

Разработка нейронной сети для отслеживания негативных изменений в сердечно-сосудистой системе человека на основе сигналов пульсовых волн

С. Мсукар,^{1*} Р. В. Давыдов^{1†}

¹Санкт-Петербургский Политехнический университет Петра Великого,
институт компьютерных наук и кибербезопасности,
высшая школа управления кибер-физическими системами
Россия, 195251, Санкт-Петербург, ул. Политехническая, д. 29
(Поступила в редакцию 10.06.2025; подписана в печать 01.11.2025)

Сердечно-сосудистые заболевания являются одной из основных причин смертности во всём мире, что делает критически важным раннее выявление патологических изменений для своевременного принятия мер. В данной работе представлена разработанная нейросетевая модель, предназначенная для обнаружения и отслеживания негативных изменений в сердечно-сосудистой системе человека путём анализа сигналов пульсовой волны. В исследовании используется медицинский датасет, содержащий 657 записей данных от 219 пациентов. Датасет охватывает возрастной диапазон 20–89 лет и включает записи о наличии и стадии заболевания. Данные были отфильтрованы и обработаны для извлечения признаков. После обучения модель продемонстрировала точность 93% на тестовых данных, что подтверждает её потенциал для интеграции в носимые устройства и системы дистанционного мониторинга здоровья.

PACS: 87.10.+e

УДК: 612.16

Ключевые слова: сердечно-сосудистые заболевания, обработка пульсовой волны, фотоплетизмограмма, нейросетевой многоклассификатор.

ВВЕДЕНИЕ

Состояние сердечно-сосудистой системы является ключевым индикатором общего состояния организма. Раннее выявление негативных изменений, таких как повышенная артериальная ригидность или нарушения сердечного ритма, может существенно снизить уровень заболеваемости и смертности. При этом предпочтение здесь часто отдается методам мониторинга на основе неинвазивных измерений [1]. Одним из популярных из них является анализ сигнала пульсовой волны, регистрируемого пульсоксиметрами, который содержит информацию о динамике сердечно-сосудистой системы. Кроме того, такие измерения могут выполняться пациентами самостоятельно и неограниченное количество раз [2].

Анализ пульсовой волны позволяет выявлять заболевания и отслеживать негативные изменения в состоянии здоровья [3]. Существует множество методов анализа и обработки пульсовых волн, среди которых наиболее популярны: анализ сингулярных значений [4], разложение в ряд Фурье [5], метод независимых компонент, вейвлет-преобразование и адаптивная фильтрация шумов. Каждый из этих методов имеет преимущества и недостатки. Некоторые подходы обладают высокой вычислительной сложностью для использования в реальном времени. В работе [6] метод независимых компонент основан на предположении о статистической независимости артефактов движения и артериальной пульсации, которое было опровергнуто в [7].

Адаптивная фильтрация эффективно устраняет шумы без искажения сигнала, однако выбор порядка фильтра и коэффициента сходимости остаётся сложной задачей [8]. При реализации метода адаптивного шумоподавления требуется дополнительное оборудование, например, акселерометр. В [9] предложен подход на основе вейвлет-преобразования для устранения артефактов движения. Недостатком этого метода является субъективный выбор порогового значения, поскольку реконструированный сигнал зависит от индивидуальных особенностей пациента. Неверный выбор порога может привести к некорректным результатам.

В последние годы проведён ряд исследований по классификации пациентов с сердечно-сосудистыми заболеваниями (ССЗ) с использованием глубокого обучения и сигналов пульсовой волны. В работе [10] нейросетевой классификатор превзошёл другие методы (опорных векторов и к-ближайших соседей), достигнув точности около 90%. Данные об артериальном давлении и фотоплетизмограммы (ФПГ) 73 пациентов с ишемической болезнью сердца и 64 здоровых лиц были взяты из базы данных MIMIC-II. Данные предварительно обрабатывались полосовыми фильтрами с диапазонами 2.5–16 Гц для АВР и 1.5–16 Гц для РРГ. Из каждого сигнала извлечено 19 признаков, включая среднюю длительность импульса, среднюю крутизну восходящего фронта и соотношение низкочастотных и высокочастотных компонентов. В [11] предложена 1D-CNN модель для обнаружения аритмий по сигналам РРГ. Использован датасет медицинского центра университета Массачусетса, содержащий синхронные записи электрокардиограмм (ЭКГ) и ФПГ. Сигналы ЭКГ фильтровались полосовым фильтром, а ФПГ-сигналы сегментирова-

* souhair.msokar@gmail.com

† davydovroman@outlook.com

лись на 30-секундные эпизоды. Точность модели оценивалась путём сопоставления классификации PPG с эталонными данными ЭКГ. Модель достигла точности 95.17% в дифференциации нормального синусового ритма, фибрилляции предсердий и преждевременных сокращений предсердий. В [12] сверточная нейронная сеть с глубокой остаточной сетью (ResNetCNN) и двунаправленная долговременная память (LSTM) используются для определения оптимальных рабочих параметров для датасета PPG-BP. В ходе эксперимента соотношение обучающих и тестовых датасетах составляло 8:2. Модель продемонстрировала оптимальную точность классификации в 76% при использовании тестового датасета, что не очень хорошо.

Таким образом, есть потребность в разработке нового метода обработки пульсовой волны, интегрированного с нейросетевой моделью, использующей признаки, извлечённые из обработанного сигнала, для оценки эффективности выявления заболеваний на начальных стадиях, в частности гипертонии. Целью работы является разработка нейросетевой модели для прогнозирования сердечно-сосудистых заболеваний (многоклассовая классификация).

1. МЕТОДОЛОГИЯ

1.1. Датасет

Датасет, использованный в данной работе, получен из открытой базы PPG-BP (фотоплетизмограмма и артериальное давление), предназначенный для неинвазивной диагностики сердечно-сосудистых заболеваний. Он содержит 657 записей данных от 219 пациентов, охватывающих возрастной диапазон 20–89 лет, а также информацию о заболеваниях, включая гипертонию.

Сбор данных осуществлялся в соответствии со стандартными экспериментальными условиями и протоколами [13]. Протокол измерений и статистика датасета представлены на рис.1 и 2. Фотоплетизмограмма (PPG) и артериальное давление (BP) регистрировались в течение 3 мин. Для каждого участника было записано три сегмента PPG длительностью 2.1 с каждый.

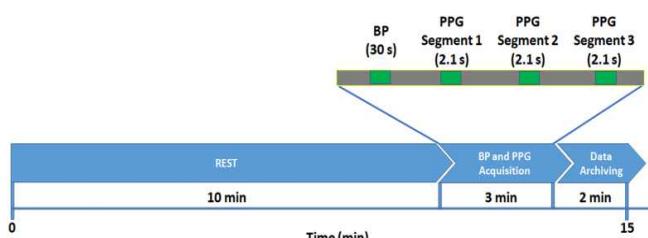


Рис. 1. Протокол измерения ФПГ сигналов [13]

Сигнал пульсовой волны обрабатывался полосовым фильтром Баттервортса второго порядка (0.5–5 Гц) с ча-

стотой дискретизации 1 кГц для подавления шумов, артефактов движения и базального дрейфа. Пример сигнала и результатов его обработки представлен на рис. 3.

1.2. Метод обработки пульсовой волны

Метод предполагает разделение сигнала пульсовой волны на три ключевые области: фронты нарастания, фонты спада и окрестность максимума. Для обработки каждой области предложено использование специализированных математических функций. На рис. 4 представлены обозначения зон пульсовой волны, используемые в математическом описании [14].

Сигнал рассматривается как ступенчатая функция с не менее чем одним, но не более чем тремя локальными максимумами (пиками). Для описания окрестности максимума сигнала используется функция F :

$$F(t) = F \left(\sum_{i=m-p}^{m+p} \Delta\tau_i \right) = \left| \frac{A_n - A_{n-1}}{\Delta\tau_n} \right|, \quad (1)$$

где $\Delta\tau_i$ — длительность шага, m — номер шага, соответствующего локальному максимуму, p — целочисленный коэффициент (по умолчанию равен 2).

Для обработки фронтов нарастания пульсовой волны используется функция $\Phi_i(t)$:

$$\Phi_i(t) = \sum_{n=k_i}^{m_i} \left[A_n(t) \sum_{j=1}^{m_i-k_i+1} \left[\frac{\Delta\tau_{j+k_i-1,p}}{\Delta T_{m_i}(m_i-1)} \right]^j \right], \quad (2)$$

где m_i — порядковый номер шага, соответствующего локальному максимуму, $\Delta\tau_n$ — длительность шага, A_n — амплитуда сигнала на шаге n , ΔT_{m_i} — длительность всех фронтов нарастания сигнала.

Фронт спада амплитуды сигнала связан с релаксационными процессами в организме и имеет экспоненциальный характер. Для её обработки разработана функция Ψ :

$$\Psi(t) = A_m \left[e^{-\frac{t \cdot p \cdot (n-m)}{\Delta\tau_k}} \frac{n-m}{p(A_{k-1} - A_k)} \right]. \quad (3)$$

Метод был протестирован на используемом датасете. Примеры обработки сигналов для трёх пациентов из используемого датасета («а», «б», «в») с разным количеством пиков у сигнала (1, 2 и 3 соответственно) представлены на рис. 5–7.

1.3. Предобработка данных

1. Извлечение признаков

После обработки сигналов пульсовой волны извлечена группа признаков. Поскольку сигнал разделён на три области (как указано выше), признаки для каждого пациента включают:

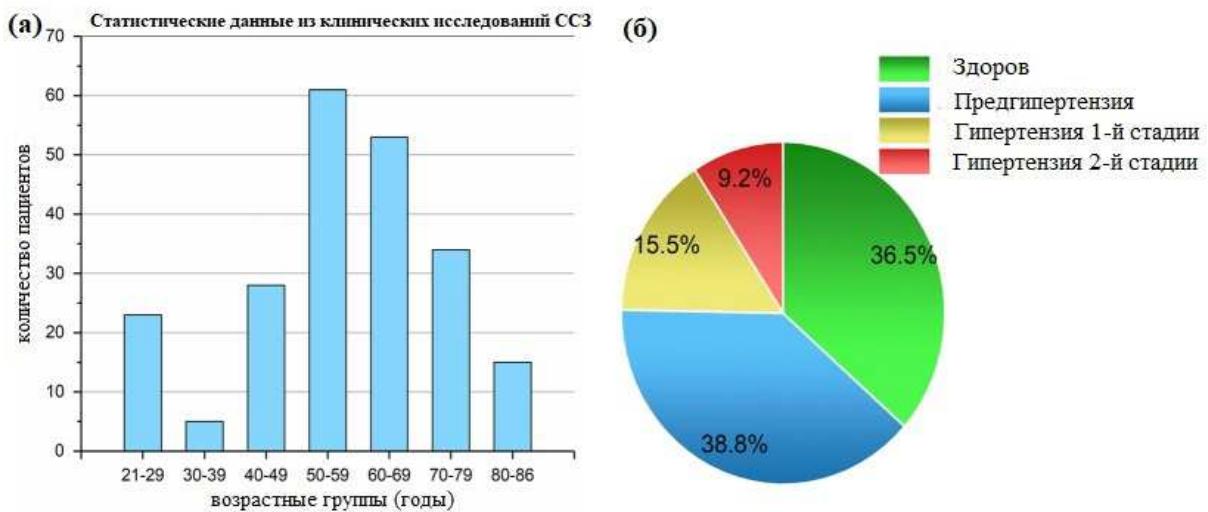


Рис. 2. Статистика по датасету PPG-BP. *а* — гистограмма возрастных групп; *б* — круговая диаграмма состояний здоровья человека [13]

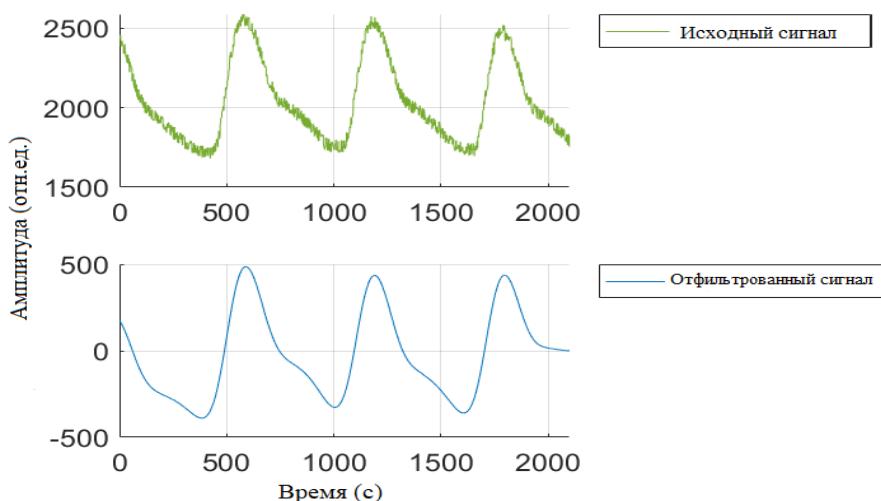


Рис. 3. Исходный и отфильтрованный нормализованный сигнал пульсовой волны

- Среднее значение суммы амплитуд в каждой области ($F, \Phi_1, \Phi_2, \Phi_3$) — 6 признаков.
- Среднее значение суммы амплитудных площадей в каждой области ($F, \Phi_1, \Phi_2, \Phi_3$) — 3 признака.
- Значение Ψ на каждом пике — 3 признака.
- Разница между значениями Ψ на двух пиках в каждой области спада — 2 признака.
- Разница между значениями Ψ в начале и конце каждой области спада — 3 признака.

Демографические и клинические данные из датасета (пол, возраст, высота, вес, систолическое артериальное давление (англ. systolic blood pressure, SBP),

диастолическое артериальное давление (англ. diastolic blood pressure, DBP), частота сердечных сокращений (англ. heart rate, HR), индекс массы тела (англ. body mass index, BMI)) — 8 признаков. Сформированная база данных, включающая эти признаки, используется для обучения и тестирования нейросетевой модели.

Новый метод обработки учитывает в сигнале пульсовой волны разное количество максимумов. В датасете большинство записей содержат сигналы с одним пиком — 557 из 657 записей, соответствующих пациентам с различным состоянием: здоров, предгипертония, гипертония 1-й и 2-й стадий, как показано на рис. 8.

Признаки, которые были взяты для однопиковых сигналов:

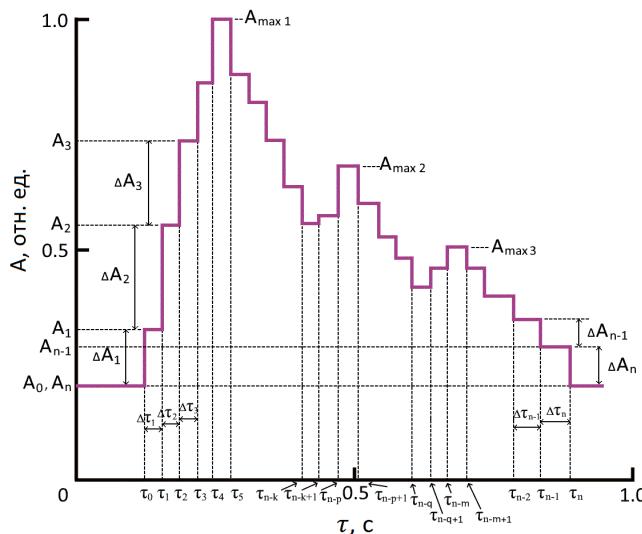


Рис. 4. Основные обозначения на областях пульсовой волны

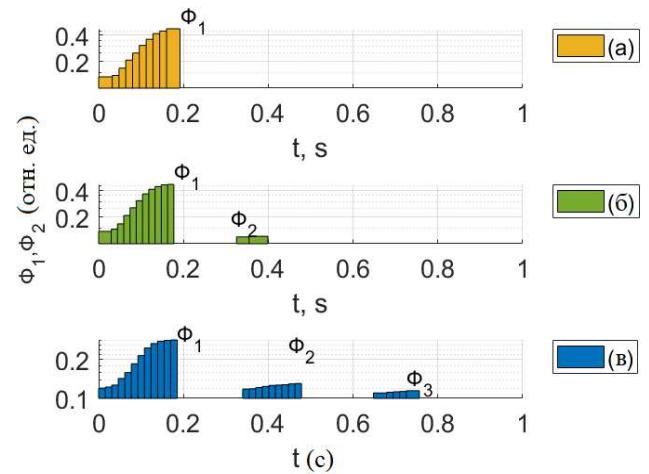


Рис. 6. Результаты обработки фронтов нарастания за один период с использованием функций Φ_1 , Φ_2 , Φ_3 у трех пациентов

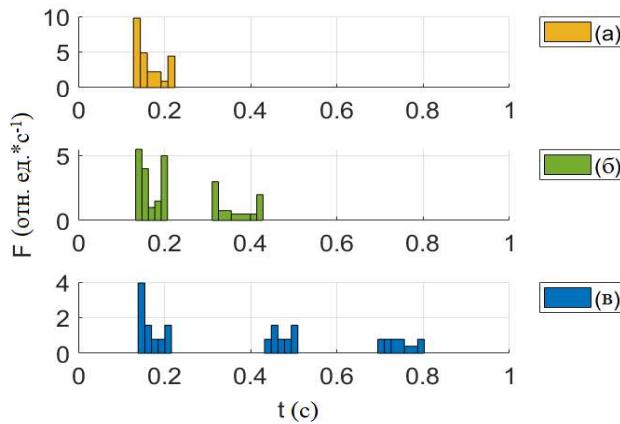


Рис. 5. Результаты обработки окрестностей максимума за один период с использованием функции F у трех пациентов

- Среднее значение суммы амплитуд в областях (F , Φ_1) — 2 признака.
- Среднее значение амплитудной площади в области (Φ_1) — 1 признак.
- Значение Ψ на пике — 1 признак.
- Разница между значениями Ψ в начале и конце области спада — 1 признак.
- Демографические и клинические данные (пол, возраст, высота, вес, SBP, DBP, HR, BMI) — 8 признаков.

Для получения хорошего прогноза используемые данные должны быть сбалансированными и не содержать экстремальных значений, которые отрицательно влияют на результаты. Поэтому были реализованы этапы предварительной обработки:

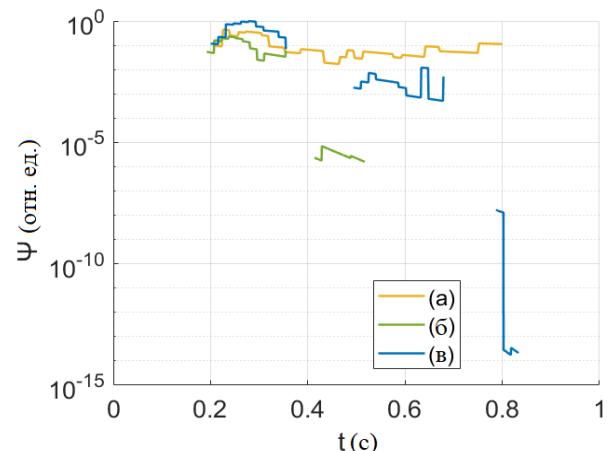


Рис. 7. Результаты обработки фронтов спада за один период с использованием функции Ψ у трёх пациентов

1. Обработка пропущенных значений и кодирование категориальных переменных (например, пол — бинарное кодирование: «Мужчина»/«Женщина» → 0/1).
2. Нормализация признаков. Использован StandardScaler из библиотеки sklearn для стандартизации данных (центррирование по среднему и масштабирование до единичной дисперсии).
3. Балансировка данных. На рис. 8 виден дисбаланс классов. Для его устранения применён метод передискретизации SMOTE (Synthetic Minority Over-sampling Technique), генерирующий синтетические примеры для миноритарных классов.

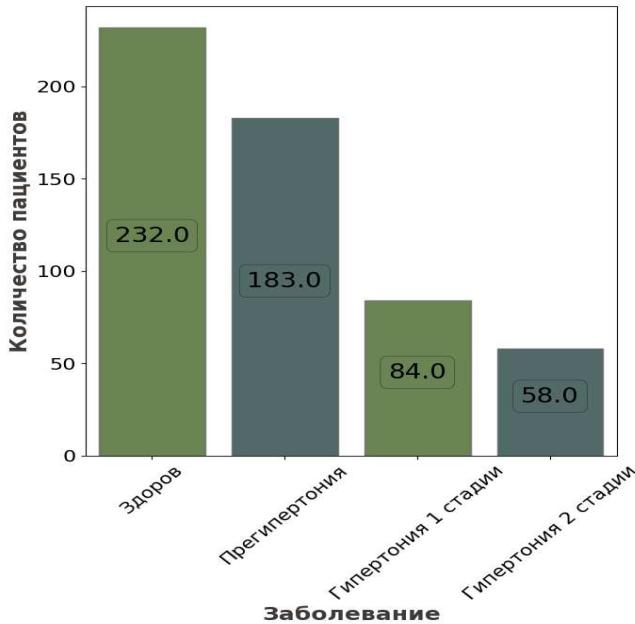


Рис. 8. Информация о датасете сигналов однопиковой пульсовой волны

2. Архитектура нейронной сети

Была создана модель нейронной сети для классификации четырех стадий гипертонии на основе описанного выше датасета. Архитектура нейронной сети состоит из трёх слоев (рис. 9), где входной слой представляет независимые переменные (признаки), выход каждого нейрона (каждый вход) передается всем следующим нейронам в выходном скрытом слое которые умножаются на некоторый вес, и их произведение будет использоваться для классификации зависимой переменной на четыре класса: либо здоров, либо предгипертония, либо гипертония 1 стадии, либо гипертония 2 стадии с использованием функции активации Softmax. Скрытый слой имеет 4 блока с RELU в качестве функции активации. Слой отсева с показателем отсева, равным 0.2, используется для предотвращения переобучения [15]. Модель была обучена с использованием адаптивного алгоритма оптимизации Adam с настройкой скорости обучения [16] с 100 эпохами. На основе результатов обучения и тестирования рассчитаны: точность, F1-мера и матрица ошибок (confusion matrix). Эти метрики сравнивались между обучающей и тестовой выборками для проверки обобщающей способности модели.

2. РЕЗУЛЬТАТЫ

При оценке эффективности модели классификации ключевыми метриками являются точность (precision) и полнота (recall).

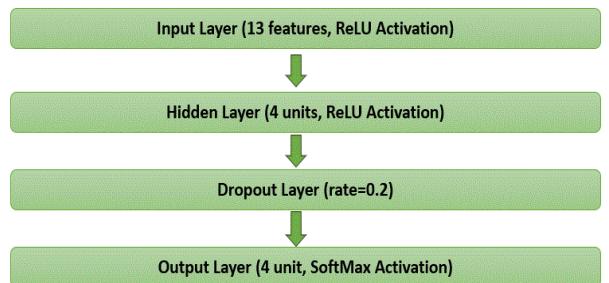


Рис. 9. Предлагаемая архитектура нейронной сети

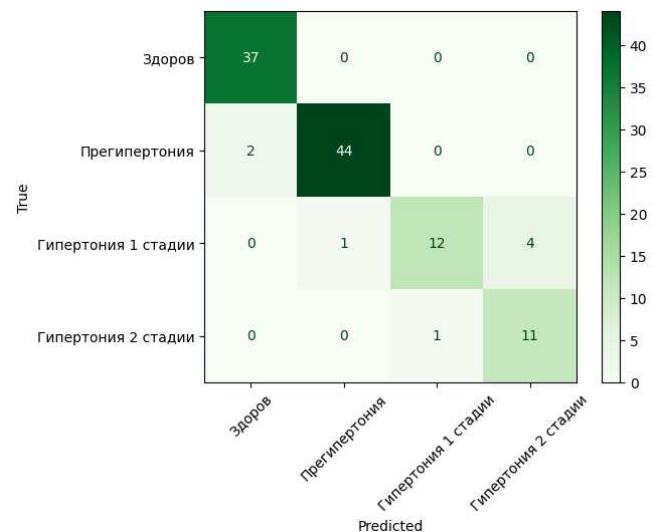


Рис. 10. Матрица ошибок модели нейронной сети

- Точность рассчитывается как отношение верно классифицированных положительных случаев к общему числу случаев, отнесённых моделью к положительному классу [17].

$$Precision = \frac{TP}{TP + FP}. \quad (4)$$

- Полнота отражает долю фактически положительных случаев, корректно идентифицированных моделью [18].

$$Recall = \frac{TP}{TP + FN}. \quad (5)$$

- F1 — мера (F1-score) — важный показатель, представляющий собой взвешенное гармоническое среднее точности и полноты. Эта метрика оценивает общую производительность модели на датасете [19] и показывает частоту корректных прогнозов в рамках всех предсказаний [20].

$$F1\text{-score} = \frac{2 * (Precision * Recall)}{Precision + Recall}. \quad (6)$$

Таблица. Классификационный отчёт

	Precision	Recall	F1-score	Support
«здоров»	0.95	1.00	0.97	37
«предгипертония»	0.98	0.96	0.97	46
«гипертония 1 стадии»	0.92	0.71	0.80	17
«гипертония 2 стадии»	0.73	0.92	0.81	12
Accuracy			0.93	112
Macro avg	0.90	0.89	0.89	112
Weighted avg	0.93	0.93	0.93	112

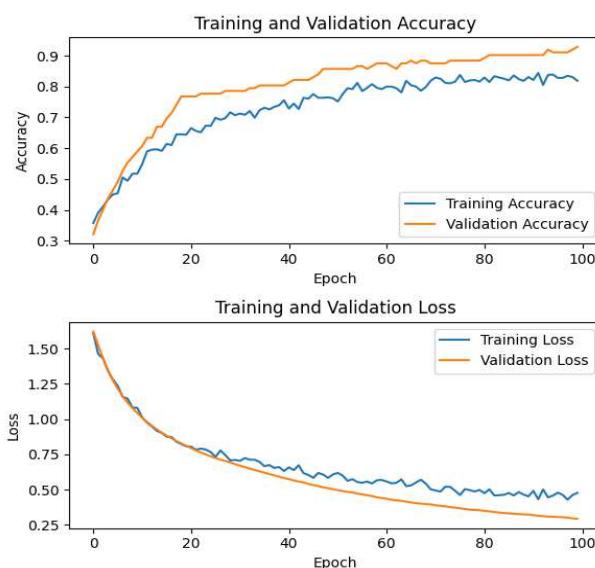


Рис. 11. Обучение и проверка точности и потерь

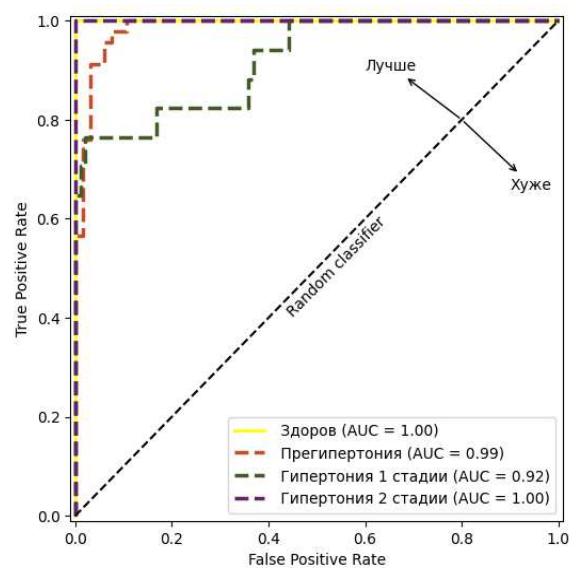


Рис. 12. ROC-кривые

- Поддержка (support) — количество образцов каждого класса в исходных данных. Значения метрик для классов суммируются с учётом весов, пропорциональных их частоте, после чего вычисляется взвешенное среднее [20].

$$WeightedAverage = \frac{\sum (Metrics * support)}{\sum Support}. \quad (7)$$

- Точность (accuracy) — доля верных прогнозов модели относительно общего числа предсказаний [18]. Однако эта метрика релевантна только при сбалансированном распределении классов в данных (когда количество образцов в каждом классе примерно одинаково) [21, 22].

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN}, \quad (8)$$

где TP — истинно положительные случаи, TN — истинно отрицательные случаи, FP — ложно положительные случаи, FN — ложно отрицательные случаи.

Значения метрик классификации представлены в таблице.

Рис. 10 отображает матрицу ошибок модели (confusion matrix), позволяя определить значения TP , TN , FP и FN для каждого класса.

Модель точно прогнозирует здоровых пациентов (класс «здоров») и случаи предгипертонии, однако в 5% случаев ошибочно классифицирует предгипертонию как здоровье. Модель демонстрирует хорошую способность различать гипертонию 1-й стадии от еще предгипертонии. Отличить стадии гипертонии между собой удается хуже, но при выявлении любого из этих состояний рекомендуется консультация врача. Общая точность модели составила 93% (рис. 11).

На рис. 12 показаны ROC-кривые. Модель показывает исключительную эффективность для классов «здоров», «предгипертония» и «гипертония 2-й стадии» ($AUC \approx 1.00$), где AUC является площадь под ROC-кривой, метрика качества классификации. Их ROC-кривые примыкают к верхнему левому углу, что указывает на высокую долю истинно положительных и низкую долю ложноположительных прогнозов. Для «ги-

пертонии 1-й стадии» достигнут $AUC = 0.92$. Кривая ближе к диагонали, что отражает сложности в дифференциации этого класса от остальных. Линия случайного классификатора ($AUC = 0.5$) служит референсом. Любая кривая выше неё указывает на эффективность выше случайной.

ЗАКЛЮЧЕНИЕ

Создана нейросетевая модель, которая позволяет на основе сигнала пульсовой волны предсказывать нали-

чие заболеваний сердечно-сосудистой системы. Результаты этого исследования показывают, что предложенный подход является перспективным методом классификации сигналов ФПГ и диагностики гипертонии на ранних стадиях.

Полученную точность модели планируется далее улучшить, расширив датасет путем добавления большего количества объектов. Далее планируется дообучить модель на сигналах, содержащих два и три пика пульсовых волн.

- [1] Netala V.R., Teertam S.K., Li H., Zhang Z.. // Cells. **13**, N 17. 1471 (2024).
- [2] Davydov R., Zaitseva A., Davydov V. et al. // J. Pers. Med. **13**. 443 (2023).
- [3] Nascimento L.M.S.d., Bonfati L. V., Freitas M.L.B. et al. // Sensors. **20**. N 15. 4063 (2020).
- [4] Ashoka K., Boby G., Kumar V. // IEEE trans. On instrumentation and measurement. **58**. N 5. 1706 (2009). L
- [5] Naraharisetti K.V. , M. Bawa. // IEEE International Conference On Electro/Information Technology. 1 (2011).
- [6] Kim B.S., Yoo S.K. // IEEE Transactions on Biomedical Engineering. **53**. N 3. 566 (2006).
- [7] Yao J., Warren S. // Proceedings of Annual International Conference of the IEEE Engineering in Medicine and Biology Society. 3585 (2005).
- [8] Relente A.R., Sison L.G. // Proceedings of the Second Joint 24th Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society]. 1769 (2002).
- [9] Lee C.M., Zhang Y.T. // IEEE EMBS Asian-Pacific Conference on Biomedical Engineering. 194 (2023).
- [10] Minhas, A., Pal, S.C., Jain, K. // Scientific reports. **15**. N 1. 8574 (2025).
- [11] Bulut M. G., Unal S., Hammad M., Plawiak // PloS one. **20**. N 2 (2025).
- [12] Yen C.T., Chang S.N., Liao C.H. // Measurement and Control. **54**. N 3–4. 439 (2021).
- [13] Liang Y., Chen Z., Liu G., Elgendi M. // Scientific data. **5**. 4180020 (2018).
- [14] Давыдов Р.В., Якушева М.А., Порфириева Е.В. и др. // ЖТФ. **94**. № 9. 1466 (2024).
- [15] Srivastava N., Hinton G., Krizhevsky A. et al. // JMLR. **15**, 56. N 3–4. 1929 (2014).
- [16] Kingma D., Ba J. // CoRR. abs/1412.6980. (2014).
- [17] Ali K., Shaikh Z.A., Khan A.A., Laghari A.A. // Neuroscience Informatics. **2**, 4. 100034 (2021).
- [18] Weng S., Hu D., Chen J. et al. // Diagnostics. **13**, 6. 1168 (2023).
- [19] Ragab M., Alshehri S., Alhakamy N.A. et al. // Computational Intelligence and Neuroscience. 6185013 (2022).
- [20] Mathew J., Kshirsagar R., Abidin D.Z. et al. // Scientific reports. **13**, 1. 9948 (2023).
- [21] Grandini M., Bagli E., Visani G. // arXiv:2008.05756. 2020.
- [22] Moulaiefard M., Coquelin L., Rinkevičius M. et al. // arXiv:2502.19949. 2025.

Deep-learning detection of human cardiovascular system deterioration from pulse-wave signals

C. Msokar^{1,a}, R. V. Davydov^{1,b}

Higher School of Cyber-Physical Systems Control, Institute of Computer Science and Cybersecurity
Peter the Great St. Petersburg Polytechnic University
St. Petersburg 195251, Russia
E-mail: ^asouhair.msokar@gmail.com, ^bdavydovroman@outlook.com

Cardiovascular diseases (CVD) are among the leading causes of mortality worldwide, making the early detection of pathological changes critically important for timely intervention. This study presents a developed neural network model designed to detect and monitor adverse changes in the human cardiovascular system through the analysis of pulse wave signals. The research utilizes a medical dataset comprising 657 data recordings from 219 patients. The dataset covers an age range of 20–89 years and includes records on disease presence and stage. The data were filtered and processed for feature extraction. After training, the model demonstrated an accuracy of 93% on test data, confirming its potential for integration into wearable devices and remote health monitoring systems.

PACS: 87.10.+e

Keywords: cardiovascular diseases, pulse wave processing, photoplethysmogram, neural network multiclassifier.

Received 10 June 2025.

Сведения об авторах

1. Мсукар Сухайр — студент; e-mail: souhair.msokar@gmail.com.
2. Давыдов Роман Вадимович — канд. физ.-мат. наук, доцент; e-mail: davydovroman@outlook.com.