



# МАТЭМАТЫКА

УДК 004.8:004.93

## АНАЛИЗ АРХИТЕКТУР СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ ОПРЕДЕЛЕНИЯ ВЕРОЯТНОСТИ ИНФАРКТА ПО ЦИФРОВОМУ ИЗОБРАЖЕНИЮ ЭЛЕКТРОКАРДИОГРАММЫ

П.Д. Кузнецова\*, Е.А. Корчевская\*, Т.В. Никонова\*\*

\*Учреждение образования «Витебский государственный  
университет имени П.М. Машерова»

\*\*Учреждение образования «Витебский государственный технологический университет»

*Сердечно-сосудистые заболевания остаются основной причиной смертности в мире, что делает разработку инновационных диагностических инструментов критически важной. Внедрение технологий искусственного интеллекта в кардиологию открывает новые возможности для повышения точности диагностики и качества медицинской помощи.*

*Цель работы — анализ эффективности различных архитектур нейронных сетей для автоматической постановки диагноза инфаркта по изображениям ЭКГ, а также определение оптимальной модели для практического применения.*

**Материал и методы.** В качестве ключевых подходов к автоматизации процесса диагностики кардиологических заболеваний можно использовать метод сравнения с эталоном и искусственные нейронные сети. Первый подход отражен в [1], где представлен алгоритм анализа кардиограмм с помощью метода вейвлет-преобразования сигналов стандартных отведений.

*Примером применения второго подхода является [2], в которой осуществлена попытка анализа электрокардиограмм посредством нейронных сетей. Здесь проводится моделирование электрокардиограмм различных сердечных заболеваний эквивалентным генератором сердца.*

**Результаты и их обсуждение.** Для решения задачи определения вероятности инфаркта разработаны и обучены различные архитектуры сверточных нейронных сетей. На обучение моделей были поданы 279 изображений ЭКГ здорового человека и 234 изображения ЭКГ с признаками инфаркта.

*Процесс обучения моделей проводился в течение 20 эпох с размером батча 32. Использовался оптимизатор Adam, функция потерь — бинарная кросс-энтропия, метрика — точность.*

**Заключение.** В ходе исследования сравнивались различные архитектуры сверточных нейронных сетей, предназначенные для автоматической оценки вероятности инфаркта миокарда на основе изображений электрокардиограммы. Анализ показал, что более глубокие и сложные модели с большим числом сверточных слоев и слоев подвыборки позволяют лучше выявлять характерные признаки патологии, что повышает точность и надежность диагностики. В то же время увеличение глубины сети требует самой тщательной настройки гиперпараметров и регуляризации для предотвращения переобучения.

**Ключевые слова:** электрокардиограмма, сверточные нейронные сети, сердечно-сосудистые заболевания, задача классификации.

# ANALYSIS OF CONVOLUTIONAL NEURAL NETWORK ARCHITECTURES IN PROBLEMS OF IDENTIFYING THE PROBABILITY OF A HEART ATTACK BY THE DIGITAL IMAGE OF ELECTROCARDIOGRAM

P.D. Kuznetsova\*, E.A. Korchevskaya\*, T.V. Nikonova\*\*

\*Education Establishment "Vitebsk State P.M. Masherov University"

\*\*Education Establishment "Vitebsk State Technological University"

*Cardiovascular diseases remain the leading cause of death worldwide, making the development of innovative diagnostic tools critical. The introduction of artificial intelligence technologies in cardiology opens up new opportunities to improve diagnostic accuracy and quality of medical care.*

*The aim of the work is to analyze the efficiency of various neural network architectures for automatic diagnosis of a heart attack based on ECG images, as well as to identify the optimal model for practical application.*

**Material and methods.** *The method of comparison with standards and artificial neural networks can be used as the main approach to automating the process of diagnosing cardiac diseases. The first approach is reflected in the work [1]. Here, an algorithm for analyzing cardiograms using the wavelet transform method of standard lead signals is presented.*

*An example of the use of the second approach is the work [2], which attempts to analyze electrocardiograms using neural networks. Here, electrocardiograms of various heart diseases are simulated using an equivalent heart generator.*

**Findings and their discussion.** *To solve the problem of spotting the probability of a heart attack, various architectures of convolutional neural networks were developed and trained. 279 ECG images of a healthy person and 234 ECG images with signs of a heart attack were submitted for training the models.*

*The models were trained over 20 epochs with a batch size of 32. The Adam optimizer was used, the loss function was binary cross-entropy, and the metric was accuracy.*

**Conclusion.** *The study compared different architectures of convolutional neural networks designed to automatically estimate the probability of myocardial infarction based on electrocardiogram images. The analysis showed that deeper and more complex models with a large number of convolutional layers and pooling layers allow better detection of characteristic signs of pathology, increasing the accuracy and reliability of diagnostics. At the same time, increasing the depth of the network requires very careful tuning of hyperparameters and regularization to prevent overfitting.*

**Key words:** *electrocardiogram, convolutional neural networks, cardiovascular diseases, classification problem.*

**В** настоящее время наблюдается активное развитие и внедрение цифровых технологий в различные сферы деятельности человека. Особенно значимым является интеграция искусственного интеллекта в медицинскую сферу, где технологии машинного обучения демонстрируют широкие возможности для диагностики заболеваний.

Сердечно-сосудистые заболевания остаются основной причиной смертности в мире, что делает разработку инновационных диагностических инструментов критически важной. Поэтому необходимо создавать новые алгоритмы, методы и программные продукты для диагностики кардиологических заболеваний по цифровым изображениям электрокардиограммы.

Цель работы — анализ эффективности различных архитектур нейронных сетей для автоматической постановки диагноза инфаркта по изображениям ЭКГ, а также определение оптимальной модели для практического применения.

**Материал и методы.** В качестве ключевых подходов к автоматизации процесса диагностики кардиологических заболеваний можно использовать метод сравнения с эталоном и искусственные нейронные сети. Первый подход отражен в [1], где описан алгоритм анализа кардиограмм с помощью метода вейвлет-преобразования сигналов стандартных отведений. Показано, что вейвлет-анализ сигналов отведений дает наглядное представление о характере кардиограммы с учетом как высокочастотных, так и низкочастотных составляющих. Предложен метод реконструкции эквипотенциальных поверхностей сердца, включая векторную диаграмму.

Примером применения второго подхода является [2], в которой осуществлена попытка анализа электрокардиограмм посредством нейронных сетей. Здесь проводится моделирование

электрокардиограмм различных сердечных заболеваний эквивалентным генератором сердца. С целью создания базы для обучения нейронной сети в исследовании используется эквивалентная модель генератора сердца, разработанная с применением алгоритмов реконструкции токовых источников по измеренным электрическим потенциалам для электрокардиографии. В результате генерации была произведена серия моделирований сердечных заболеваний (инфаркт, сужение просвета коронарных артерий). На полученных моделях ЭКГ выделены отличия от ЭКГ здорового человека, общие для всех типов патологий, а также отклонения, наиболее характерные только для одного типа заболевания. По этим отклонениям была создана таблица признаков, а затем корреляционная матрица, позволяющая выбрать наиболее значимые признаки для их последующего использования в качестве входных сигналов для обучения нейронной сети. Нейросеть была разработана в программе MATLAB, которая после обучения отличала модели ЭКГ без патологий от ЭКГ с патологиями, и во втором случае классифицировала подаваемые входные сигналы на категории по типу смоделированных заболеваний. Обучение нейросетей только на смоделированных данных имеет ряд существенных недостатков, которые могут негативно сказаться на качестве и надежности модели. Смоделированные данные создаются на основе гипотез и математических моделей, которые могут не полностью отражать реальные особенности электрокардиограмм у пациентов. Это снижает эффективность нейронной сети в реальных клинических условиях.

Сверточные нейронные сети являются более совершенными методами искусственного интеллекта и позволяют автоматически и более полно обращаться со всей информацией, содержащейся в сигнале, что повышает точность диагностики по сравнению с использованием заранее определенных матриц признаков.

Глубокое обучение — это особый раздел машинного обучения, демонстрирующий новый подход к поиску представления данных, делающий упор на изучении последовательных слоев все более значимых представлений. Количество слоев, на которые делится модель данных, называют глубиной модели. В глубоком обучении такие многослойные представления изучаются с помощью моделей нейронных сетей, структурированных в виде слоев.

Искусственные нейронные сети представляют собой математические модели, имитирующие работу человеческого мозга. Классическая модель искусственной нейронной сети направлена на воспроизведение общего механизма передачи нервных импульсов между нейронами. Сверточные нейронные сети являются специализированной разновидностью искусственной нейронной сети, которые фокусируются на математическом моделировании процесса обработки визуальной информации в коре головного мозга. В этом контексте роль визуального нервного импульса выполняет цифровое изображение. Основное применение такой сети связано с задачами обработки и анализа изображений. Их структура построена на основе математического нейронного слоя, который выступает в качестве базовой единицы сети, обеспечивающей эффективную работу с визуальными данными.

**Результаты и их обсуждение.** Для решения задачи определения вероятности инфаркта разработаны и обучены различные архитектуры сверточных нейронных сетей. На обучение моделей были поданы 279 изображений ЭКГ здорового человека и 234 изображения ЭКГ с признаками инфаркта. Итого: 513 изображений для обучения классификации [3].

Процесс обучения моделей проводился в течение 20 эпох с размером батча 32. Использовался оптимизатор Adam, функция потерь — бинарная кросс-энтропия, метрика — точность. В ходе обучения нашел применение разделенный на обучающую и валидационную части набор данных.

Сверточная нейронная сеть включает в себя несколько типов слоев:

1. Слой свертки или Convolutional Layer. Сверточные слои используют фильтры. Они служат для извлечения признаков. Выход слоя представляет набор карт признаков.
2. Слой активации, добавляющий нелинейность. Обычно этот слой использует функцию активации ReLU.
3. Слой субдискретизации или Pooling Layer (слой пулинга). Уменьшает размер карт признаков — берет максимум в окне.

Архитектура CNN представляет собой комбинацию этих слоев. Последовательность слоев зависит от типа решаемой задачи.

Сверточный слой — основа сверточных нейронных сетей, применяемых в задачах компьютерного зрения. Это может быть обнаружение объектов или определение принадлежности изображения к какому-либо классу. В сверточных слоях к входным данным используется операция свертки. Это позволяет извлекать различные признаки из изображений.

С каждым последующим сверточным слоем извлекаются признаки различных уровней. Первые слои, как правило, извлекают простые признаки, такие как текстуры или границы. Более глубокие слои захватывают объекты или формы. Увеличение количества сверточных слоев позволяет модели изучать более сложные и абстрактные представления данных. Хотя увеличение количества слоев может улучшить качество модели, это также может привести к переобучению, особенно если на обучение модели было подано небольшое количество входных данных [4].

Для операции свертки в сверточных нейронных сетях используются небольшие матрицы, которые называются ядрами или фильтрами. Фильтры указываются первым аргументом в слоях свертки, количество нейронов — первым аргументом в полносвязных слоях.

Для предотвращения переобучения нейронной сети следует добавить слой Dropout. Этот слой необходимо включить в архитектуру обучаемых нейронных сетей.

Dropout — регуляризатор, который во время обучения случайным образом «выключает» (зануляет) часть нейронов в слое с заданной вероятностью, что помогает предотвратить переобучение, заставляет модель не слишком сильно зависеть от конкретных нейронов и улучшить обобщающую способность.

В качестве архитектуры нейронной сети предложена следующая (рис.):

- количество слоев модели: 6;
- первый слой: сверточный слой с 32 фильтрами размером 3×3, с функцией активации ReLU;
- второй слой: подвыборочный слой размером 2×2;
- третий слой: слой выпрямления, преобразующий признаки в вектор;
- четвертый слой: полносвязный с 64 нейронами, с функцией активации ReLU и инициализатором весов `he_normal`;
- пятый слой: Dropout с вероятностью отключения нейронов 0.7 для регуляризации;
- шестой (выходной) слой: Dense с 1 нейроном и сигмоидальной функцией активации для бинарной классификации.




Рис. Архитектура сверточной нейронной сети

Входное изображение — черно-белое предварительно обработанное изображение с размером 224×224 пикселей. На входном изображении содержится визуальная информация, обрабатываемая нейронной сетью. На первом этапе модель применяет к изображению 32 фильтра размером 3×3. Каждый из фильтров проходит по изображению и извлекает определенные признаки. Это могут быть границы, текстуры, а также другие особенности изображения. В результате применения операции свертки получается новое изображение меньшего размера (на 2 пикселя с каждой стороны), где каждый пиксель — это результат обработки соответствующего участка исходного изображения. Следующий слой применяет к изображению, полученному на выходе предыдущего слоя, операцию максимального объединения. На этом шаге признаки изображения становятся более устойчивыми

к смещениям и уменьшается вычислительная нагрузка. В результате размер изображения уменьшается вдвое, получается более компактное представление данных с сохранением важных деталей изображения. Далее слой выпрямления преобразует извлеченные признаки изображения в одномерный вектор чисел. Этот вектор содержит все извлеченные признаки и служит входом для полносвязного слоя. Проходя через полносвязный слой, состоящий из 64 нейронов, каждый нейрон полносвязного слоя объединяет информацию всех признаков и учится распознавать сложные паттерны и комбинации признаков. Во время обучения, с помощью слоя Dropout, случайным образом отключается 70%. Это позволяет модели не переобучаться и лучше обобщать информацию. На последнем слое модель на выход подает число в промежутке от 0 до 1. Это число является вероятностью принадлежности к определенному классу («норма» или «инфаркт»). Указанное число можно интерпретировать как степень уверенности модели в своем решении.

Точность этой модели на тестовых данных составляет 100%. По результатам анализа нейросетью новых данных вероятность инфаркта на изображениях с инфарктом составляет 51%, на изображениях здоровых ЭКГ — 15%. Вероятность 51% свидетельствует о неспособности нейронной сети выделить признаки заболевания.

Для улучшения результатов работы нейронной сети можно изменить количество сверточных слоев. Архитектура второй нейронной сети с увеличением слоев свертки до 4:

- количество слоев: 12;
- первый слой: сверточный слой с 32 фильтрами размером 3×3, с функцией активации ReLU;
- второй слой: слой подвыборки размером 2×2;
- третий слой: сверточный слой с 64 фильтрами размером 3×3, активационная функция ReLU, инициализация весов he\_normal;
- четвертый слой: слой подвыборки размером 2×2;
- пятый слой: сверточный слой с 128 фильтрами размером 3×3, активационная функция ReLU, инициализация he\_normal;
- шестой слой: слой подвыборки размером 2×2;
- седьмой слой: сверточный слой с 256 фильтрами размером 3×3, активационная функция ReLU, инициализация he\_normal;
- восьмой слой: слой подвыборки размером 2×2;
- девятый слой: выпрямление для преобразования признаков в вектор;
- десятый слой: полносвязный с 64 нейронами, активационная функция ReLU, инициализация he\_normal;
- одиннадцатый слой: Dropout с вероятностью отключения 0.7 для предотвращения переобучения;
- двенадцатый (выходной) слой: Dense с одним нейроном и сигмоидальной функцией активации для бинарной классификации.

Точность модели на тестовых данных достигает 87%. Вероятность определения инфаркта на изображении ЭКГ составляет 76%.

Более глубокие модели имеют увеличенное количество параметров и с большей вероятностью переобучаются, особенно если объем данных недостаточен. Модель может с трудом обобщать на валидационных или тестовых данных. Увеличение количества сверточных слоев до 4 в нейросети не всегда приводит к улучшению точности, особенно в задачах, связанных с медицинскими данными, такими как определение признаков инфаркта на ЭКГ.

Третья архитектура нейронной сети содержит 2 слоя свертки:

- количество слоев: 8;
- первый слой: сверточный слой с 32 фильтрами размером 3×3, активационная функция ReLU, входная форма;
- второй слой: слой подвыборки размером 2×2;
- третий слой: сверточный слой с 64 фильтрами размером 3×3, активационная функция ReLU, инициализация весов he\_normal;
- четвертый слой: слой подвыборки размером 2×2;
- пятый слой: слой выпрямления для преобразования признаков в вектор;

- шестой слой: полносвязный с 64 нейронами, активационная функция ReLU, инициализация `he_normal`;
- седьмой слой: Dropout с вероятностью отключения 0.7 для регуляризации;
- восьмой (выходной) слой: Dense с 1 нейроном и сигмоидальной функцией активации для бинарной классификации.

Точность данной архитектуры достигает 98%. На новых изображениях ЭКГ, которые классифицированы как изображения с инфарктом, вероятность инфаркта составляет 96%.

**Заключение.** В ходе исследования сравнивались различные архитектуры сверточных нейронных сетей, предназначенных для автоматической оценки вероятности инфаркта миокарда на основе изображений электрокардиограммы. Анализ показал, что более глубокие и сложные модели с большим числом сверточных слоев и слоев подвыборки позволяют лучше выявлять характерные признаки патологии, то повышает точность и надежность диагностики. В то же время увеличение глубины сети требует самой тщательной настройки гиперпараметров и регуляризации для предотвращения переобучения.

Использование современных методов инициализации весов, таких как `he_normal`, а также регуляризация Dropout улучшают обобщающую способность моделей. В результате экспериментов было установлено, что оптимальная архитектура должна балансировать между сложностью и вычислительной эффективностью, обеспечивая высокую точность при минимальных затратах времени обучения.

В результате исследования для решения задачи определения вероятности инфаркта была подобрана оптимальная архитектура нейронной сети. На вход нейросети подаются изображения электрокардиограммы с 12 отведениями. Это позволяет комплексно оценить вероятность заболевания.

Данное исследование подтверждает перспективность применения сверточных нейросетей в автоматизированной диагностике сердечно-сосудистых заболеваний по электрокардиограммам.

### ЛИТЕРАТУРА

1. Леонова, М.Д. Анализ электрокардиограмм посредством нейронных сетей / М.Д. Леонова // Международный научно-исследовательский журнал. — 2015. — № 4(35). — URL: <https://research-journal.org/archive/4-35-2015-may/analiz-elektrokardiogramm-posredstvom-nejronnyx-setej> (дата обращения: 12.04.2025).
2. Бокхан, Ю.И. Метод вейвлет-анализа отведений кардиограмм / Ю.И. Бокхан // Проблемы инфокоммуникаций. — 2018. — № 2. — С. 95–100.
3. ECG Images dataset of Cardiac Patients. — URL: <https://data.mendeley.com/datasets/gwbz3fsgp8/2> (date of access: 14.04.2025).
4. Шолле, Ф. Глубокое обучение на Python / Франсуа Шолле. — СПб.: Питер, 2023. — 576 с.

### REFERENCES

1. Leonova M.D. *Mezhdunarodny nauchno-issledovatel'ski zhurnal* [International Research Journal]. 2015, 4(35). — URL: <https://research-journal.org/archive/4-35-2015-may/analiz-elektrokardiogramm-posredstvom-nejronnyx-setej> (date of access: 12.04.2025).
2. Bokhan Yu.I. *Problemy infokommunikatsii* [Issues of Infocommunication]. 2018, 2, pp. 95–100.
3. ECG Images dataset of Cardiac Patients. — URL: <https://data.mendeley.com/datasets/gwbz3fsgp8/2> (date of access: 14.04.2025).
4. Chollet F. *Glubokoye obucheniye na Python* [Python Deep Training], SPb.: Piter, 2023, 576 p.

Поступила в редакцию 29.05.2025

Адрес для корреспонденции: e-mail: [Korchevskaya.Elena@gmail.com](mailto:Korchevskaya.Elena@gmail.com) — Корчевская Е.А.