

# РАЗРАБОТКА НЕЙРОННОЙ СЕТИ ТИПА GRU ДЛЯ АВТОМАТИЗИРОВАННОЙ ИНТЕРПРЕТАЦИИ КАРДИОГРАММ

**Лосев А.Ю.**, соискатель, ФГАОУ ВО Первый Московский государственный медицинский университет имени И.М. Сеченова (Сеченовский Университет)

*Существующие трудности ручного анализа электрокардиограмм из-за разнообразия и изменчивости паттернов приводят к необходимости создания автоматизированных решений. Изложена последовательность шагов по разработке GRU-нейросети для анализа кардиограмм, использующей модели автоматического анализа и интерпретации электрокардиограмм.*

*Представлены результаты обучения и тестирования GRU-нейросети, оценки точности алгоритма классификации для разных классов аритмии с помощью метрик Accuracy, Precision, Recall и F1-score. Приведены графики обучения полученных результатов (матрица ошибок, графики точности и потерь по эпохам).*

*Проведен анализ полученных результатов, заключающихся в снижении времени анализа кардиограмм, повышении надежности диагностики при хронической сердечной недостаточности. Подчеркнут потенциальный вклад рассмотренного подхода в области персонализированной медицины, особенно в условиях ограниченного доступа к специализированной кардиологической помощи.*

**Ключевые слова:** сердечно-сосудистые заболевания, электрокардиограмма, рекуррентная нейронная сеть, машинное обучение, метрики классов аритмий, персонализированная медицина.

**Цитирование:** Лосев А.Ю. Разработка нейронной сети типа GRU для автоматизированной интерпретации кардиограмм // Информационно-экономические аспекты стандартизации и технического регулирования. 2025. № 5 (86). С. 104–109.

## ВВЕДЕНИЕ

Диагностика и лечение хронической сердечной недостаточности (ХСН) и связанных с ней аритмий требует точного и своевременного распознавания паттернов сердца. В условиях сложной клинической картины ХСН характеризуется многообразием симптомов и вариативностью проявлений у разных пациентов, что приводит к необходимости включения в систему поддержки принятия врачебных решений (СПВР) подсистемы, способной автоматизировать и оптимизировать диагностический процесс.

Современные подходы к решению такой задачи включают применение методов машинного обучения нейронной сети типа Gated Recurrent Units (GRU), ориентированной на обработку последовательности данных, таких как ЭКГ-сигналы, обеспечивая не только обнаружение аномальных паттернов сердца, но и мониторинг состояния пациента.

Врачебные решения при ХСН значительно усложняются из-за обширного спектра клинических проявлений заболевания – от неясных симптомов до комплексной комби-

нации сопутствующих признаков [1]. Это приводит к риску диагностических ошибок и недостаточно точному персонализированному лечению. Мониторинг состояния пациента в рамках направлений телемедицины уже активно внедряется в повседневную практику [2]. Традиционные методы диагностики аритмий часто зависят от визуального анализа кардиолога и ручных измерений данных электрокардиограмм (ЭКГ). Это не только трудоемко, но и подвержено субъективности [3]. Машинное обучение является по сути основой приобретения и накопления знаний в системах искусственного интеллекта для задач принятия решений [4, 5]. Алгоритмы на основе процедур машинного обучения позволяют минимизировать риски, связанные с субъективностью при чтении ЭКГ специалистами, повышая точность диагностирования до уровня 95% и выше для некоторых форм аритмий [6], что существенно улучшает персонализированную терапию и снижает риск ошибок и в целом повышает эффективность обследования [7]. В связи с этим внедрение GRU-нейросети для целей анализа данных ЭКГ позволяет обеспечить проведение ранней диагностики и персонализированный подход в терапии.

В данной работе рассматривается применение GRU-нейросети для автоматизированной интерпретации ЭКГ, акцентируя внимание на их высокой точности распознавания сердечных аритмий, что критически важно как для диагностики ХСН, так и для мониторинга состояния пациентов с хроническими заболеваниями сердца. При этом не только улучшается качество прогноза, но также обеспечивается прозрачность критериев оценки здоровья пациента, повышается оперативность принятия врачебных решений.

### МАТЕРИАЛЫ И МЕТОДЫ

Для разработки и оценки эффективности модели на базе GRU, предназначенной для автоматической классификации ЭКГ, были использованы следующие материалы и методологические подходы.

Использовался набор данных о случаях аритмий из репозитория MIT-BIH Arrhythmia Database [8]. Этот набор включает в себя более 100 тыс. записей и охватывает пять классов аритмии (*N, S, V, F, Q*), что позволяет охватить широкий спектр сердечных паттернов (см. таблицу).

#### Классы аритмии, определяемые с помощью ЭКГ

Класс	Аннотация
<i>N</i>	<ol style="list-style-type: none"> <li>1. Нормальный</li> <li>2. Блокада левой/правой ножек пучка гисса</li> <li>3. Фибрилляция предсердий</li> <li>4. Узловая фибрилляция</li> </ol>
<i>S</i>	<ol style="list-style-type: none"> <li>1. Предсердная экстрасистолия</li> <li>2. Аберрантная предсердная экстрасистолия</li> <li>3. Узловая экстрасистолия</li> <li>4. Наджелудочковая экстрасистолия</li> </ol>
<i>V</i>	<ol style="list-style-type: none"> <li>1. Преждевременное сокращение желудочков</li> <li>2. Желудочковая фибрилляция</li> </ol>
<i>F</i>	<ol style="list-style-type: none"> <li>1. Сливной комплекс</li> </ol>
<i>Q</i>	<ol style="list-style-type: none"> <li>1. Кардиостимуляция</li> <li>2. Сочетание кардиостимуляции и нормального ритма</li> <li>3. Не классифицируемый</li> </ol>

Предварительная обработка данных заключалась в подавлении шума, выделении пиков и нормализации сигналов. Для повышения качества исходных сигналов ЭКГ использовалась методика вейвлет-анализа, что позволило эффективно устранить электрические помехи и дрейф базовой линии. Для правильного сегментирования кардиограмм на такты длительностью 100 точечных выборок в сигналах было выполнено выделение пиковых точек R. Для ускорения процесса обучения и улучшения устойчивости модели к вариациям данных проведена нормализация значений каждого сигнала в диапазоне [0,1].

Структура нейронной сети включает последовательное сочетание сверточных слоев (Conv), пакетных нормали-

заций (Batch Normalization – BN) и нелинейного активатора ReLU, направленных на эффективное выделение особенностей из входящих временных рядов ЭКГ [9]. Схема работы сети следующая. Сверточные слои Conv предварительного анализа обеспечивают детальное вычленение локальных паттернов в исходном сигнале. Блоки BN и ReLU улучшают обучение модели через нормализацию распределения данных и добавление нелинейности, соответственно. Выделяются следующие компоненты GRU-сети: забывающий гейт (Forget Gate), предназначенный для определения информации из прошлого состояния сети, которую следует сохранить; и обновленный гейт (Update Gate), управляющий текущей информацией и определяющий новое состояние GRU-сети. При этом в качестве функции оценки используется кросс-энтропия для минимизации ошибки между предсказываемым и фактическим классом записи ЭКГ. Оптимизатор Adam предназначен для адаптации скорости обучения на основе предыдущих шагов, что способствует устойчивому обучению даже с большими наборами данных [10].

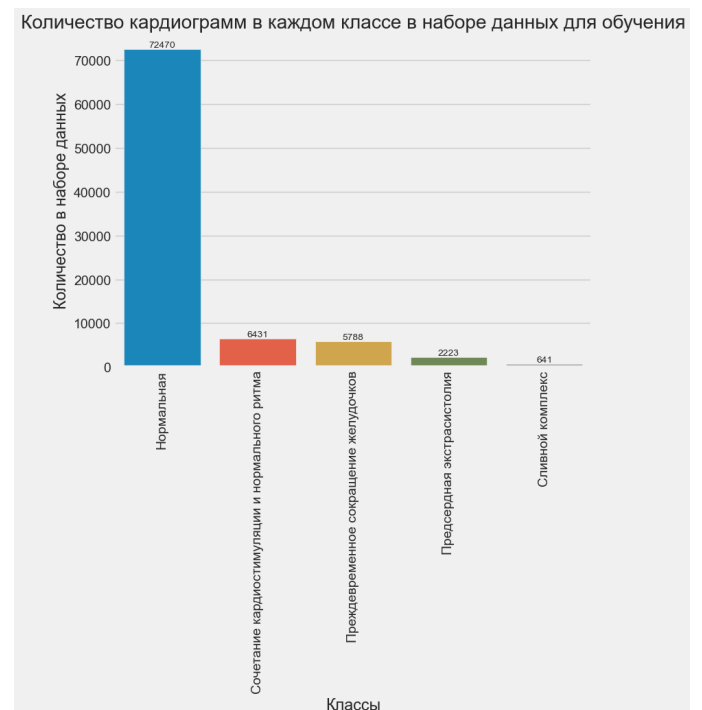


Рис. 1. Характеристика классов в обучающем наборе данных

Для реализации процедуры обучения и тестирования данные были случайным образом разделены в соотношении 80%/20% для обучающего и тестового наборов соответственно (рис. 1). Оценку эффективности модели сети проводили с помощью метрик Accuracy (точность), Precision (точность предсказаний положительного класса), Recall (полнота) и F1-score.

Этот комплексный методологический подход был использован для демонстрации способности разработанной GRU-нейросети эффективно анализировать ЭКГ и классифицировать сердечные аритмии, что свидетельствует о возможности ее применения в медицинской диагностике ХСН с акцентом на персонализированную терапию.

## РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

В представленной работе достигнута высокая точность модели классификации, построенной на базе GRU-нейросети. Для анализа и интерпретации данных ЭКГ модель была обучена с применением датасета MIT-BIH Arrhythmia Database.

На этапе обучения и тестирования модель продемонстрировала следующие ключевые показатели.

Точность классификации (Ассигасу) варьировалась от 0,99 до 0,85 для различных классов аритмий, что указывает на высокий уровень общей точности:

класс «N» (нормальный ритм): точность – 0,99;

класс «S» (наджелудочковая экстрасистолия): точность – 0,91;

класс «V» (предсердная или желудочковая экстрасистолия): точность – 0,95;

класс «F» (фибрилляция предсердий или узловая фибрилляция): точность – 0,85;

класс «Q» (кардиостимуляция): точность достигла максимального уровня в 1,0.

Precision и Recall также были оценены для каждого класса аритмии, демонстрируя способность модели точно выделять и не пропускать положительные случаи.

F1-score, как сбалансированная мера точности и полноты предсказаний, показала результаты от 0.93 до 0.88 для разных классов, что подтверждает стабильные показатели модели в комплексе всех критериев оценки.

Графики обучения (рис. 2) показали сглаженную динамику снижения ошибок по мере увеличения числа эпох, подтверждая устойчивое и эффективное обучение модели.

Анализ матрицы ошибок (рис. 3) позволил визуально оценить долю правильных предсказаний для каждого класса аритмии — диагональные значения были выше 85% на тестовом наборе данных.

Сравнительный анализ с результатами других известных методов (например, традиционных нейронных сетей и простых классификаторов) подтвердил преимущество




Рис. 2. Оценки результатов обучения и тестирования модели GRU-нейросети



Рис. 3. Матрица ошибок при классификации ЭКГ со случаями аритмии

GRU-нейросети в способности к долгосрочной памяти и эффективному анализу временных рядов ЭКГ [11].

На обучение модели на мощных вычислительных ресурсах для достижения оптимального состояния с низким уровнем потерь потребовалось менее часа, что подчеркивает приемлемые временные характеристики при использовании на практике.

В целом, полученные результаты демонстрируют высокую эффективность GRU-нейросети в автоматизированных системах диагностики аритмий сердечного ритма. Модель продемонстрировала высокое качество классификации как для наиболее частых паттернов ЭКГ (нормального ритма), так и для менее распространенных, что значительно улучшает возможности ранних диагностических процедур при заболеваниях сердца.

Исследование подтверждает потенциал GRU-нейросетей в персонализированной медицине – повышая точность и скорость диагностики аритмий, а также открывая новые горизонты для эффективного мониторинга состояния па-

циентов с ХСН. Результаты данного исследования для повышения качества медицинской помощи при сердечно-сосудистых заболеваниях интегрированы в СПВР.

Полученные результаты подтверждены визуализацией и статистическими измерениями, что позволяет с целью улучшения диагностических процедур и персонализации лечения пациентов уверенно рекомендовать использование GRU-нейросети в качестве ключевого инструмента для продвинутого анализа ЭКГ.

## АНАЛИЗ РЕЗУЛЬТАТОВ

В контексте данной работы для диагностики сердечных аритмий и хронической сердечной недостаточности успешное внедрение GRU-нейросети в анализ ЭКГ демонстрирует значительные преимущества в области медицинской диагностики и персонализированного лечения. При этом выделяются следующие преимущества GRU-моделей:

– высокая точность и надежность классификационных выводов – результаты исследования демонстрируют, что модели на основе GRU-нейросети достигли точностей до 0,99 для некоторых классов аритмий (например, нормального ритма), что критически важно в условиях неотложной медицинской помощи;

– анализ временных последовательностей с долговременными зависимостями основан на компонентах GRU-нейросети, таких как забывающий и обновляющий гейты, что обеспечивает устойчивую обработку длинных временных рядов ЭКГ. Это особенно полезно при диагностике ХСН, где длительное наблюдение за состоянием сердца критично для персонализированной терапии.

Следует отметить, что внедрение разработанной GRU-нейросети в СПВР позволяет сократить время анализа ЭКГ до нескольких секунд с высоким уровнем точности, что существенно повышает оперативность медицинской помощи. При этом благодаря персонализированному подходу, основанному на точных классификациях аритмий и отслеживании долгосрочных паттернов сердца пациентов, GRU-модели могут способствовать более эффективному выбору терапевтических стратегий в зависимости от динамики состояния здоровья пациента.

Хотя модель показала высокий уровень точности на тестовом наборе, дальнейшее улучшение может быть достигнуто путем увеличения размера и разнообразия обучающих данных, включая редкие паттерны аритмий. Расширение входных данных с включением дополнительных биометрических показателей (например, биохимические показатели крови) или функциональных параметров сердечно-сосудистой системы совместно с GRU-нейросетью могло бы усилить диагностическую силу модели.

Для адаптации предложенной GRU-нейросети к деятельности врачей, включая возможность интерпретировать предсказанные модели как части комплексного решения, необходимо обеспечить прозрачность механизмов работы этой сети.

Для обеспечения механизма рассуждения на базе ЭКГ-данных при помощи SWRL-правил результаты обучения и тестирования модели успешно интегрированы в СПВР. Это позволяет значительно ускорить диагностические процессы и обеспечить более точную оценку состояния пациента.

Применение разработанной GRU-модели в клинических условиях в удаленных районах с ограниченным доступом к высококвалифицированным специалистам, автоматизированные системы диагностики могут стать незаменимым инструментом для улучшения качества и доступности медицинской помощи.

Успешное применение GRU-нейросети не только подтверждает их потенциал в области персонализированной кардиологической диагностики, но также указывает на широкие возможности дальнейшего развития таких методов. Это открывает путь к более точной ранней диагностике аритмий сердца и ХСН, что потенциально может привести к значительным улучшениям качества жизни пациентов через профилактические мероприятия и оптимизацию лечения.

## ВЫВОДЫ

В данной работе успешно продемонстрирован высокий потенциал GRU-нейросети для диагностики сердечных аритмий и поддержки принятия решений при ХСН в рамках подсистемы автоматизированного анализа ЭКГ в СПВР. Важнейшие выводы можно сформулировать следующим образом.

Разработка и обучение GRU показали высокие результаты – прогнозная точность зависит от класса и варьируется от 85% до 99%, включая точные оценки для редких паттернов аритмий. Это указывает на возможность использования модели в клинической практике при диагностике и персонализированной терапии ХСН.

Внедрение GRU-нейросети упрощает диагностику, сокращая время анализа ЭКГ до минимума без потери качества, что существенно повышает эффективность клинических решений и уменьшает риск ошибочного распознавания патологий сердца. Благодаря структуре GRU-нейросети с детализированным управлением информацией через забывающий и обновленный гейты врачи получают более понятные критерии оценки состояния здоровья пациентов, что способствует повышению доверия к автоматизированным решениям в медицине. При этом повышение точности ранней диагностики позволяет более эффективно предот-

вращать как развитие сложных сердечных заболеваний, так и повышает прогноз выздоровления у страдающих ХСН.

Для расширения применимости и универсальности GRU-нейросети необходимо дальнейшее исследование с различными демографическими группами, с учетом индивидуальных особенностей пациентов, имеющих несколько заболеваний. В дальнейшем, для более полной и точной оценки состояния пациента, усматривается улучшение модели диагностики посредством включения в анализ дополнительных медицинских показателей (например, биохимические данные, гемодинамика).

В целом, внедрение GRU-нейросети в области кардиологии представляет собой прорывной шаг вперед, позволяющий не только повысить точность диагностики аритмий сердца, но также обеспечивающий доступ к высококлас-ной медицинской помощи пациентам в удаленных регионах.

Наиболее перспективными представляются работы по интеграции предложенной модели машинного обучения с су-

ществующими клиническими рекомендациями в рамках СПВР. Так, использование онтологий с SWRL-правилами позволило улучшить качество работы СПВР благодаря более четкой интерпретации данных ЭКГ. Становится очевидным, что GRU-нейросети обеспечивают мощный инструментарий для улучшения как точности диагностики аритмий сердца, так и оценки хронического состояния типа ХСН. В рамках дальнейшего развития медицины они могут стать неотъемлемой частью персонализированной терапии с акцентом на раннее выявление патологий и минимизацию рисков осложнений.

**Рецензент: Бурый Алексей Сергеевич, доктор технических наук, эксперт РАН, заместитель начальника отдела ФГБУ «Институт стандартизации», г. Москва, Российская Федерация.**  
**E-mail: a.s.burji@gostinfo.ru**

#### Список использованных источников и литературы / References

1. Муромцев В.В., Никитин В.М., Ефремова О.А., Камышникова Л.А. Подход к улучшению автоматизированной системы компьютерного анализа электрокардиограммы // Медицинские технологии. Оценка и выбор. 2019. № 2 (36). С. 42–48. / Muromtsev V.V., Nikitin V.M., Efremova O.A., Kamyshnikova L.A. Podhod k uluchsheniyu avtomatizirovannoj sistemy komp'yuternogo analiza elektrokardiogrammy. Medicinskie tekhnologii. Ocenka i vybor. 2019. No. 2(36), pp. 42–48.
2. Лебедев Г.С., Шепетовская Н.Л., Решетников В.А. Телемедицина и механизмы ее интеграции // Национальное здравоохранение. 2021. Т. 2, № 2. С. 21–27. / Lebedev G.S., Shepetovskaya N.L., Reshetnikov V.A. Telemedicina i mekhanizmy ee integracii. Nacional'noe zdravoohranenie. 2021. Vol. 2. No. 2, pp. 21–27.
3. Волосатова Т.М., Спасёнов А.Ю., Логунова А.О. Автоматизированная система анализа и интерпретации электрокардиосигнала // Радиооптика. 2016. № 1. С. 1–18. / Volosatova T.M., Spasyonov A.Yu., Logunova A.O. Avtomatizirovannaya sistema analiza i interpretacii elektrokardiosignala. Radiooptika. 2016. No. 1, pp. 1–18.
4. Кошечкин К.А. Регулирование искусственного интеллекта в медицине // Пациентоориентированная медицина и фарма-ция. 2023. Т. 1, № 1. С. 32–40. / Koshechkin K.A. Regulirovanie iskusstvennogo intellekta v medicine. Pacientoorientirovannaya medicina i farmaciya. 2023. Vol. 1. No. 1, pp. 32–40.
5. Гудфеллоу Я., Бенджо И., Курвилль А. Глубокое обучение. – 2-е изд., испр. – М.: ДМК Пресс, 2018. – 652 с. / Goodfellow Y., Bendzhio I., Kurvill A. Glubokoe obuchenie: 2-nd ed. Moscow: DMK Press Publ., 2018. 652 p.
6. Ramaraj E. A novel deep learning based gated recurrent unit with extreme learning machine for electrocardiogram (ECG) signal recognition // Biomedical Signal Processing and Control. 2021. Vol. 68. Art. 102779.
7. Лосев А.Ю., Сулейманова Д.С., Черноморец Ю.А. [и др.]. Повышение эффективности медицинских осмотров на основе медицинских информационных систем // Информационно-экономические аспекты стандартизации и технического регулирования. 2024. № 3 (78). С. 59–66. / Losev A.Yu., Sulejmanova D.S., Chernomorec Yu.A., et al. Povyshenie effektivnosti medicinskih osmotrov na osnove medicinskih informacionnyh sistem. Information and Economic Aspects of Standardization and Technical Regulation. 2024. No. 3 (78), pp. 59–66.
8. Moody G.B., Mark R.G. The impact of the MIT-BIH arrhythmia database // IEEE Engineering in Medicine and Biology Magazine. 2001. Vol. 20, no. 3, pp. 45–50.
9. Kim B.H., Pyun J.Y. ECG identification for personal authentication using LSTM-based deep recurrent neural networks // Sensors. 2020. Vol. 20, no. 11. Art. 3069.
10. Lynn H.M., Pan S.B., Kim P. A deep bidirectional GRU network model for biometric electrocardiogram classification based on recurrent neural networks // IEEE Access. 2019. Vol. 7, pp. 145395–405.
11. Hammad M., Chelloug S.A., Alkanhel R., et al. Automated detection of myocardial infarction and heart conduction disorders based on feature selection and a deep learning model // Sensors. 2022. Vol. 22, no. 17. Art. 6503.

# DEVELOPMENT OF A GRU NEURAL NETWORK FOR AUTOMATED INTERPRETATION OF CARDIOGRAMS

**Losev A.Yu.**, applicant, Sechenov First Moscow State Medical University (Sechenov University)

*The existing difficulties of manual analysis of electrocardiograms due to the variety and variability of patterns lead to the need to create automated solutions. The sequence of steps for the development of a GRU neural network for the analysis of cardiograms using models of automatic analysis and interpretation of electrocardiograms is described.*

*The results of training and testing the GRU neural network, evaluating the accuracy of the classification algorithm for different classes of arrhythmias using Accuracy, Precision, Recall and F1-score metrics are presented. The graphs of learning the obtained results (error matrix, graphs of accuracy and loss by epoch) are given.*

*The analysis of the obtained results is carried out, which consist in reducing the analysis time of cardiograms and increasing the reliability of diagnosis in chronic heart failure. The potential contribution of the considered approach in the field of personalized medicine is emphasized, especially in conditions of limited access to specialized cardiological care.*

**Keywords:** cardiovascular diseases, electrocardiogram, recurrent neural network, machine learning, metrics of classes of arrhythmias, personalized medicine.

**For citation:** Losev A.Yu. Development of a GRU neural network for automated interpretation of cardiograms. Information and Economic Aspects of Standardization and Technical Regulation. 2025; 5 (86): 104–109. (In Russ.).