

Оптимизация генеративно-сопоставительных сетей для синтеза электрокардиограмм методом адаптивной квантизации

М.М. Гордеев, А.Е. Савкин, О.П. Тимофеева, П.А. Шагалова

Нижегородский государственный технический университет им. Р.Е.Алексеева,
603155, г. Нижний Новгород, ул. Минина, 24, Россия

Резюме. Цель. Данная работа посвящена преодолению высоких требований к вычислительным ресурсам и объему оперативной памяти путем разработки методов эффективной оптимизации генеративно-сопоставительных сетей, адаптированных для генерации сигналов электрокардиограмм. **Метод.** В работе использованы методы глубокого обучения генеративно-сопоставительных сетей, способы обработки сигналов электрокардиограмм и реализации адаптивной квантизации весовых коэффициентов по поиску оптимального уровня квантизации для снижения потребления памяти при сохранении качества синтеза данных. **Результат.** В результате проведенных экспериментов была разработана и обучена собственная архитектура генеративно-сопоставительной сети для синтеза сигналов электрокардиограмм. Сравнительный анализ метрики Fréchet Distance подтвердил высокое сходство сгенерированных данных с реальными ЭКГ-записями. Разработанный метод адаптивного квантования AGWR обеспечил сокращение потребления оперативной памяти на 75% при сохранении качества синтеза, превосходя традиционный подход Min-Max даже при экстремальном сжатии весов до 4 бит. **Вывод.** Работа преодолевает ограничения GAN по вычислительным ресурсам, открывая возможности для практического внедрения в медицинские системы с ограниченными аппаратными ресурсами. Предложенная методика способствует восполнению дефицита клинических данных, ускоряя развитие интеллектуальных диагностических инструментов и персонализированной медицины в области сердечно-сосудистой патологии.

Ключевые слова: генеративно-сопоставительные сети, методы оптимизации, квантизация весовых коэффициентов электрокардиографических сигналов.

Для цитирования: М.М. Гордеев, А.Е. Савкин, О.П. Тимофеева, П.А. Шагалова. Оптимизация генеративно-сопоставительных сетей для синтеза электрокардиограмм методом адаптивной квантизации. Вестник Дагестанского государственного технического университета. Технические науки. 2026;53(2):52-60. DOI:10.21822/2073-6185-2026-53-2-52-60

Optimization of generative-adversarial networks for the synthesis of electrocardiograms by adaptive quantization

M.M. Gordeev, A.E. Savkin, O.P. Timofeeva, P.A. Shagalova

R.E.Alekseev Nizhny Novgorod State Technical University,
24 Minina St., Nizhny Novgorod 603155, Russia

Abstract. Objective. This work is devoted to overcoming high requirements for computational resources and RAM volume through the development of effective optimization methods for generative adversarial networks, adapted for generating electrocardiogram signals. **Method.** The work employed methods of deep learning generative adversarial networks, electrocardiogram signal processing techniques, and implementations of adaptive quantization of weight coefficients for searching the optimal quantization level to reduce memory consumption while maintaining data synthesis quality. **Result.** Based on experiments, a proprietary architecture of a generative adversarial network for synthesizing electrocardiogram signals was developed and trained. Comparative analysis of the Fréchet Distance metric confirmed high similarity between generated data

and real ECG recordings. The developed adaptive quantization method AGWR achieved a 75% reduction in RAM consumption while maintaining synthesis quality, outperforming the traditional Min-Max approach even at extreme weight compression to 4 bits. **Conclusion.** The work overcomes the computational resource limitations of GANs, opening opportunities for practical implementation in medical systems with constrained hardware. The technique helps fill the gap in clinical data, accelerating the development of intelligent diagnostic tools and personalized medicine in cardiovascular pathology.

Keywords: generative-adversarial networks, optimization methods, quantization of weighting coefficients of electrocardiographic signals.

For citation: M.M. Gordeev, A.E. Savkin, O.P. Timofeeva, P.A. Shagalova. Optimization of generative-adversarial networks for electrocardiogram synthesis by Adaptive quantization. Herald of Daghestan State Technical University. Technical Sciences. 2026;53(2):52-60. (In Russ) DOI:10.21822/2073-6185-2026-53-2-52-60

Введение. Электрокардиограмма (ЭКГ) - ключевой инструмент диагностики сердечно-сосудистых заболеваний. История этого метода насчитывает более века - первый практический электрокардиограф был создан нидерландским физиологом Виллемом Эйтховеном в 1901 году. С тех пор процедура снятия ЭКГ стала стандартом в клинической практике, позволяя выявлять десятки видов аномалий сердечного ритма. За прошедшие десятилетия этот метод диагностики превратился в золотой стандарт кардиологического обследования, позволяя выявлять десятки видов аритмий и других аномалий сердечной деятельности.

В современную эпоху рост объемов собираемых ЭКГ данных - как в клинических условиях, так и с помощью носимых устройств - создает потребность в разработке высокоэффективных алгоритмов для автоматического анализа таких сигналов [1]. Разработка таких алгоритмов становится критически важной для обеспечения своевременной диагностики, точного прогнозирования рисков и непрерывного мониторинга состояния пациентов.

Однако дальнейшее развитие таких технологий сталкивается с фундаментальным препятствием - дефицитом высококачественных, аннотированных и открытых клинических данных [2]. Ограничения, связанные с защитой конфиденциальности пациентов, и объективная сложность сбора масштабных датасетов приводят к формированию ограниченных обучающих выборок, что отрицательно влияет на способность моделей глубокого обучения к обобщению и ставит под вопрос достоверность их результатов. Перспективным решением этой проблемы является использование генеративно-сопоставительных сетей (GAN) [3], способных синтезировать крайне реалистичные синтетические данные, практически неотличимые от реальных клинических записей. Такие искусственно созданные наборы данных способны существенно расширить объемы тренировочных выборок и тем самым повысить точность обучаемых моделей. Однако широкое внедрение GAN, особенно в области генерации сложных сигналов электрокардиограммы (ЭКГ), ограничивается высокими требованиями к вычислительным ресурсам и объему оперативной памяти.

Постановка задачи. Целью данной работы является преодоление высоких требований к вычислительным ресурсам и объему оперативной памяти путем разработки методов эффективной оптимизации GAN, специфически адаптированных для генерации сигналов ЭКГ. Основное внимание уделяется квантизации обученной сети - процессу сокращения разрядности представления чисел, при котором веса генератора переводятся из 16-битного формата в 4-битный, что позволяет значительно снизить требования к памяти и вычислительным ресурсам [4].

Методы исследования. Мы исследуем традиционный Min-Max подход и предлагаем новый адаптивный метод Adaptive Generative Weight Reconstruction (AGWR), разработанный для минимизации потерь качества синтезируемых сигналов при переходе к низкоразрядным представлениям весов. Для исследования был использован широко известный публичный датасет MIT-BIH Arrhythmia Database [5], содержащий обширную коллекцию записей

электрокардиографических сигналов. Каждая запись имеет продолжительность десять секунд и была зарегистрирована с частотой дискретизации 500 Гц во всех двенадцати стандартных отведениях. Для дальнейшей обработки был применен подход автоматического распознавания границ [6], позволяющий точно выделять основные компоненты сигнала (рис. 1): точку начала волны Р, точку окончания волны Т, а также комплекс QRS [7]. Записи, в которых затруднено точное определение пика R, были автоматически выявлены и исключены при помощи метода, разработанного с использованием библиотеки Matplotlib.




Рис. 1 – Схема сигнала ЭКГ
Fig. 1 – ECG signal diagram

Генеративная состязательная сеть (GAN) представляет собой архитектуру, состоящую из двух взаимодействующих компонентов: дискриминатора и генератора [3]. Основная цель дискриминатора заключается в оценке принадлежности поступающего образца одной из категорий, а задача генератора противоположна - он должен научиться формировать такие образцы, которые будут успешно отнесены дискриминатором к требуемым классам. По результатам серии экспериментов была разработана собственная модель генеративно-состязательной сети - «MeGAN» (рис. 2), в которой генератор принимает на вход шумовую последовательность, заданную вещественным вектором размером 100 элементов. Структура генератора построена на основе пары двунаправленных рекуррентных слоёв LSTM [8], содержащих по сто скрытых единиц каждая. Что касается дискриминатора, его структура сформирована путём каскадирования последовательно соединённых свёрточных (Conv1-Conv4) и максимальных пулинговых (MaxPool1-MaxPool4) слоёв. Для ускорения процесса схождения используется активационная функция ReLU. Выход дискриминатора представлен функцией сигмоиды, предназначенной для бинарной классификации.




Рис. 2 – Схема разработанной генеративно-состязательной нейросети MeGAN
Fig. 2 – Diagram of the developed generative-adversarial neural network MeGAN

Во время тренировки основная задача дискриминатора состоит в выявлении поддельных примеров среди предъявляемых ему сигналов, тогда как генератор стремится создать искусственные данные такого уровня реалистичности, чтобы обмануть дискриминатор и заставить его принять их за реальные записи ЭКГ из первоначального набора данных.

Разработанная модель достигла стабильной и качественной генерации новых образцов ЭКГ, достоверно имитируя структуру и характеристики оригинальных данных. Чтобы подтвердить качество полученного результата, была проведена оценка разработанной генеративной состязательной сети с использованием широко применяемой метрики - Fréchet Distance (FD) [8].

Эта метрика предназначена для измерения схожести распределения синтезированных данных с естественным распределением реальных объектов. Пространство признаков генерируемого слоя рассматривалось как непрерывное, многомерное распределение Гаусса, затем определялись среднее значение и матрица ковариации для обеих групп данных - сгенерированной и реальной. Сгенерированные данные считаются качественными, если значение метрики FD находится в диапазоне от 0.9 до 1.0 (в зависимости от датасета сигналов ЭКГ), при этом

более низкие значения FD указывают на лучшее качество генерации, отражающее большую схожесть с реальными данными.

В табл. 1 показаны значения метрики FD нашей модели (MeGAN) и полученные в результате экспериментов, проведенных самостоятельно путем реализации и обучения различных архитектур, указанных в статье [9]. Сравнительный анализ результатов демонстрирует, что предложенная нами модель обеспечивает хорошие показатели качества. Это подтверждает достаточное сходство генерируемых сетью данных с реальными записями ЭКГ.

Таблица 1. Результаты сравнения

Table 1. Comparison results

Метод Method	FD метрика Metrics
RNN-AE GAN	0.969
LSTM-AE GAN	0.996
MeGAN	0.963
RNN-VAE GAN	0.982
LSTM-VAE GAN	0.975

Несмотря на высокое качество генерации сигналов ЭКГ, объем памяти, занимаемый моделью, превышает требования к вычислительным ресурсам, необходимые для развертывания генеративно-сопоставительной сети на маломощных медицинских устройствах.

Одним из ключевых факторов успешного применения генеративных сопоставительных сетей в условиях ограничений по вычислительным ресурсам является выбор наиболее подходящего уровня квантизации весовых коэффициентов. Так, уменьшение разрядности до 4 бит обладает рядом преимуществ. Во-первых, снижение в таком случае числа используемых битов резко сокращает объем необходимой оперативной памяти (практически до 25%) и ускоряет выполнение арифметических операций. Во-вторых, такая степень сжатия позволяет значительно уменьшить энергопотребление устройств, что особенно важно для мобильных приложений и встроенных систем медицинского назначения.

Первоначально для решения задачи квантизации весов генератора GAN был применен традиционный подход, основанный на методике Min-Max [10]. Этот подход нацелен на поддержание динамики распределения признаков путем сохранения максимального диапазона значений, что способствует сохранению наибольшего объема полезной информации даже при переходе к низкоресурсному представлению данных. Благодаря своей простоте и эффективности, данная техника получила широкое распространение в процессе квантизации различных типов глубоких нейронных сетей.

Принцип симметричной квантизации предполагает сохранение симметрии вокруг нулевого значения (рис.3), при которой границы допустимого диапазона задаются абсолютным максимумом квантизируемых величин $|r|_{max}$.




Рис. 3 - Симметричная квантизация

Fig. 3 - Symmetric quantization

Нулевое значение в исходной шкале непосредственно соответствует нулю в квантованной форме, что упрощает обработку и уменьшает искажения результатов.

Квантованное значение X_q вычисляется как округлённое к ближайшему целому частное исходного значения X делённое на коэффициент масштабирования S .

Коэффициент S представляет собой константу квантизации, необходимую для преобразования весовых коэффициентов в дискретный диапазон квантования; он определяется максимальным абсолютным значением сигнала $|r|_{max}$, делённым на величину $2^{N-1} - 1$, соответствующую максимально представимому целочисленному значению при N -битной разрядности:

$$X_q = \left\lfloor \frac{X}{S} \right\rfloor, \quad (1)$$

где $S = \frac{|r|_{max}}{2^{N-1}-1}$.

Алгоритм квантизации min-max выполняется в несколько этапов:

1. Определение диапазона значений. Находятся минимальное $|r|_{min}$ и максимальное $|r|_{max}$ значения весовой матрицы конкретного слоя нейронной сети.
2. Разделение диапазона. Диапазон равномерно делится на заданное количество уровней квантования (так, при 4-битном квантовании используется 16 уровней).
3. Квантование. Каждый вес присваивается ближайшему уровню квантования, полученному путем деления диапазона.

После выполнения процедуры квантизации вышеуказанным методом были проведены измерения следующих метрик качества, отражающих схожесть исходных и квантованных сигналов ЭКГ:

1. PSNR (Отношение пиковой мощности сигнала к шуму) [11]. Данная метрика показывает уровень соответствия между исходным и квантованным сигналом, оценивая соотношение энергии полезного сигнала и уровней вносимых ошибок. Высокое значение PSNR свидетельствует о низкой степени деградации сигнала.
2. SSIM (Индикатор структурного подобия) [11]. Показатель SSIM отражает меру структурного сходства между двумя изображениями или сигналами. Значения SSIM близки к единице указывают на высокое визуальное сходство между исходным и обработанным сигналом.
3. Pearson's Correlation (Коэффициент корреляции Пирсона) [12]. Данный показатель количественно выражает силу линейной связи между исходным и квантованным сигналом. Коэффициент Пирсона, близкий к 1, демонстрирует практически полное совпадение формы кривых обоих сигналов.

В табл. 2 приведено сравнение метрик качества модели MeGAN до и после применения квантизации на основе подхода Min-Max. Как можно заметить из табл. 2 данный подход приводит к потерям в точности и качестве восстановления.

Таблица 2. Сравнение метрик качества до и после квантизации MeGAN при помощи Min-Max подхода

Table 2. Comparison of quality metrics before and after MeGAN quantification using the Min-Max approach

Метрика качества Quality metrics	Значение метрики оригинальной модели The value of the original model's metric	Значение метрики квантованной модели The meaning of the quantized model metric
PSNR	29.82	28.75
SSIM	0.9430	0.931
Pearson's Correlation	0.9239	0.902

Это связано с тем, что, несмотря на всю простоту реализации и универсальность, алгоритм имеет серьезные недостатки:

- Равномерное квантование не учитывает распределение весов, что приводит к сильным искажениям в областях с высокой плотностью весов.
- Простое задание диапазона не принимает во внимание конкретные особенности задачи, что снижает качество сигнала.

Именно поэтому появилась потребность в разработке более современного и эффективного метода квантования, направленного на сохранение структуры и качества сигнала при минимальных затратах памяти. С целью минимизации объема памяти и поддержания высокого качества сигнала при использовании малого числа бит был разработан метод адаптивного квантования весов генератора Adaptive Generative Weight Reconstruction (AGWR). Данный подход принципиально отличается от традиционных методов квантования благодаря комбинации адаптивного выбора центров кластеров и эффективных инструментов борьбы с шумами, неизбежными при квантовании.

Центральным элементом метода является гибридная стратегия адаптации центров кластеров. Вместо простого выбора центров по минимальному и максимальному значениям, в AGWR используется специальный подход, основанный на кумулятивной сумме распределения весов [4].

В классических методах квантизации весов центры кластеров выбираются либо равномерно, либо с помощью итеративного подхода k-means, который минимизирует ошибку аппроксимации, но обычно не учитывает явно распределение весов через кумулятивную функцию. Некоторые методы учитывают статистику весов, например, гистограммы или плотность распределения, но обычно работают с плотностью вероятности, а не с кумулятивной функцией распределения.

Использование кумулятивной суммы распределения весов для определения оптимальных центров кластеров в AGWR позволяет учитывать фактическое распределение весов на всем диапазоне, а не просто в локальных пиках.

Конкретно, центры размещаются равномерно по кумулятивной вероятности, а не по равномерному шагу значений весов. Это обеспечивает лучшее покрытие редких и плотных областей распределения, минимизируя ошибку аппроксимации, особенно в случае сильно неравномерных распределений весов, где стандартные методы могут оставлять пробелы или перекрытия.

Например, если веса нейронной сети имеют длинный «хвост» с экстремальными значениями, кумулятивный подход гарантирует, что центры кластеров адаптируются к этому, снижая искажения при квантизации.

Другим ключевым компонентом метода является применение предварительного фильтра Гаусса [13]. Перед процессом квантования выполняется фильтрация весов, позволяющая устранить мелкие шумы, присутствующие в сигналах.

Это улучшает точность самого процесса квантования и защищает сигнал от неблагоприятных факторов.

AGWR включает в себя следующие основные шаги (рис.4):

1. Фильтрация весов. Весовые коэффициенты подвергаются фильтрации с помощью гауссова фильтра, чтобы минимизировать шумы и мелкие возмущения, оказывающие негативное влияние на последующие стадии.
2. Определение центров кластеров. С помощью подхода, основанного на кумулятивной сумме распределения весов, рассчитываются оптимальные по критерию минимизации ошибки аппроксимации [14] центры кластеров, что достигается за счет равномерного распределения по кумулятивной вероятности реального распределения весов.
3. Квантование весов основано на подсчете индекса принадлежности каждого элемента к определенному кластеру и последующем вычислении квантованного значения.




Рис. 4 – Метод квантизации AGWR
Fig. 4 – The AGWR quantification method

Весовые коэффициенты всех слоев генератора обученной модели MeGAN были также подвергнуты процессу квантования в 4 бита методом AGWR, после чего были произведены замеры метрик качества (табл.3).

Таблица 3. Сравнение метрик качества до и после квантизации GAN
Table 3. Comparison of quality metrics before and after GAN quantification

Метрика качества Quality metrics	Значение метрики оригинальной модели The value of the original model's metric	Значение метрики квантованной модели Min-Max The meaning of the quantized model metric Min-Max	Значение метрики квантованной модели методом AGWR The meaning of the quantized model metric AGWR
PSNR	29.82	28.75	29.81
SSIM	0.9430	0.931	0.9427
Pearson's Correlation	0.9239	0.902	0.9237

Обсуждение результатов. Как видно из экспериментальных результатов, стандартный Min-Max приводит к заметным потерям метрик качества, что указывает на ухудшение точности аппроксимации и потенциальные артефакты в синтезированных данных. В противоположность этому, AGWR минимизирует такие потери, сохраняя метрики практически на уровне оригинальной модели: PSNR - 29.81 (<0.04%), SSIM - 0.9427 (~0.03%), коэффициент корреляции Пирсона - 0.9237 (~0.02%). Такое минимальное снижение метрик свидетельствует о способности AGWR адаптивно перераспределять веса без существенного искажения распределения.

Табл. 4 представляет сравнительный анализ значений показателя метрики FD для изначально обученной модели MeGAN (до квантизации) и её квантованной версии с использованием метода AGWR. Это сравнение иллюстрирует влияние пост-обученной квантизации на метрику качества генерации модели. Как видно из представленных данных, наша квантованная модель демонстрирует незначительное снижение метрики FD, но при этом обеспечивает лучшие показатели по объему памяти (объем памяти снижен примерно на 75%).

Таблица 4. Результаты сравнения с квантованной моделью
Table 4. Comparison results with the quantized model

Метод Method	FD метрика Metrics
MeGAN	0.963
MeGANQuantModel	0.964

Таким образом, разработанный метод AGWR представляет собой эффективное решение для квантования генератора GAN, которое сочетает в себе адаптивность, средства

фильтрации и надежную систему противодействия шумам. Это делает его подходящим кандидатом для задач, связанных с внедрением нейронных сетей в среду с ограниченными ресурсами, таких как мобильные устройства или серверы с ограниченными возможностями.

Вывод. Настоящая работа охватывает полный цикл проектирования и оптимизации генеративно-сопоставительной сети для синтеза электрокардиографических сигналов (ЭКГ), начиная с этапа подготовки входных данных. В ходе серии экспериментов была создана и обучена собственная архитектура GAN. Сравнительный анализ метрики FD, проведённый на нашей модели и на других различных архитектурах, реализованных и обученных нами в рамках исследования, показал, что предложенная модель демонстрирует достаточно высокие показатели. Это свидетельствует о значительном сходстве сгенерированных данных с реальными ЭКГ-записями и подтверждает эффективность модели для восполнения дефицита клинических данных в медицинских приложениях.

Несмотря на значительные достижения GAN-моделей в генерации качественных синтетических выборок данных ЭКГ, их высокие требования к вычислительным ресурсам ограничивали широкое практическое применение. Разработанный нами метод адаптивного квантования AGWR эффективно решает эту проблему, обеспечивая оптимизацию весов модели без существенной потери качества. В сравнении с традиционным подходом Min-Max, который приводит к заметному снижению качества синтезируемых сигналов, разработанный подход позволяет сохранить метрики на уровне оригинальной модели даже при экстремальном сжатии весов генератора до 4 бит.

Предложенная методика открывает возможности для практического внедрения GAN-технологий в системы диагностики с ограниченными аппаратными ресурсами.

Достигнутое сокращение потребления объема памяти примерно на 75% без потери качества генерации позволит ускорить процессы создания синтетических данных, обеспечивая доступность таких подходов в ситуациях, когда сбор реальных клинических данных осложнён. Таким образом, исследование создаёт предпосылки для дальнейшего совершенствования интеллектуальных диагностических инструментов и перехода к следующему этапу персонализации медицинской помощи в области сердечно-сосудистой патологии.

Библиографический список:

1. Hannun A. Y., Rajpurkar P., Haghpanahi M., et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network // *Nature Medicine*. – 2019. – Vol. 25. – P. 65–69.
2. Wagner P., Strodthoff N., Bousseljot R., et al. PTB-XL, a large publicly available electrocardiography dataset // *Scientific Data*. – 2020. – Vol. 7. – P. 1–154.
3. Ian J. Goodfellow. Generative Adversarial Nets. // arXiv preprint arXiv: 1406.2661. – 2014.
4. Jacob B., Kligys S., Chen B., et al. Quantization and Training of Neural Networks for Efficient Integer-Arithmetic-Only Inference // *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. – 2018. – P. 2704–2713.
5. Moody G. B., Mark R. G. The impact of the MIT-BIH Arrhythmia Database // *IEEE Engineering in Medicine and Biology Magazine*. – 2001. – Vol. 20, № 3. – P. 45–50.
6. О.П. Тимофеева, М.М. Гордеев, Д.А. Кобляков. Обработка и генерация изображений ЭКГ // *Труды НГТУ им. П.Е. Алексеева* № 1 (132), 2021. – С. 24.
7. Hochreiter S., Schmidhuber J. Long Short-Term Memory // *Neural Computation*. – 1997. – Vol. 9, № 8. – P. 1735–1780.
8. Heusel M., Ramsauer H., Unterthiner T., et al. GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium // *Advances in Neural Information Processing Systems (NIPS)*. – 2017. – P. 6626–6637.
9. Fel Zhu, Ye Fei. Electrocardiogram generation with a bidirectional LSTM-CNN Generative adversarial network. // *Translational Biomedical Informatics*. – 2019. – P. 1–9.
10. A. Zhou et al. Incremental network quantization: Towards lossless CNNs with low-precision weights. // *Proceedings of the International Conference on Learning Representations (ICLR)*. – 2017.
11. Z. Wang et al. Image quality assessment: From error visibility to structural similarity. // *IEEE Transactions on Image Processing*. – Vol. 13, Issue 4, Apr. 2004. – PP. 600–612.
12. Field, A. *Discovering Statistics Using IBM SPSS Statistics*. – London: Sage Publications Ltd., 2018.

13. H. Li et al. Pruning Filters for Efficient ConvNets. // Proceedings of the International Conference on Learning Representations (ICLR). – 2017.
14. Lloyd, S. P. Least Squares Quantization in PCM // IEEE Transactions on Information Theory. – 1982. – Vol. 28, № 2. – P. 129–137.

References:

1. Hannun A. Y., Rajpurkar P., Haghpanahi M., et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine*. 2019;25:65–69.
2. Wagner P., Strodthoff N., Bousseljot R., et al. PTB-XL, a large publicly available electrocardiography dataset. *Scientific Data*. 2020;7:154.
3. IanJ. Goodfellow. Generative Adversarial Nets. // arXiv preprint arXiv: 1406.2661. – 2014.
4. Jacob B., Kligys S., Chen B., et al. Quantization and Training of Neural Networks for Efficient Integer-Arithmetic-Only Inference. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2018; 2704–2713.
5. Moody G. B., Mark R. G. The impact of the MIT-BIH Arrhythmia Database. *IEEE Engineering in Medicine and Biology Magazine*. 2001; 20(3):45–50.
6. O.P. Timofeeva, M.M. Gordeev, D.A. Koblyakov. ECG Image Processing and Generation. *Proceedings of the R.E. Alekseev NSTU* 2021;1(132):24.(In Russ)
7. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997;9(8):1735–1780.
8. Heusel M., Ramsauer H., Unterthiner T., et al. GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium. *Advances in Neural Information Processing Systems (NIPS)*. 2017;. 6626–6637.
9. Fel Zhu, Ye Fei. Electrocardiogram generation with a bidirectional LSTM-CNN Generative adversarial network. *Translational Biomedical Informatics*. 2019:1-9.
10. A. Zhou et al. Incremental network quantization: Towards lossless CNNs with low-precision weights. *Proceedings of the International Conference on Learning Representations (ICLR)*. 2017.
11. Z. Wang et al. Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*. 2004; 13(4, Apr.):600–612.
12. Field, A. Discovering Statistics Using IBM SPSS Statistics. – London: Sage Publications Ltd., 2018.
13. H. Li et al. Pruning Filters for Efficient ConvNets. *Proceedings of the International Conference on Learning Representations (ICLR)*. 2017.
14. Lloyd, S. P. Least Squares Quantization in PCM. *IEEE Transactions on Information Theory*. 1982; 28(2): 129–137.

Информация об авторах:

Максим Михайлович Гордеев, аспирант, кафедра «Информатика и системы управления»; maximgrdv@gmail.com; ORCID: 0009-0005-2450-0274

Артем Евгеньевич Савкин, ассистент, кафедра «Информатика и системы управления»; sae.20@bk.ru; ORCID: 0000-0003-4826-9087

Ольга Павловна Тимофеева, кандидат технических наук, доцент; кафедра «Информатика и системы управления»; optimofeeva@mail.ru;

ORCID: 0000-0002-1935-7697

Полина Анатольевна Шагалова, кандидат технических наук, доцент, кафедра «Информатика и системы управления»; polli-shagalova@yandex.ru; ORCID:0000-0002-6676-4228

Information about the authors:

Maxim M. Gordeev, Postgraduate Student, Department of Computer Science and Control Systems; maximgrdv@gmail.com; ORCID: 0009-0005-2450-0274

Artem E. Savkin, Assistant, Department of Computer Science and Control Systems; sae.20@bk.ru; ORCID: 0000-0003-4826-9087

Olga P. Timofeeva, Cand. Sci. (Eng.), Assoc. Prof.; Department of Computer Science and Control Systems; optimofeeva@mail.ru; ORCID: 0000-0002-1935-7697

Polina A. Shagalova, Cand. Sci. (Eng.), Assoc. Prof., Department of Computer Science and Control Systems; polli-shagalova@yandex.ru; ORCID:0000-0002-6676-4228

Конфликт интересов/Conflict of interest.

Авторы заявляют об отсутствии конфликта интересов/The authors declare no conflict of interest.

Поступила в редакцию/Received 08.11.2025.

Одобрена после рецензирования/Revised 19.01.2026.

Принята в печать/Accepted for publication 15.04.2026.