., Kang, K. Arrhythmia detection from heartbeat using k-nearest neighbor classifier // IEEE International Conference on Bioinformatics and Biomedicine. — 2013. — URL: <https://doi.org/10.1109/bibm.2013.6732594>. (дата обращения 13.12.19).
- [14] Ronald J. Prineas, Richard S. Crow, Zhu-Ming Zhang. The Minnesota Code Manual of Electrocardiographic Findings // Springer, London. — 2010.
- [15] S. Kiranyaz, T. Ince, M. Gabbouj. Real-Time Patient-Specific ECG Classification by 1-D Convolutional Neural Networks // IEEE Transactions on Biomedical Engineering. — Volume 63. — Issue 3. — 2016. — P. 664-675.
- [16] Tae Joon Jun, Hoang Minh Nguyen, Daeyoun Kang, Dohyeun Kim, Daeyoung Kim, Young-Hak Kim. ECG arrhythmia classification using a 2-D convolutional neural network // 2018 — URL: <https://arxiv.org/abs/1804.06812>. (дата обращения 01.02.20).

- [17] U. R. Acharya, S. L. Oh, Y. Hagiwara, J. H. Tan, M. Adam, A. Gertych, R. S. Tan. A deep convolutional neural network model to classify heartbeats // Computers in Biology and Medicine. – 2017. – P. 389-396.
- [18] A Wavelet Tour of Signal Processing / C. Mallat, S.A. MALLAT, S. Mallat, Engineering Information Inc. Electronics & Electrical. — Elsevier Science, 1999.
- [19] Wei Jiang, Seong Kong. Block-Based Neural Networks for Personalized ECG Signal Classification // IEEE Transactions on Neural Networks. – Volume 18. – Issue 6. – 2007. – P. 1750-1761.
- [20] А.В. Синьков, Г.М.Синькова. ЭКГ диагностика ишемии и инфаркта миокарда // ГБОУ ВПО ИГМУ Минздрава. – 2015 – URL: [https://mir.ismu.baikal.ru/src/downloads/00e5b5c4\\_4.\\_ekg\\_ishemiya.pdf](https://mir.ismu.baikal.ru/src/downloads/00e5b5c4_4._ekg_ishemiya.pdf). (дата обращения 13.12.19).
- [21] Шубик Ю. В., Апарина И. В., Медведев М. М., Фельдман А. П. Качество врачебных заключений по данным суточного мониторинга ЭКГ // Вестник аритмологии. – ВА-N49 от 06/11/2007. – стр. 25-34.