

УДК 004.891.3

Т. В. Ермоленко, Д. В. Ролик

Государственное образовательное учреждение высшего профессионального образования  
«Донецкий национальный университет», г. Донецк  
83001, г. Донецк, ул. Университетская, 24

## КЛАССИФИКАЦИЯ АНОМАЛИЙ СЕРДЦЕБИЕНИЯ С ПОМОЩЬЮ ГЛУБОКОГО ОБУЧЕНИЯ

T. V. Yermolenko, D. V. Rolik

State Educational Institution of Higher Professional Education «Donetsk National University»  
83001, Donetsk, University st, 24

## CLASSIFICATION OF HEART ABNORMALITIES USING DEEP LEARNING

Т. В. Ермоленко, Д. В. Ролік

Державна освітня установа вищої професійної освіти  
«Донецький національний університет», м. Донецьк  
83001, м. Донецьк, вул. Університетська, 24

## КЛАСИФІКАЦІЯ АНОМАЛІЙ СЕРЦЕБИТТЯ ЗА ДОПОМОГОЮ ГЛИБОКОГО НАВЧАННЯ

В статье рассматривается задача диагностики сердечных заболеваний по изображению скейлограмм фонокардиографических сигналов с помощью сверточных нейронных сетей. Проведены исследования информативности вейвлет-базисов по энтропийному критерию, а также эффективности использования сетей различных архитектур для разработки диагностических кардиологических систем. Наибольшую информативность среди исследуемых базисов показал вейвлет Морле, в качестве базовой модели классификации аномалий сердцебиения целесообразно использовать InceptionV3.

**Ключевые слова:** фонокардиографические сигналы, вейвлет-фильтры, энтропийный критерий, скейлограмма, сверточные нейронные сети.

The article deals with the problem of diagnosing heart diseases by imaging scalograms of phonocardiographic signals using convolutional neural networks. The information content of wavelet bases by the entropy criterion, as well as the efficiency of using networks of various architectures for the development of diagnostic cardiological systems, have been studied. The Morlet wavelet has the highest information content among the studied bases; it is advisable to use InceptionV3 as the basic model for classifying heartbeat anomalies.

**Key words:** phonocardiographic signals, wavelet filters, entropy criterion, scalogram, convolutional neural networks.

У статті розглядається задача діагностики серцевих захворювань за допомогою зображень скейлограм фонокардіографічних сигналів з використанням згорткових нейронних мереж. Проведено дослідження інформативності вейвлет-базисів за ентропійним критерієм, а також ефективності використання мереж різних архітектур для розробки діагностичних кардіологічних систем. Найбільшу інформативність серед досліджуваних базисів показав вейвлет Морле, як базову модель класифікації аномалій серцебиття доцільно використовувати InceptionV3.

**Ключові слова:** фонокардіографічні сигнали, вейвлет-фільтри, ентропійний критерій, скейлограма, згорткові нейронні мережі.

## Введение

В последние годы технологии анализа и классификации изображений с помощью сверточных сетей набирают популярность, поскольку глубокие сети обладают высокой точностью, могут обрабатывать большое количество данных, находя в них скрытые взаимосвязи, что делает их широко используемыми в различных сферах человеческой деятельности. Медицинская диагностика не стала исключением, в качестве примера можно привести флюорографию, ультразвуковую диагностику, магнитно-резонансную томографию и рентгенографию, компьютерную томографию, анализ изображений кристаллизации биологических жидкостей и т.д.

Диагностика заболеваний сердечно-сосудистой системы – одна из самых актуальных проблем здравоохранения. На сегодняшний день детальную информацию о состоянии сердца пациента кардиолог получает, вручную анализируя электрокардиограмму (ЭКГ). При расшифровке ЭКГ оценивают сердечный ритм, интервалы сокращений и другие показатели работы сердца.

Данная работа посвящена вопросам создания интеллектуальной системы анализа ритма сердцебиения по цифровому изображению его спектрограммы. Такая диагностическая система способна автоматизировать работу врача-кардиолога, повысить эффективность диагностики за счет своевременного выявления признаков сердечного заболевания, что способствует правильному формированию процесса и уменьшению осложнений.

**Целью работы** является анализ информативности вейвлет-базисов, получивших широкое распространение в цифровой обработке звуковых сигналов, а также эффективности различных архитектур сверточных нейросетей в задаче диагностики сердечных заболеваний по изображению спектрограмм ЭКГ и сердцебиений.

Для достижения поставленной цели необходимо:

- осуществить выбор анализирующего вейвлета для получения спектрограммы;
- провести сравнительный анализ архитектур сверточных сетей, используемых в цифровой медицине для диагностики сердечно-сосудистых заболеваний;
- сформировать набор данных, состоящий из размеченных звукозаписей ритмов сердцебиений, как здорового человека, так и с заболеваниями для обучения и тестирования моделей;
- провести численные исследования эффективности выбранных архитектур сверточных сетей в задаче классификации аномалий сердцебиения по изображению его спектрограммы вейвлет-спектра.

## Структура фонокардиографического сигнала

Звуки сердцебиения представляют собой квазипериодические сигналы, генерируемые турбулентностью крови и бьющимся сердцем. Эти звуки обеспечивают важные и распространенные способы диагностики сердечных заболеваний благодаря своей доступности и экономичности. Вариабельность интервалов между сокращениями сердца (кардиоинтервалами) имеет сложную структуру. Периодические колебания разной частоты в сердечном ритме отражают состояние сердца и всего организма, поэтому врачи им уделяют особое внимание при диагностике заболеваний. Специфические черты временной и частотной структуры фонокардиографических сигналов (ФКГС) достаточно хорошо изучены и систематизированы.

Как известно, цикл сердечной деятельности в норме складывается из трех фаз. Первая из них – систола предсердий (порядка 0.1 с), вторая – систола желудочков (порядка 0.3 с) и третья – общая пауза (порядка 0.4 с) или так называемая диастола [1]. В связи с этим различают несколько характерных тонов ФКГС [2]:

- первый тон сердца, определяемый на ФКГС первым всплеском осцилляций уровня сигнала в фазе систолы сердечного цикла, которому соответствует область частот 30-120 Гц.

- второй тон возникает в начале диастолы, определяемый на ФКГС вторым всплеском осцилляций уровня и имеющий диапазон частот 70-150 Гц;

- третий и четвертый тоны регистрируются не всегда, гораздо слабее первых двух тонов и могут наблюдаться на частотах 10-70 Гц и 16-35 Гц соответственно.

Таким образом, основная информация о состоянии сердца может быть получена из анализа первых двух тонов сердца, являющихся наиболее сильными акустическими составляющими ФКГС, соответствующими фазе систолы. Длительность импульсов тонов сердца составляет примерно 100 мс [3]. На остальном участке цикла сердечной деятельности, как правило, преобладают фоновые помехи. Эти используются при выявлении патологий сердечной деятельности.

Сложная структура вариабельности ФКГС привела к использованию многообразных методов частотно-временного анализа для обнаружения, извлечения и анализа различных компонентов ФКГС. Среди них техника вейвлет-преобразования дает многообещающие результаты [4].

Неизбежное ограничение преобразования Фурье состоит в том, что оно не позволяет определить точное положение частотных компонент в сигнале. Эти компоненты изменяются во времени. Вейвлет-преобразование лишено этого недостатка, оно основано на наборе анализирующих функций (вейвлетов), дающих разложение ФКГС на последовательность коэффициентов. Каждый вейвлет имеет определенную длительность, положение во времени и полосу частот.

Преимущество этого преобразования состоит в способности отмечать детали ФКГС с оптимальным частотно-временным разрешением. Так как применение вейвлет-анализа в кардиографии является сравнительно новой областью исследования, то много методологических аспектов (выбор материнского вейвлета, масштаба) вейвлет-техники требуют дальнейших исследований для увеличения клинической эффективности. В работе исследование фокусируется на изучении и сравнении вейвлет-базисов, используемых для анализа квазипериодических сигналов, а также основных сверточных архитектур глубокого обучения, используемых в решении задачи классификации аномалий сердцебиения по изображению спектрограмм.

## Исследование вейвлет-базисов на информативность

В рамках данной работы рассмотрены две группы вейвлетов. К первой группе относятся Мексиканская шляпа (mexh), Морле (Morl), Гаусса (gaus), ко второй – семейства ортонормированных вейвлетов Добеши (db), Койфмана (coif), Симмлеты (sym), для которых существует пирамидальный алгоритм получения быстрого преобразования.

Для вычисления характеристик банка вейвлет-фильтров определены центральная частота и ширина полосы пропускания материнского вейвлета  $w(t)$  согласно следующим формулам [5]:

$$\langle t \rangle = \frac{1}{\|w(t)\|^2} \int_{-\infty}^{+\infty} t |w(t)|^2 dt, \Delta_w = \frac{1}{\|w(t)\|} \left[ \int_{-\infty}^{+\infty} (t - \langle t \rangle)^2 |w(t)|^2 dt \right]^{1/2},$$

где  $\langle t \rangle$  – центр окна,  $\Delta_w$  – радиус окна вейвлета  $w(t)$ .

Как было сказано выше, информация о сердечных тонах находится на низких частотах между 30 и 200 Hz. Форма амплитудно-частотной характеристики зависит как от самого анализирующего вейвлета, так и от набора масштабов, на которых выполняется преобразование. В связи с чем был произведен выбор начального ( $j_{\min}$ ) и конечного ( $j_{\max}$ ) уровней разложения, на которых осуществляется обработка и анализ по формулам:

$$j_{\min} = \text{int} \left( \log_{a_0} \frac{f_d \langle \omega \rangle}{2\pi f_2} \right), j_{\max} = \text{int} \left( \log_{a_0} \frac{f_d \langle \omega \rangle}{2\pi f_1} \right),$$

где  $\text{int}()$  – округление до ближайшего целого,  $a_0$  – шаг масштабирующей переменной (в нашем случае для вейвлетов первой группы был выбран 1.1, для второй – 2),  $f_d$  – частота дискретизации,  $f_1$  и  $f_2$  – диапазон частот.

В результате для вейвлет-анализа сигнала при частоте дискретизации 22 kHz по исследуемым базисам вейвлетов первой группы достаточно 61 уровня разложения, для вейвлетов второй группы – 16 уровней.

Для более полного анализа ФКГС как здоровых, так и с аномалиями, которые имеют характерные спектральные особенности, единственного вейвлетного базиса может оказаться недостаточно. Таким образом, оправдан мультивейвлетный подход, при котором подлежат рассмотрению результаты вейвлет-преобразования, выполненного в нескольких базисах [6]. Для оценки информативности может быть использован критерий энтропии.

$$H(f, B^\lambda) = - \sum_{m=j_{\min}}^{j_{\max}} \sum_{l=0}^{N-1} \frac{d_{ml}^2}{E} \ln \left( \frac{d_{ml}^2}{E} \right),$$

где  $B^\lambda$  – семейства вейвлетов, характеристики которых были рассчитаны по формулам выше,  $E$  – энергия сигнала  $f$ ,  $d_{ml}$  – коэффициенты вейвлет-спектра на уровне  $m$ ,  $N$  – длина анализируемого сигнала.

Результаты проведенных в ходе данной работы исследований приведены на рис. 1. Показанные на рисунке значения энтропии распределения энергии исследуемых вейвлет-базисов получены для звуков, принадлежащих различным типам сердцебиения.

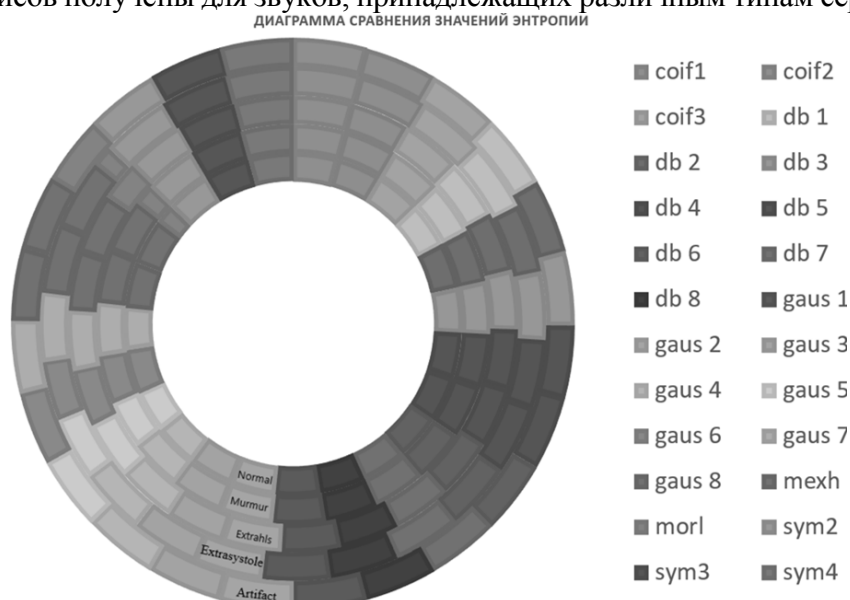


Рисунок 1 – Диаграмма сравнения значений энтропии, полученных для звуков разных сердцебиений с помощью различных вейвлет-базисов

На рисунке можно увидеть следующие обозначения: Normal – нормальное сердцебиение; Murmur – сердцебиение с шумами; Extrahls – дополнительный звук сердца; Extrasystole – экстрасистолия; Artifact – сердцебиение с артефактами.

Как видно из рис. 1, для описания различных типов сердцебиения наиболее информативным является вейвлет Морле. Значения энтропии распределения энергии, полученные для записей сердцебиения с артефактами по всем базисным функциям, различаются незначительно.

Вычисления вейвлетов и энтропии были произведены при помощи инструментов Matlab и waveletAnalyzer [7].

В результате проведенных исследований по энтропийному критерию наибольшую информативность для анализа аудиозаписей сердцебиения как нормального, так и при определенных патологиях, показал вейвлет Морле.

Для анализа различных компонентов ФКГС используют скейлограмму – функцию, описывающую распределение энергии вейвлет-коэффициентов по масштабам, являющуюся двумерным представлением одномерных данных: на ось X наносится время, а на ось Y – номера уровней разложения, абсолютное значение амплитуды вейвлет-коэффициентов передается интенсивностью цвета. Ряд современных диагностических систем, способных автоматически выявлять и вовремя информировать носителя о возможных проблемах функционирования сердца, анализируют изображения скейлограмм ФКГС, используя глубокие сверточные сети (Convolutional Neural Network, CNN).

## Анализ эффективности архитектур нейронных сетей в задаче диагностики заболеваний сердца

Для оценки эффективности моделей нейронных сетей их разработчиками использовалась F1-мера [8], результаты сведены в табл. 1. Результаты получены в ходе анализа современных статей, посвященных глубокому обучению и прогнозированию сердечно-сосудистых заболеваний на основе ЭКГ и ФКГС.

Таблица 1 – Эффективность моделей нейронных сетей в задаче диагностики сердечно-сосудистых заболеваний

Описание модели сети и задач классификации	Описание обучающего набора данных	Значение F1-меры
1	2	3
Модель: LeNet (CNN) с использованием операции одномерной свертки, выпадающего слоя между сверточным слоем и полносвязным слоем [9]. Задача: классификация проблем сердцебиения.	Physionet Apnea ECG dataset и UCD dataset, 90 записей ЭКГ длительностью от 401 до 587 минут	97,1%
Модель: двухлинейная нейронная сеть канонического корреляционного анализа (DL-CCANet) и трёхлинейная каноническая нейронная сеть корреляционного анализа (TL-CCANet) обе с двумя сверточными слоями [10]. Задача: классификация сердечных сокращений с различными патологическими сердечными заболеваниями.	MIT-BIH Arrhythmia database, INCART database содержащие 5280 записей ЭКГ	95,25% (DL-CCANet); 94,0% (TL-CCANet)
Модель: глубокая сверточная сеть с (DNN), состоящая из 7 ансамблей и 11 слоев (10 сверточных и 1 полно связный) [11]. Задача: классификация гиперкалиемии.	576581 записей ЭКГ от 449380 пациентов с 1994 по 2017 годы	90%

Продолжение таблицы 1

Модель: Linear support vector machine (SVM) с функцией линейного ядра [12]. Задача: классификация перекосов и шумов сердечбиения.	MIT-BIH Arrhythmia database, для обучения использовано 107 168 записей ЭКГ	97,77%
Модель: остаточная нейронная сеть с блоком сжатия и возбуждения (SE_ResNet) [13]. Задача: классификация 27 отклонений ЭКГ.	PhysioNet / Computing in Cardiology Challenge обучающий набор – 43101 записей, тестовый – 11630.	68,3%
Модель: 9-слойная CNN [14], анализирует спектрограммы сигналов длительной электрокардиографии. Задача: классификация аномалий (17 видов) сердечного ритма.	MIT-BIH Arrhythmia database, для обучения использовано 1280 записей ЭКГ	91,33%
Модель: CNN с бинаправленной долгой краткосрочной памятью (CNN-BLSTM), состоящая из 2 сверточных слоев и 2 BLSTM блоков [15]. Задача: диагностика аритмии.	MIT-BIH Arrhythmia database для обучения использовано 3699 записей ЭКГ	96,59%
Модель: CNN с 7 слоями свертки [16]. Задача: классификация аритмии.	Publicly available database	78,6%
Модель: рекуррентная сеть с долгой краткосрочной памятью и блоком автоэнкодера (LSTM-AE) [17]. Задача: классификация аритмий.	MIT-BIH Arrhythmia database, для обучения использовано 1482 записей ЭКГ	98,63%
Модель: Region Based Convolutional Neural Networks (R-CNN) [18]. Задача: классификация аритмий пяти категорий.	MIT-BIH Arrhythmia database, для обучения использовано 2132 записи ЭКГ	94,20%.
Модель: 20-слойная CNN, содержащая несколько остаточных блоков, а именно глубокая остаточная сверточная нейронная сеть (DR-CNN) [19]. Задача: классификация аритмий с легкими внутренними искажениями и внешними шумами.	MIT-BIH Arrhythmia database, для обучения использовано 1625 записей ЭКГ	99,3347%
Модель: многослойный перцептрон (MLP) [20]. Задача: классификация аритмии в реальном времени.	MIT-BIH Arrhythmia database, для обучения использовано 23 276 записей, для тестирования – 85 432 записей	97,08%
Модель: Extreme Learning Machine (ELM) [21]. Задача: классификация сердечбиения с несколькими классами на основе гибридных временных характеристик.	MIT-BIH Arrhythmia database, для обучения использовано 1482 записей ЭКГ	93,72%
Модель: объединение рекуррентной нейронной сети и сети с 33 слоями свертки [22]. Задача: классификация аритмий на маленьких dataset на предобученных сетях.	Physio net/CinC Challenge 2017dataset	86%
Модель: 2-х слойная (с 80/40 нейронов) рекуррентная сеть с долгой краткосрочной памятью [23]. Задача: распознавание сердечных аномалий на фотоплетизмограммах.	400 000 фотоплетизмограмм	83%

Продолжение таблицы 1

Модель: ограниченная машина Больцмана (RBN) [24]. Задача: классификация аномалий с помощью метода снижения частоты ложных тревог.	Physio net/CinC Challenge 2017dataset	79%
Модель: скрытая полумарковская модель (HSMM) с 64 начальными состояниями для каждого класса в неконтролируемой обстановке. Всего ансамбль моделей состоит из 15 рекуррентных сетей и 4 HSMM. Прогнозирующий вектор – объединение нормализованных логарифмических вероятностей ЭКГ для каждого класса HSMM и выходных данных softmax-слоя рекуррентной сети [25]. Задача: обнаружение аритмий.	MIT-BIH Arrhythmia database, для обучения использовано 12 186 записей ЭКГ	99,97

Как видно из табл. 1, лучшие результаты показали глубокие сверточные сети в задаче обнаружения и классификации аритмии (более 99%). Практически все модели выполняют классификацию по записям ЭКГ, не используют аудиосигнал ФКГС. Наиболее часто используемым набором данных является MIT-BIH Arrhythmia database, который содержит длительные записи ЭКГ (до 30 минут), размеченные на большое количество классов, что дает возможность исследователям сосредоточиться на решении задач классификации конкретных типов аритмий [26].

Разрабатываемая диагностическая система должна анализировать изображения скейлограмм ФКГС и определять аномалии, характерные для ряда заболеваний сердца, для чего необходимо выбрать базовую модель CNN среди современных архитектур сетей, показавших высокую эффективность в классификации изображений.

## Выбор базовой модели нейронной сети для задачи диагностики заболеваний сердца

Выбор базовой архитектуры CNN производился путем выбора модели по двум критериям: точности и скорости обучения. Для чего реализованы архитектуры современных сверточных сетей VGG [27], Inception [28], ResNet [29] и DenseNet, которые являются результатом развития сети ResNet и основываются на их остаточных блоках [30], а также Xception, являющейся модификацией Inception [31]. Эти архитектуры в разное время стали победителями соревнований ImageNet Large Scale Visual Classification Challenge, которые проводятся с 2012 года [32].

Обучение нейронных сетей проходило на сервисе Colaboratory. В CNN чем выше уровень, тем он более специализирован, первые же несколько слоев изучают очень простые и общие функции, которые распространяются практически на все типы изображений. По мере наращивания слоев эти функции становятся все более специфичными для набора данных, на котором модель обучается, т.е. проводится ее «тонкая настройка», цель которой – адаптировать эти специализированные функции для работы с новым набором данных, а не перезаписывать общее обучение. В связи с этим для повышения производительности использовались предобученные модели на ImageNet.

Для обучения моделей использовался набор данных [33], содержащий 821 запись ФКГС продолжительностью от 1 секунды до 30 секунд, с частотой дискретизации 22 050 Hz, разбитый на 5 классов: «Нормальное сердцебиение», «Сердцебиение с шумами», «Экстрасистолия», «Сердцебиение с артефактами», «Дополнительный звук сердца». Выборка делилась на обучающую 1693 записи и тестовую 821 запись.

Для каждого аудиосигнала выбирался отрезок длиной 88 200 отсчетов (2 секунды) и выполнялось вейвлет-преобразование Морле с коэффициентом масштабирования 1.1, после чего генерировалось изображение скейлограммы в формате jpg, разрешением 840×456 и глубиной цвета 24. Сгенерированные изображения подавались на вход сетей для их обучения. Примеры амплитудно-временного представления ФКГС и соответствующего ему изображения скейлограммы демонстрируют рис. 2, 3.

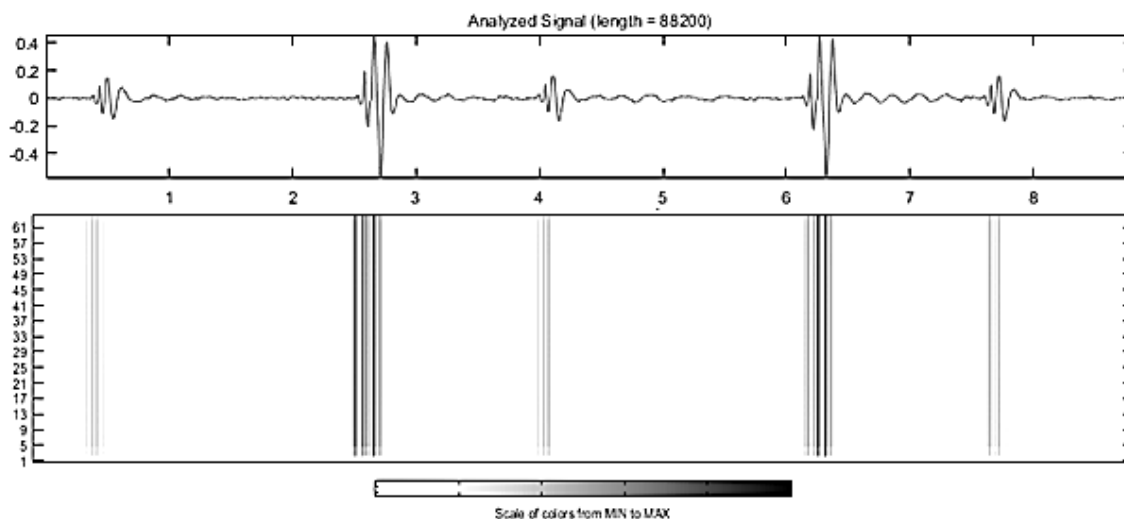


Рисунок 2 – Амплитудно-временное представление нормального сердцебиения (вверху) и его скейлограмма (внизу)

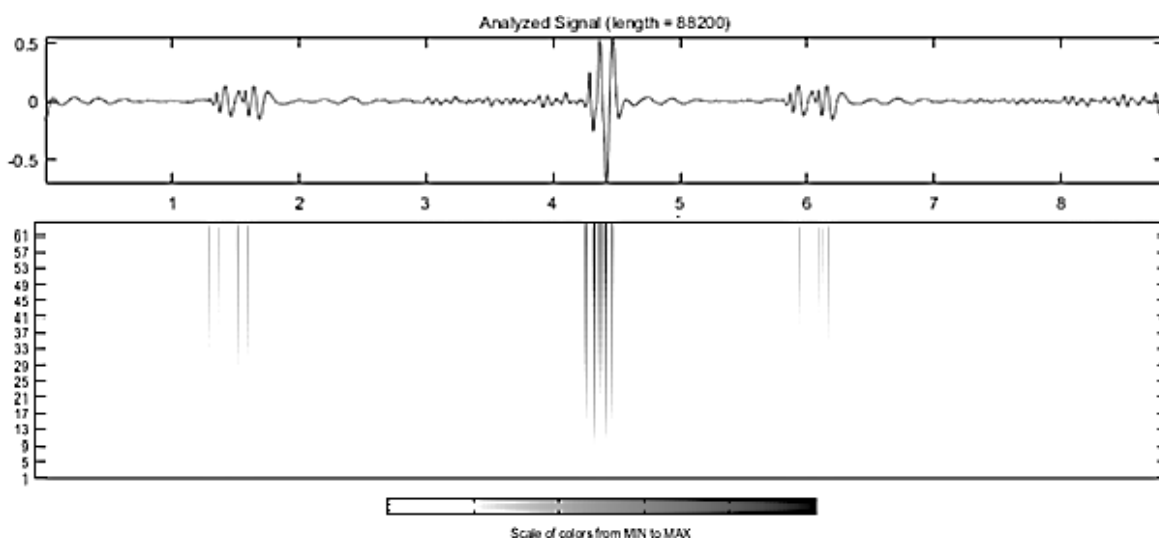


Рисунок 3 – Амплитудно-временное представление сердцебиения с шумами (вверху) и его скейлограмма (внизу)

Сети с вышеуказанными архитектурами реализованы со следующими гиперпараметрами:

- размер батча: 256;
- функция активации для скрытых слоёв: rectified linear unit;
- функция активации выходного слоя: softmax;
- функция потерь: разреженная кросс-энтропия;



- функция регуляризации: L2-регуляризация;
- оптимизатор для градиентного спуска: Adamax;
- коэффициент скорости обучения: 0,0005;
- количество эпох: 10.

Таблица 2 – Показатели эффективности моделей в задаче диагностики заболеваний сердца по скейлограммам ФКГС

Модель	Точность, %	Время обучения
VGG16	65,34	21м 31с
VGG19	61,59	21м 51с
InceptionV3	98,81	5м 57с
DenseNet121	95,31	5м 40с
ResNet50	58,48	6м 25с
Xception	90,76	6м 34с

Как видно из табл. 2, лучшие результаты показали модели InceptionV3 и DenseNet121. В качестве базовой модели для построения диагностической системы выбрана архитектура InceptionV3, обладающая более высокой точностью.

## Выводы

Вейвлет-анализ наиболее приспособлен для обработки ФКГС, т.к. позволяет одновременно выполнять частотный анализ, локализовать место проявления шумов и оценивать их характеристики. Проведенные исследования информативности по энтропийному критерию ряда вейвлет-базисов показали, что наиболее оптимальным материнским вейвлетом для анализа ФКГС является вейвлет Морле, показавший наилучший результат как нормального сердцебиения, так и при определенных патологиях по всем классам аномалий.

Преимущества использования нейросетей при разработке медицинских диагностических систем перед статистическими методами заключаются в способности обучения на больших множествах параметров при неизвестных закономерностях между входными и выходными данными. В результате анализа использования различных моделей нейронных сетей в задаче обнаружения и классификации аномалий сердцебиения лучшие результаты показали глубокие сверточные сети. В рамках данного исследования по точности классификации изображений скейлограмм ФКГС и скорости обучения сравнивались архитектуры CNN, ставшие победителями в соревнованиях ImageNet Large Scale Visual Classification Challenge. Наилучший результат по точности показала модель InceptionV3 (более 98% на тестовой выборке), уступая при этом всего 17 секунд наилучшему результату по скорости обучения, который принадлежит архитектуре DenseNet121. В связи с этим в качестве базовой модели для диагностической системы заболеваний сердца по изображению скейлограмм звуков сердцебиения целесообразно выбрать InceptionV3.

## Список литературы

1. Крижановский В. В. Некоторые возможности повышения эффективности спектрального анализа низкочастотных тонов акустических кардиосигналов [Электронный ресурс] / В. В. Крижановский, В. В. Крижановский (мл.). // Акустичний вісник. – 2013-2014. – Том 16, № 1. – С. 33–46. – URL: [https://journals.kpi.ua/publications/text/2009\\_1\\_148\\_155.pdf](https://journals.kpi.ua/publications/text/2009_1_148_155.pdf) (дата обращения: 22.12.2021).

2. Порева А. С. Обработка ФКГ-сигнала при помощи вейвлет-преобразования [Электронный ресурс] / А. С. Порева, В. А. Фесечко // Электроника и связь. Тематический выпуск «Электроника и нанотехнологии». – Ч. 1, 2009. – С. 148-155. – URL: [https://journals.kpi.ua/publications/text/2009\\_1\\_148\\_155.pdf](https://journals.kpi.ua/publications/text/2009_1_148_155.pdf) (дата обращения: 22.12.2021).
3. Farshad Arvin. Frequency shifting approach towards textual transcription of heartbeat sounds [Электронный ресурс] / Farshad Arvin, Shyamala Doraisamy, Ehsan Safar Khorasani // Biological Procedures Online, 2011. – Vol. 13. DOI: 10.1186/1480-9222-13-77. – URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3396354/pdf/1480-9222-13-7.pdf> (дата обращения: 22.12.2021).
4. Новое о колебательных процессах в сердечном ритме (непрерывный вейвлет-анализ) [Электронный ресурс] / Куклин Сергей Германович, Михалеви́ч Исай Моисеевич, Рожкова Нина Юрьевна, Дзизинский Александр Александрович, Титов Юрий Михайлович, Темников Андрей Александрович // Пространство и Время. – 2013. – № 4 (14). – URL: <https://cyberleninka.ru/article/n/novoe-o-kolebatelnyh-protsessah-v-serdechnom-ritme-neprevyvu-veyvlet-analiz> (дата обращения: 22.12.2021).
5. Астафьева Н.М. Вейвлет-анализ: основы теории и некоторые приложения // Успехи физических наук. – 1998. – №11. – С.1145-1170.
6. Ермоленко Т. В. Применение вейвлет-преобразования для обработки и распознавания речевых сигналов [Текст] / Т. В. Ермоленко // Искусственный интеллект. – 2002. – № 4. – С. 200–208.
7. MathWorks Documentation [Электронный ресурс]. – URL: <https://www.mathworks.com/help/wavelet/ref/cwt.html#bvayt13-3> (дата обращения: 22.12.2021).
8. The truth of the F-measure [Электронный ресурс]. – URL: <https://www.toyota-ti.ac.jp/Lab/Denshi/COIN/people/yutaka.sasaki/F-measure-YS-26Oct07.pdf> (дата обращения: 22.12.2021).
9. Weiyi Yang. A Novel Approach for Multi-Lead ECG Classification Using DL-CCANet and TL-CCANet [Электронный ресурс] / Weiyi Yang, Yujuan Si, Di Wang, Gong Zhang // Sensors (Basel), 2019. – Vol. 19(14). – DOI:10.3390/s19143214. – URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6679505/pdf/sensors-19-03214.pdf> (дата обращения: 22.12.2021).
10. Development and Validation of a Deep-Learning Model to Screen for Hyperkalemia From the Electrocardiogram [Электронный ресурс] / Conner D. Galloway, Alexander V. Valys, Jacqueline B. Shreibati et al. // JAMA Cardiology, 2019. – Vol. 4(5). – P. 428-436. DOI: 10.1001/jamacardio.2019.0640. – URL: <https://jamanetwork.com/journals/jamacardiology/fullarticle/2729582> (дата обращения: 22.12.2021).
11. Savalia, S. Cardiac arrhythmia classification by multi-layer perceptron and convolution neural networks [Электронный ресурс] / S. Savalia, V. Emamian // Bioengineering, 2018. – Vol. 5(2). DOI: 10.3390/bioengineering5020035. – URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6027502/pdf/bioengineering-05-00035.pdf> (дата обращения: 22.12.2021).
12. Weiyi Yang. Automatic recognition of arrhythmia based on principal component analysis network and linear support vector machine [Электронный ресурс] / Weiyi Yang, Yujuan Si, Di Wang, Buhao Guo // Computers in biology and medicine, 2018. – Vol. 101. – P. 22-32. DOI: 10.1016/j.compbiomed.2018.08.003. – URL: <https://www.sciencedirect.com/science/article/pii/S001048251830221X> (дата обращения: 22.12.2021).
13. Identification of 27 abnormalities from multi-lead ECG signals: an ensembled SE\_ResNet framework with Sign Loss function [Электронный ресурс] / Zhaowei Zhu, Xiang Lan, Tingting Zhao et al. // arXiv.org. 2011. – URL: <https://arxiv.org/pdf/2101.03895.pdf> (дата обращения: 22.12.2021).
14. Arrhythmia detection using deep convolutional neural network with long duration ECG signals [Электронный ресурс] / Yıldırım Özal, Pławiak Paweł, Tan Ru San, Acharya U. Rajendra // Computers in biology and medicine, 2018. – Vol. 102. – P. 411-420. DOI: 10.1016/j.compbiomed.2018.09.009. – URL: [https://www.researchgate.net/publication/327602644\\_Arrhythmia\\_Detection\\_Using\\_Deep\\_Convolutional\\_Neural\\_Network\\_With\\_Long\\_Duration\\_ECG\\_Signals](https://www.researchgate.net/publication/327602644_Arrhythmia_Detection_Using_Deep_Convolutional_Neural_Network_With_Long_Duration_ECG_Signals) (дата обращения: 22.12.2021).
15. (2019). A Novel Deep Arrhythmia-Diagnosis Network for Atrial Fibrillation Classification Using Electrocardiogram Signals [Электронный ресурс] / Dang, H., Sun, M., Zhang, G., Qi, X., Zhou, X., and Chang, Q. // IEEE Access, 2019. – Vol. 7. – P. 75577-75590. DOI: 10.1109/ACCESS.2019.2918792. – URL: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8721643> (дата обращения: 22.12.2021).
16. Constrained transformer network for ECG signal processing and arrhythmia classification [Электронный ресурс] / Chao Che, Peiliang Zhang, Min Zhu, Yue Qu, Bo Jin. // BMC Medical Informatics and Decision Making, 2021. – Vol. 184. – URL: <https://link.springer.com/article/10.1186/s12911-021-01546-2> (дата обращения: 22.12.2021).

17. B. Hou J. LSTM-Based Auto-Encoder Model for ECG Arrhythmias Classification [Электронный ресурс] / B. Hou J. Yang P., Wang R. Yan // IEEE Transactions on Instrumentation and Measurement, 2020. – Vol. 69, № 4. – P. 1232-1240. DOI: 10.1109/TIM.2019.2910342. – URL: <https://ieeexplore.ieee.org/document/8688435> (дата обращения: 22.12.2021).
18. Yinsheng Ji. Electrocardiogram Classification Based on Faster Regions with Convolutional Neural Network. [Электронный ресурс] / Yinsheng Ji, Sen Zhang, Wendong Xiao // Sensors (Basel), 2019 – Vol. 19(11):2558. DOI: 10.3390/s19112558. – URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6603727/pdf/sensors-19-02558.pdf> (дата обращения: 22.12.2021).
19. Li D. Deep residual convolutional neural network for recognition of electrocardiogram signal arrhythmias [Электронный ресурс] / Li D, Zhang H, Liu Z, Huang J, Wang T. // Journal of biomedical engineering, 2019. – Vol. 36(2). – P. 189-198. DOI: 10.7507/1001-5515.201712031. – URL: <https://pubmed.ncbi.nlm.nih.gov/31016934/> (дата обращения: 22.12.2021).
20. Ihsanto Eko. Real-Time Classification for Cardiac Arrhythmia ECG Beat [Электронный ресурс] / Ihsanto Eko, Ramli Kalamullah, Sudiana Dodi // 16th International Conference on Quality in Research (QIR): International Symposium on Electrical and Computer Engineering, 2019. – DOI: 10.1109/QIR.2019.8898298. – URL: [https://www.researchgate.net/publication/337504579\\_Real-Time\\_Classification\\_for\\_Cardiac\\_Arrhythmia\\_ECG\\_Beat](https://www.researchgate.net/publication/337504579_Real-Time_Classification_for_Cardiac_Arrhythmia_ECG_Beat) (дата обращения: 22.12.2021).
21. Classification of Arrhythmia Based on Extreme Learning Machine [Электронный ресурс] / Xingjin Zhang, Runchuan Li, Yongpeng Liu et al. // 10th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC), 2018. – Vol. 2. – P. 123-126. – DOI: 10.1109/IHMSC.2018.10135. – URL: <https://ieeexplore.ieee.org/document/8530196> (дата обращения: 22.12.2021).
22. Chen L. Transfer Learning for Electrocardiogram Classification Under Small Dataset [Текст] / Chen L., Xu G., Zhang S., Kuang J., Hao L. // Machine Learning and Medical Engineering for Cardiovascular Health and Intravascular Imaging and Computer Assisted Stenting. MLMECH 2019, CVII-STENT 2019. Lecture Notes in Computer Science, 2019. – Vol. 11794. – P. 45-54.
23. Recognizing Cardiac Abnormalities in Wearable Device Photoplethysmography (PPG) with Deep Learning [Электронный ресурс] / Stewart Whiting, Samuel Moreland, Jason Costello, Glen Colopy, Christopher McCann // arXiv.org. 2018. – URL: <https://arxiv.org/pdf/1807.04077.pdf> (дата обращения: 22.12.2021).
24. Tajji B. False Alarm Reduction in Atrial Fibrillation Detection Using Deep Belief Networks [Текст] / B. Tajji, A. D. Chan, S. Shirmohammad. // IEEE Transactions on Instrumentation and Measurement, 2018. – Vol. 67, № 5. – P. 1124–1131. DOI: 10.1109/TIM.2017.2769198.
25. Beat by beat: Classifying cardiac arrhythmias with recurrent neural networks [Электронный ресурс] / Patrick Schwab, Gaetano Scabbia, Jia Zhang, Marco Delai, Walter Karlen // arXiv.org. 2017. – URL: <https://arxiv.org/pdf/1710.06319.pdf> (дата обращения: 22.12.2021).
26. Мустафаев А. Г. Использование нейросетевых методов для автоматического анализа электрокардиограмм при диагностике заболеваний сердечно-сосудистой системы [Электронный ресурс] / А. Г. Мустафаев // Кибернетика и программирование, 2019. – № 1. – С. 66-74. DOI: 10.25136/2306-4196.2019.1.19343. – URL: [https://nbpublish.com/library\\_read\\_article.php?id=19343](https://nbpublish.com/library_read_article.php?id=19343) (дата обращения: 22.12.2021).
27. Karen Simonyan. Very deep convolutional networks for large-scale image recognition [Электронный ресурс] / Karen Simonyan, Andrew Zisserman // arXiv.org. 2014. – URL: <https://arxiv.org/pdf/1409.1556.pdf> (дата обращения: 28.12.2021).
28. Rethinking the Inception Architecture for Computer Vision [Электронный ресурс] / Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jonathon Shlens, Zbigniew Wojna // arXiv.org. 2015. – URL: <https://arxiv.org/pdf/1512.00567.pdf> (дата обращения: 28.12.2021).
29. Kaiming He. Deep Residual Learning for Image Recognition [Электронный ресурс] / Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. // arXiv.org. 2015. – URL: <https://arxiv.org/pdf/1512.03385.pdf> (дата обращения: 28.12.2021).
30. Weinberger. Densely connected convolutional networks [Электронный ресурс] / Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. // arXiv.org. 2016. – URL: <https://arxiv.org/pdf/1610.02357.pdf> (дата обращения: 28.12.2021).
31. François Chollet. Xception: deep learning with depthwise separable convolutions [Электронный ресурс] // arXiv.org. 2017. – URL: <https://arxiv.org/pdf/1610.02357.pdf> <https://arxiv.org/pdf/1610.02357.pdf> (дата обращения: 28.12.2021).
32. ImageNet Large Scale Visual Recognition Competition 2014 (ILSVRC2014) [Электронный ресурс]. – URL: <http://www.image-net.org/challenges/LSVRC/2014/results> (дата обращения: 28.12.2021).

33. Heartbeat Sounds. Classifying heartbeat anomalies from stethoscope audio [Электронный ресурс]. – URL: <https://www.kaggle.com/kinguistics/heartbeat-sounds> (дата обращения: 28.12.2021).
34. Распознавание параметров variability сердечного ритма по кардиосигналу в процессе баротерапии [Текст] / Кравченко Н. М., Ладария Е. Г., Ключанова Т. Д., Бондарчук В. В. // Международный рецензируемый научно-теоретический журнал «Проблемы искусственного интеллекта». – 2020. – № 2 (17). – С. 28–35.

## References

1. Krizhanovskij V.V., Krizhanovskij V.V. (ml.). Nekotorye vozmozhnosti povysheniya effektivnosti spektral'nogo analiza nizkochastotnyh tonov akusticheskikh kardiosignalov [Some possibilities of increasing the efficiency of spectral analysis of low-frequency tones of acoustic cardiosignals] [Elektronnyj resurs] // *Akustichnij visnik* [Acoustic visnik] 2013-2014. Tom 16, № 1. S. 33–46. URL: [https://journals.kpi.ua/publications/text/2009\\_1\\_148\\_155.pdf](https://journals.kpi.ua/publications/text/2009_1_148_155.pdf) (data obrashcheniya: 22.12.2021).
2. Poreva A.S., Fesechko V.A. Obrabotka FKG-signalov pri pomoshchi vejvlet-preobrazovaniya [Processing of the PCG signal using wavelet transform] [Elektronnyj resurs] *Elektronika i svyaz'. Tematicheskij vypusk «Elektronika i nanotekhnologii»* [Electronics and communication. Thematic issue "Electronics and Nanotechnologies"], ch.1, 2009. – S. 148-155. – URL: [https://journals.kpi.ua/publications/text/2009\\_1\\_148\\_155.pdf](https://journals.kpi.ua/publications/text/2009_1_148_155.pdf) (data obrashcheniya: 22.12.2021).
3. Farshad Arvin, Shyamala Doraisamy, Ehsan Safar Khorasani. Frequency shifting approach towards textual transcription of heartbeat sounds [Elektronnyj resurs]. *Biological Procedures Online*, 2011. Vol. 13. DOI: 10.1186/1480-9222-13-77. URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3396354/pdf/1480-9222-13-7.pdf> (data obrashcheniya: 22.12.2021).
4. Kuklin Sergej Germanovich, Mihalevich Isaj Moiseevich, Rozhkova Nina YUr'evna, Dzizinskij Aleksandr Aleksandrovich, Titov YUrij Mihajlovich, Temnikov Andrej Aleksandrovich Novoe o kolebatel'nyh processah v serdechnom ritme (nepreryvnyj vejvlet-analiz) [New about oscillatory processes in the heart rhythm (continuous wavelet analysis)] [Elektronnyj resurs]. *Prostranstvo i Vremya* [Space and Time], 2013, №4 (14), URL: <https://cyberleninka.ru/article/n/novoe-o-kolebatel'nyh-protsessah-v-serdechnom-ritme-nepreryvnyy-vejvlet-analiz> (data obrashcheniya: 22.12.2021).
5. Astaf'eva N.M. Vejvlet-analiz: osnovy teorii i nekotorye prilozheniya [Wavelet analysis: foundations of theory and some applications] *Uspekhi fizicheskikh nauk* [Uspekhi fizicheskikh nauk], 1998, №11, S.1145-1170.
6. Yermolenko T. V. Primenenie vejvlet-preobrazovaniya dlya obrabotki i raspoznavaniya rechevykh signalov [Application of wavelet transform for processing and recognition of speech signals] *Iskusstvennyj intellekt* [Artificial intelligence], 2002, № 4, S. 200-208.
7. *MathWorks Documentation* [Elektronnyj resurs]. URL: <https://www.mathworks.com/help/wavelet/ref/cwt.html#bvayt13-3> (data obrashcheniya: 22.12.2021).
8. *The truth of the F-measure* [Elektronnyj resurs]. URL: <https://www.toyota-ti.ac.jp/Lab/Denshi/COIN/people/yutaka.sasaki/F-measure-YS-26Oct07.pdf> (data obrashcheniya: 22.12.2021).
9. Weiyi Yang, Yujuan Si, Di Wang, Gong Zhang. A Novel Approach for Multi-Lead ECG Classification Using DL-CCANet and TL-CCANet [Elektronnyj resurs]. *Sensors (Basel)*, 2019. Vol. 19(14). DOI:10.3390/s19143214. URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6679505/pdf/sensors-19-03214.pdf> (data obrashcheniya: 22.12.2021).
10. Conner D. Galloway, Alexander V. Valys, Jacqueline B. Shreibati et al. Development and Validation of a Deep-Learning Model to Screen for Hyperkalemia From the Electrocardiogram [Elektronnyj resurs]. *JAMA Cardiology*, 2019. Vol. 4(5). P. 428-436. DOI: 10.1001/jamacardio.2019.0640. URL: <https://jamanetwork.com/journals/jamacardiology/fullarticle/2729582> (data obrashcheniya: 22.12.2021).
11. Savalia, S., Emamian, V. Cardiac arrhythmia classification by multi-layer perceptron and convolution neural networks [Elektronnyj resurs]. *Bioengineering*, 2018. Vol. 5(2). DOI: 10.3390/bioengineering5020035. URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6027502/pdf/bioengineering-05-00035.pdf> (data obrashcheniya: 22.12.2021).
12. Weiyi Yang, Yujuan Si, Di Wang, Buhao Guo. Automatic recognition of arrhythmia based on principal component analysis network and linear support vector machine [Elektronnyj resurs]. *Computers in biology and medicine*, 2018. Vol. 101. P. 22-32. DOI: 10.1016/j.compbiomed.2018.08.003. URL: <https://www.sciencedirect.com/science/article/pii/S001048251830221X> (data obrashcheniya: 22.12.2021).
13. Zhaowei Zhu, Xiang Lan, Tingting Zhao et al. Identification of 27 abnormalities from multi-lead ECG signals: an ensemble SE\_ResNet framework with Sign Loss function [Elektronnyj resurs]. *arXiv.org*. 2011. URL: <https://arxiv.org/pdf/2101.03895.pdf> (data obrashcheniya: 22.12.2021).
14. Yıldırım Özal, Pławiak Paweł, Tan Ru San, Acharya U. Rajendra. Arrhythmia detection using deep convolutional neural network with long duration ECG signals [Elektronnyj resurs]. *Computers in biology and medicine*, 2018. Vol. 102. P. 411-420. DOI: 10.1016/j.compbiomed.2018.09.009.

- URL: [https://www.researchgate.net/publication/327602644\\_Arrhythmia\\_Detection\\_Using\\_Deep\\_Convolutional\\_Neural\\_Network\\_With\\_Long\\_Duration\\_ECG\\_Signals](https://www.researchgate.net/publication/327602644_Arrhythmia_Detection_Using_Deep_Convolutional_Neural_Network_With_Long_Duration_ECG_Signals) (data obrashcheniya: 22.12.2021).
15. Dang, H., Sun, M., Zhang, G., Qi, X., Zhou, X., and Chang, Q., (2019). A Novel Deep Arrhythmia-Diagnosis Network for Atrial Fibrillation Classification Using Electrocardiogram Signals [Elektronnyj resurs]. *IEEE Access*, 2019. Vol. 7. P. 75577-75590. DOI: 10.1109/ACCESS.2019.2918792. URL: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8721643> (data obrashcheniya: 22.12.2021).
  16. Chao Che, Peiliang Zhang, Min Zhu, Yue Qu, Bo Jin. Constrained transformer network for ECG signal processing and arrhythmia classification [Elektronnyj resurs] *BMC Medical Informatics and Decision Making*, 2021. Vol. 184. URL: <https://link.springer.com/article/10.1186/s12911-021-01546-2> (data obrashcheniya: 22.12.2021).
  17. B. Hou J. Yang P., Wang R. Yan. LSTM-Based Auto-Encoder Model for ECG Arrhythmias Classification [Elektronnyj resurs]. *IEEE Transactions on Instrumentation and Measurement*, 2020, Vol. 69, № 4, P. 1232-1240. DOI: 10.1109/TIM.2019.2910342, URL: <https://ieeexplore.ieee.org/document/8688435> (data obrashcheniya: 22.12.2021).
  18. Yinsheng Ji, Sen Zhang, Wendong Xiao. Electrocardiogram Classification Based on Faster Regions with Convolutional Neural Network. [Elektronnyj resurs], *Sensors (Basel)*, 2019, Vol. 19(11):2558. DOI: 10.3390/s19112558, URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6603727/pdf/sensors-19-02558.pdf> (data obrashcheniya: 22.12.2021).
  19. Li D, Zhang H, Liu Z, Huang J, Wang T. Deep residual convolutional neural network for recognition of electrocardiogram signal arrhythmias [Elektronnyj resurs], *Journal of biomedical engineering*, 2019, Vol. 36(2), P. 189-198. DOI: 10.7507/1001-5515.201712031, URL: <https://pubmed.ncbi.nlm.nih.gov/31016934/> (data obrashcheniya: 22.12.2021).
  20. Ihsanto Eko, Ramli Kalamullah, Sudiana Dodi. Real-Time Classification for Cardiac Arrhythmia ECG Beat [Elektronnyj resurs]. *16th International Conference on Quality in Research (QIR): International Symposium on Electrical and Computer Engineering*, 2019. DOI: 10.1109/QIR.2019.8898298. URL: [https://www.researchgate.net/publication/337504579\\_Real-Time\\_Classification\\_for\\_Cardiac\\_Arrhythmia\\_ECG\\_Beat](https://www.researchgate.net/publication/337504579_Real-Time_Classification_for_Cardiac_Arrhythmia_ECG_Beat) (data obrashcheniya: 22.12.2021).
  21. Xingjin Zhang, Runchuan Li, Yongpeng Liu et al. Classification of Arrhythmia Based on Extreme Learning Machine [Elektronnyj resurs]. *10th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)*, 2018. Vol. 2. P. 123-126. DOI: 10.1109/IHMSC.2018.10135. URL: <https://ieeexplore.ieee.org/document/8530196> (data obrashcheniya: 22.12.2021).
  22. Chen L., Xu G., Zhang S., Kuang J., Hao L. Transfer Learning for Electrocardiogram Classification Under Small Dataset. *Machine Learning and Medical Engineering for Cardiovascular Health and Intravascular Imaging and Computer Assisted Stenting. MLMECH 2019, CVII-STENT 2019. Lecture Notes in Computer Science*, 2019, Vol. 11794, P. 45-54.
  23. Stewart Whiting, Samuel Moreland, Jason Costello, Glen Colopy, Christopher McCann. Recognizing Cardiac Abnormalities in Wearable Device Photoplethysmography (PPG) with Deep Learning [Elektronnyj resurs]. *arXiv.org. 2018*. URL: <https://arxiv.org/pdf/1807.04077.pdf> (data obrashcheniya: 22.12.2021).
  24. B. Taji, A. D. Chan, S. Shirmohammad. False Alarm Reduction in Atrial Fibrillation Detection Using Deep Belief Networks. *IEEE Transactions on Instrumentation and Measurement*, 2018, Vol. 67, № 5, P. 1124-1131. DOI: 10.1109/TIM.2017.2769198.
  25. Patrick Schwab, Gaetano Scabbia, Jia Zhang, Marco Delai, Walter Karlen. Beat by beat: Classifying cardiac arrhythmias with recurrent neural networks [Elektronnyj resurs]. *arXiv.org. 2017*. URL: <https://arxiv.org/pdf/1710.06319.pdf> (data obrashcheniya: 22.12.2021).
  26. Mustafaev A.G. Ispol'zovanie nejrosetevykh metodov dlya avtomaticheskogo analiza elektrokardiogramm pri diagnostike zabol'evanij serdechno-sosudistoj sistemy [Using neural network methods for automatic analysis of electrocardiograms in the diagnosis of diseases of the cardiovascular system] [Elektronnyj resurs]. *Kibernetika i programirovanie [Cybernetics and programming]* 2019, № 1, S. 66-74. DOI: 10.25136/2306-4196.2019.1.19343. URL: [https://nbpublish.com/library\\_read\\_article.php?id=19343](https://nbpublish.com/library_read_article.php?id=19343) (data obrashcheniya: 22.12.2021).
  27. Karen Simonyan, Andrew Zisserman. Very deep convolutional networks for large-scale image recognition [Elektronnyj resurs]. *arXiv.org. 2014*. URL: <https://arxiv.org/pdf/1409.1556.pdf> (data obrashcheniya: 28.12.2021).
  28. Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jonathon Shlens, Zbigniew Wojna. Rethinking the Inception Architecture for Computer Vision [Elektronnyj resurs]. *arXiv.org. 2015*. URL: <https://arxiv.org/pdf/1512.00567.pdf> (data obrashcheniya: 28.12.2021).
  29. Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. Deep Residual Learning for Image Recognition [Elektronnyj resurs]. *arXiv.org. 2015*. URL: <https://arxiv.org/pdf/1512.03385.pdf> (data obrashcheniya: 28.12.2021).
  30. Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger. Densely connected convolutional networks [Elektronnyj resurs]. *arXiv.org. 2016*. URL: <https://arxiv.org/pdf/1610.02357.pdf> (data obrashcheniya: 28.12.2021).

31. François Chollet. Xception: deep learning with depthwise separable convolutions [Elektronnyj resurs] *arXiv.org*. 2017. URL: <https://arxiv.org/pdf/1610.02357.pdf> <https://arxiv.org/pdf/1610.02357.pdf> (data obrashcheniya: 28.12.2021).
32. *ImageNet Large Scale Visual Recognition Competition 2014 (ILSVRC2014)* [Elektronnyj resurs]. URL: <http://www.image-net.org/challenges/LSVRC/2014/results> (data obrashcheniya: 28.12.2021).
33. *Heartbeat Sounds. Classifying heartbeat anomalies from stethoscope audio* [Elektronnyj resurs]. URL: <https://www.kaggle>.
34. Kravchenko N.M., Ladaria E.G., Klyushanova TD, Bondarchuk V.V. Raspoznavaniye parametrov varia-bel'nosti serdechnogo ritma po kardiosignalu v protsesse baroterapii [Recognition of heart rate variability parameters by cardiac signal in the process of barotherapy]. *Mezhdunarodnyy retsenziruyemyy nauchno-teoreticheskiy zhurnal «Problemy iskusstvennogo intellekta»* [International peer-reviewed scientific and theoretical journal "Problems of Artificial Intelligence"], 2020, No. 2 (17), P. 28–35.

## RESUME

*T. V. Yermolenko, D. V. Rolik*

### *Classification of Heart Abnormalities Using Deep Learning*

In this work, we studied the information content of wavelet bases used to analyze quasi-periodic signals, as well as the effectiveness of using convolutional neural networks in the development of medical diagnostic systems for detecting heart diseases.

The pathology of cardiac activity can be detected by analyzing the components of the phonocardiographic signal (PCGS), for which the wavelet analysis technique is used. The conducted experimental studies have shown that the most informative analyzing wavelet among the considered bases is the Morlet wavelet.

Based on the review of modern articles on digital medicine, the best results were shown by deep convolutional networks in the problem of detecting and classifying arrhythmias from ECG records, PCGS is practically not used, despite its availability, economy and knowledge of their time and frequency structure.

For a diagnostic system that analyzes images of PCGS scalograms, as a result of experimental studies, the InceptionV3 model was chosen as the basic architecture of a convolutional network, which makes it possible to classify a number of pathologies of cardiac activity with high accuracy and speed (more than 98%).

## РЕЗЮМЕ

*Т. В. Ермоленко, Д. В. Ролик*

### *Классификация аномалий сердцебиения с помощью глубокого обучения*

В данной работе проведены исследования информативности вейвлет-базисов, используемых для анализа квазипериодических сигналов, а также эффективности использования сверточных нейронных сетей при разработке медицинских диагностических систем для выявления сердечных заболеваний.

Патологию сердечной деятельности можно выявить, анализируя компоненты ФКГС, для чего используют технику вейвлет-анализа. Проведенные экспериментальные исследования показали, что наиболее информативным анализирующим вейвлетом среди рассмотренных базисов является вейвлет Морле.

Исходя из сделанного обзора современных статей по цифровой медицине, лучшие результаты показали глубокие сверточные сети в задаче обнаружения и классификации аритмии по записям ЭКГ, ФКГС практически не используется, несмотря на свою доступность, экономичность и изученность их временной и частотной структуры.

Для диагностической системы, анализирующей изображения скейлограмм ФКГС, в результате экспериментальных исследований выбрана модель InceptionV3 в качестве базовой архитектуры сверточной сети, позволяющей классифицировать с высокой точностью и быстродействием ряд патологий сердечной деятельности (более 98%).

Статья поступила в редакцию 15.12.2021.