

Программно-аппаратный исследовательский комплекс диагностики состояния человека на основе облачной микросервисной архитектуры

Н. А. Борисов, Д. А. Карчков, Г. В. Кузенкова*

ФГАОУ ВО «Национальный исследовательский Нижегородский государственный университет
им. Н.И. Лобачевского», г. Нижний Новгород, Российская Федерация

Адрес: 603022, Российская Федерация, Нижний Новгород, пр. Гагарина, д. 23

* kuzenkovagv@mail.ru

Аннотация

Предложена архитектура программно-аппаратного комплекса сбора, хранения, анализа и обработки диагностических сигналов. Архитектура программно-аппаратного комплекса представлена несколькими уровнями (модулями). Аппаратной основой является набор сенсоров для регистрации различных показателей с поверхности тела человека. За агрегацию и аккумуляцию данных с устройств сбора данных отвечает хаб, представляющий собой совокупность программного обеспечения, функционирующего на персональном компьютере. Особенностью программно-аппаратного комплекса является программный модуль, реализованный в облаке, предоставляющий авторизованным пользователям различные возможности анализа данных. Анализ сигналов производится аналитическими и нейросетевыми средствами, при необходимости проводится дообучение или корректировка алгоритмов анализа, которая осуществляется на отдельных выделенных мощностях – микросервисах. Разработаны две нейросетевые модели, адаптированных под две задачи сегментации и классификации сигналов ЭКГ. Нейронная сеть для задачи сегментации создана на основе модификации UNet и включает четыре блока, каждый из которых состоит из двух одномерных сверточных слоёв. Предложенная модель с высокой точностью локализует кардиоциклы в сигнале. Для задачи классификации сигналов ЭКГ применялась базовая архитектура MobileNetV3, адаптированная под входные тензоры в формате (batch, 2, 5000), где batch – количество сигналов ЭКГ. Сформированы обучающая и тестовая выборки с учетом возможных проблем и неточностей, из сегментации исключены первый и последний сердечные циклы. Предложенная архитектура системы может быть масштабирована для других видов сигналов (например, сигналов головного мозга ЭЭГ) за счет выделения моделей в отдельный микросервис и возможностью последующей интеграции в развернутые аппаратно-программный комплекс сбора, хранения, анализа и обработки сигналов.

Ключевые слова: облачная микросервисная архитектура систем диагностики, нейросетевая модель анализа диагностических сигналов, сигналы ЭКГ

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Для цитирования: Борисов Н. А., Карчков Д. А., Кузенкова Г. В. Программно-аппаратный исследовательский комплекс диагностики состояния человека на основе облачной микросервисной архитектуры // Современные информационные технологии и ИТ-образование. 2026. Т. 22, № 1. С. 137-146. <https://doi.org/10.25559/SITITO.022.202601.137-146>

© Борисов Н. А., Карчков Д. А., Кузенкова Г. В., 2026



Контент доступен под лицензией Creative Commons Attribution 4.0 License.
The content is available under Creative Commons Attribution 4.0 License.



Software and Hardware Research Complex for Human Health Diagnostics Based on Cloud Microservice Architecture

N. A. Borisov, D. A. Karchkov, G. V. Kuzenkova*

National Research Lobachevsky State University of Nizhny Novgorod, Nizhny Novgorod, Russian Federation

Address: 23 Prospekt Gagarina, building 2, Nizhny Novgorod 603022, Russian Federation Russian Federation

* kuzenkovagv@mail.ru

Abstract

A hardware and software system for collecting, storing, analyzing, and processing diagnostic signals is proposed. The architecture of the hardware and software system is represented by several layers (modules). The hardware core is a set of sensors for recording various parameters from the human body surface. The hub, which is a collection of software running on a personal computer, is responsible for the aggregation and accumulation of data from data collection devices. A key feature of the hardware and software system is a software module implemented in the cloud, providing authorized users with various data analysis options. Signal analysis is performed by analytical and neural network tools, if necessary, further training or adjustment of analysis algorithms is carried out, which is carried out on separate dedicated capacities – microservices. Two neural network models have been developed, adapted for two tasks: segmentation and classification of ECG signals. The neural network for the segmentation task is based on a modification of UNet and includes four blocks, each consisting of two one-dimensional convolutional layers. The proposed model localizes cardiac cycles in the signal with high accuracy. For the ECG signal classification task, the MobileNetV3 base architecture was used, adapted to input tensors in the format (batch, 2, 5000), where “batch” is the number of ECG signals. Training and test sets were generated taking into account potential issues and inaccuracies, and the first and last cardiac cycles were excluded from segmentation. The proposed system architecture can be scaled to other signal types (e.g., brain EEG signals) by separating the models into a separate microservice and enabling subsequent integration into a comprehensive hardware and software system for signal collection, storage, analysis, and processing.

Keywords: cloud microservice architecture for diagnostic systems, neural network model for diagnostic signal analysis, ECG signals

Conflict of interests: The authors declare no conflict of interest.

For citation: Borisov N.A., Karchkov D.A., Kuzenkova G.V. Software and Hardware Research Complex for Human Health Diagnostics Based on Cloud Microservice Architecture. *Modern Information Technologies and IT-Education*. 2026;22(1):137-146. <https://doi.org/10.25559/SITITO.022.202601.137-146>



Введение

Цифровизация в такой практической и научной области деятельности как медицина позволяет организовать единую и эффективную среду оказания медицинской помощи. Основными трендами развития здравоохранения в России и мире являются персонализация, виртуализация и доказательность [1-3]. В России, Саудовской Аравии, Индии и Китае доля медицинских работников, использующих цифровые технологии здравоохранения или мобильные приложения для здравоохранения, колеблется от 81% до 94%. В Германии, Великобритании, Австралии и США этот диапазон составляет от 64% до 76%¹. Объем рынка, доля и анализ рынка аналитики в здравоохранении по таким показателям как описательный анализ, прогнозный анализ и предписывающий анализ, а также финансовая, клиническая, операционная и административная аналитика, аналитика здоровья населения возрастет в 6 раз (с 25,89 млрд долларов США в 2024 до 145,81 млрд долларов США к 2032 году)².

Инструменты анализа данных в сфере здравоохранения являются важными инструментами для улучшения результатов лечения пациентов и внедрения инноваций в организациях здравоохранения. В ряду современных технологий, применяемых в современных медицинской аналитике, выделяются технологии искусственного интеллекта [4, 5], имеющих высокий потенциал в решении задач здравоохранения [6]. Тем не менее, существуют определенные проблемы при внедрении цифровых инструментов медицинской аналитики. К ним относят проблему искажения данных при сборе и разметки данных для машинного обучения [7, 8], что может существенно сказаться на конечных результатах научных исследований, стратегиях лечения, выработки рекомендаций.

Несмотря на то, что стандартизация обмена данными имеет быть (*Digital Imaging and Communications in Medicine*, стандарт HL7 и другие), продолжает быть актуальной проблема интеграции данных с медицинской диагностической аппаратуры [9]. Вариативность данных, связанная со спецификой настройки оборудования, также может приводить к разным результатам на разной аппаратуре. Решение проблем лежит в области стандартизации хранилища данных для исследовательских целей, совершенствования безопасности передачи данных, профессиональной разметки первичных банков данных [10-12], синхронизированных справочников [13]. В России уже реализованы электронные системы ведения медицинских карт, системы управления врачебной практикой, порталы для пациентов, системы поддержки принятия клинических решений, системы удаленного мониторинга [14]. Сейчас востребованы сервисы взаимодействия исследователей и практикующих врачей³.

Однако для обеспечения возможности аккумуляции медицинской информации и широкого использования опыта врачей, осуществивших постановку диагноза на основе этих данных, необходима единая платформа для их хранения и обеспечения авторизованного доступа к ним всех заинтересованных и компетентных сторон. Такое решение на сегодня возможно только

за счет создания специализированной облачной инфраструктуры [12], [15, 16]. Кроме того, облачные инфраструктуры медицинской диагностики являются основой мониторинговых систем состояния человека, где особый интерес представляет комплексная прогноз и оценка возможной катастрофы организма, особенно если человек выполняет деятельность, связанную с опасными последствиями сбоя в работе (операторы атомных станций, водители и др.). Качественно и неинвазивно определить состояние человека можно только при регистрации различных показателей с поверхности тела человека. Так, например, для оценки функционального состояния сердца необходимо регистрировать сигнал электрокардиограммы, для определения качества мозговой активности используют анализ электроэнцефалограммы, регистрация которой проходит с поверхности головы, а для анализа звуковых шумов часто используют приёмы электронной аускультации [17, 18]. Стоит отметить, что порой проблемы в работе обследуемого органа могут быть вызваны системами, напрямую не связанные с объектом исследования. Так, экстрасистолия – преждевременное сокращение сердца или его камер, может возникать из-за психоэмоционального напряжения, переутомления, гормональных колебаний или сбоев вегетативной системы [19]. В таком случае нельзя ограничиваться исключительно анализом сигнала ЭКГ, ведь он покажет лишь последствия заболевания. Таким образом, важно проведение комплексного обследования и комбинированной оценки результатов.

Диагностика заболеваний является первостепенной, но не единственной причиной комплексного анализа показателей. Исследователи и учёные, работающие над разработкой методов машинного обучения и применении таких методов на практике нуждаются в наборах данных, и особо остро такая нехватка наблюдается при проведении медицинских исследований. Если говорить о доступных данных, то основным и научно признанным поставщиком является PhysioNet [20], в базе которого присутствуют различные медицинские данные, начиная с сигналов электрограмм крыс и заканчивая сигналами ЭЭГ и компьютерными томограммами. Однако, с каждым годом появляется всё больше публикаций, в которых зачастую говорится о высоком проценте зашумлённых и испорченных данных, восстановление или очистка которых приводит к потере важной для исследования информации [21-23]. Ещё одной проблемой банка данных PhysioNet является обособленность данных, а именно отсутствуют или представлены в малом количестве датасеты комплексной оценки состояния испытуемого. Так, база данных сегментированных сигналов ЭКГ [24] содержит данные 197 пациентов, и с каждого зарегистрирован сигнал, записанный в 12-ти отведениях. Врачом функционалистом определена локализация кардиоциклов: сокращения предсердий, сокращения желудочков и восстановление миокарда (период рефрактерности). Однако при этом не регистрировались другие важные показатели: артериальное давление, ЭхоКГ, сатурация и прочие показатели, способные дать более полную картину по состоя-

¹ ИТ в здравоохранении (мировой рынок) [Электронный ресурс] // TAdviser, 2025. URL: <https://www.tadviser.ru/index.php>Статья: ИТ в здравоохранении (мировой рынок) (дата обращения: 19.12.2025).

² Bhushan Pawar. The Global Market for Healthcare Analytics [Электронный ресурс] // Fortune Business Insights, 2025. URL: <https://www.fortunebusinessinsights.com/healthcare-analytics-market-102641> (дата обращения: 19.12.2025).

³ Например, <https://webiomed.ru/>, <https://www.onecell.ai/> и др.



нию каждого пациента. Таким образом, основной проблемой является отсутствие таких систем комплексного анализа и сбора данных, способных синхронно, в режиме онлайн, собирать функциональные показатели состояния человека. Отсутствуют и инструменты разметки таких данных. Известно лишь о нескольких инструментах, позволяющих специалисту сегментировать или классифицировать состояние, но, как правило, предлагается разметка лишь одной, конкретной задачи исследуемой области. Например, в работе [25] представлены инструменты сегментации специализированные исключительно на компьютерных томограммах и медицинских изображениях. Что касается одномерных и двумерных сигналов (ЭКГ, ЭМГ, ЭЭГ и др.), то доступных, открытых и поддерживаемых инструментов разметки нами не найдено, как не найдено и инструментов комплексной разметки.

Целью работы является разработка программно-аппаратного комплекса, который направлен на стандартизацию и упрощение механизма сбора, хранения и разметки данных с применением аналитических и нейросетевых методов анализа данных.

Материалы и методы

Для реализации комплекса необходимо выделить базовые компоненты решения. В этой архитектуре можно предварительно выделить несколько слоев по аналогии с архитектурой решений Интернета Вещей:

1. Уровень аппаратуры: здесь происходит генерация данных и их преобразование в формат, удобный для дальнейшей обработки.
2. Сетевой уровень передачи данных (реализуется локальной сетью медицинского учреждения).
3. Уровень предварительной обработки: здесь производится фильтрация данных (при необходимости), с полученными данными работает человек-эксперт (врач), использующий программные средства визуализации данных, их сегментации (при необходимости), постановки первичного диагноза (при возможности). Данный уровень реализуется локально в медицинских учреждениях, использующих ту аппаратуру, которая выступает источником генерации данных.
4. Уровень хранения данных. Поскольку медицинские данные характеризуются различным форматом и значительным объемом, необходимы специализированные базы данных, реализуемые в облаке.
5. Уровень приложений/сервисов. Наиболее интересный уровень, реализуется в облаке, и предоставляет авторизованным пользователям различные возможности анализа данных, реализованные в виде микросервисов. На этом же уровне возможно коллаборация пользователей, заинтересованных в доступе к одним и тем же данным и их совместной обработке. Включает средства визуализации данных для их совместной (при необходимости) обработки, а также средства ИИ и другие модели, которые могут использоваться для поддержки постановки диагноза и выработки плана лечения.
6. Уровень обобщения данных и формирование моделей принятия решений, используемых на уровне приложений/сервисов. Позволяет ведущим специалистам в каждой предметной области медицинской диагностики определять параметры моделей принятия решений, а также взаимодействовать с ИИ-специалистами по формированию новых моделей

7. Уровень стратегического управления и бизнес-менеджмента. Включает средства аналитики для управления функционированием системы, определения политик привлечения новых пользователей и организации их доступа в систему.

Данная архитектура является иерархической, что позволяет на каждом слое использовать несколько альтернативных технологий, согласованных по формату входных-выходных данных. Возможно также выделение новых уровней при наличии такой необходимости, например, при возникновении большой нагрузки на уровне приложений/сервисов может оказаться целесообразным выделение над ним специального уровня балансировки нагрузки, если это не предусмотрено по умолчанию средствами облачного хранилища, в котором реализуется предлагаемая инфраструктура.

Для реализации аппаратной компоненты нижнего уровня системы в качестве микроконтроллера для организации трансфера и буферизации данных выбрана плата ESP32 с процессором Xtensa LX7. Особенностью данного микроконтроллера является поддержка таких распространённых протоколов передачи данных как Bluetooth Classic, Bluetooth Low Energy и Wi-Fi. Кроме того, в силу наличия аппаратных протоколов SPI, I2C и UART появляется возможность подключить и обмениваться данными с такими популярными сенсорами регистрации биопотенциалов как ADS129X, ADS8233, модулями для аускультации MAX4466 и оценки сатурации MAX30105 и многими другими. Большая тактовая частота процессора позволяет записывать с высоким разрешением (свыше 10 кГц), а оперативной памяти достаточно для буферизации зарегистрированных сэмплов сигнала. Базовым языком разработки встроенного программного обеспечения и библиотеки, реализующей протокол передачи данных, является C++, что позволяет разрабатывать свои сенсоры для регистрации сигналов и улучшать имеющиеся встроенное программное обеспечение.

Для поддержания высоких скоростей передачи, зарегистрированных с помощью УСД сигналов выбрана технология передачи данных Wi-Fi. Скорость до 600 Мбит в секунду позволит организовать связь сразу с несколькими поставщиками данных с минимальными потерями в скорости передачи больших цифровых массивов.

Высокая скорость передачи данных необходима для поддержания онлайн режима обработки сигнала, так как частота дискретизации часто может варьироваться от 100 Гц до 20 кГц, в зависимости от природы наблюдаемого эффекта. Так, в стандарте регистрации ЭКГ прописана частота сэмплирования от 250 до 500 герц, а для высокочастотной регистрации от 1000 Гц. Если говорить об экспериментах на животных, к примеру, на изолированных сердцах крыс, то стандартной частотой регистрации электрограмм с поверхности миокарда составляет 20 000 Гц. В этом случае скорости передачи по Bluetooth каналу в 700 Кбит в секунду будет недостаточно.

Хранения результатов экспериментов и обработки сигналов осуществляется на сервере системы по средствам специализированного S3 хранилища типа MinIO. Доступ к экспериментам разграничен за счёт организации баз данных пользователей, сигналов, экспериментов и их результатов.

Для организации хранения информации о пользователях, экспериментах, сигналах и разметках используется СУБД PostgreSQL.



Серверное ПО разработано с использованием языка C# и фреймворка ASP.NET, так как технология имеет мощную систему аутентификации, эффективную систему организации работы с популярными системами управления базами данных, поддержку современных протоколов и возможность контроля работы с отдельными микросервисами.

Результаты исследования

1 Архитектура программно-аппаратного комплекса сбора, хранения, анализа и обработки сигналов

На рисунке 1 представлена разработанная архитектура комплекса.

Аппаратная компонента представлена набором сенсоров для регистрации различных показателей с поверхности тела человека. Под сенсором понимается совокупность модуля регистрации сигнала с тела человека, микроконтроллера обеспечения буферизации и передачи сигнала, а также встроенного программного обеспечения для обеспечения аккумуляции и трансфера данных. Основными задачами данного слоя архитектуры являются:

- Регистрация сигнала с тела человека по средствам специализированных модулей;
 - Буферизация данных в локальной памяти микроконтроллера;
 - Реализация передачи сигнала в хаб данных согласно разработанному унифицированному протоколу;
 - Адаптация разработки встроенного программного обеспечения под работу с различными модулями регистрации сигнала;
 - Адаптация разработки встроенного программного обеспечения под работу с различными технологиями передачи данных.
- Хаб данных – компонента, основная задача которой сбора данных с сенсоров и их предобработка. Благодаря данному слою архитектуры решения производится упаковка данных в формат, пригодный и оптимизированный для дальнейшего хранения, распространения и обработки. Хаб данных представляет собой совокупность программного обеспечения и персонального компьютера, главная цель которой заключается в агрега-

ции и аккумуляции данных с устройств сбора данных.


Данный слой архитектуры может быть представлен в двух принципиально различных состояниях:

- Тонкий клиент, когда сигналы с устройств сбора данных поступают на микрокомпьютер, с целью форматирования (приведения к единому формату описанной системы), локального хранения и дальнейшей отправки на сервера системы для обработки в рамках web-интерфейса;
- Персональный компьютер, когда данные поступают по радиоканалу на компьютер пользователя с заранее установленным и настроенным программным обеспечением для локальной обработки данных, без выхода в сеть Интернет, но с возможностью загрузки полученных в ходе проведения эксперимента сигналов на сервера системы.

Компонента анализа и обработки представлена программным обеспечением, задача которого заключается в визуализации данных с датчиков, их разметки и анализа. Предполагается, что выбор инструмента анализа сигналов и формирования результатов исследования будет лежать на исследователе, что накладывает необходимость на разработку гибкого механизма выбора аппарата обработки (аналитически, нейросетевые, комбинированные). Данный компонент имеет как офлайн, так и онлайн интерфейс для повышения удобства использования и простоты трансфера данных.

Серверная часть решения нацелена на организацию хранения данных экспериментов, предоставления доступа по средствам графического web-интерфейса, а также привлечения к разметке данных узкоспециализированных специалистов: функциональных диагностов, эпилептологов и др. Кроме того, микросервисная архитектура организации серверной части позволяет разворачивать различные модели для организации обработки сигналов в режиме постоянного доступа.

Компонент визуализации, хранения, разметки и анализа данных представлен совокупностью алгоритмов анализа данных средствами аналитических и нейросетевых методов, а также алгоритмов и технологий визуализации данных.



Р и с. 1. Архитектура решения программно-аппаратного комплекса сбора, хранения, анализа и обработки сигналов

F i g. 1. Architecture of the software and hardware complex for signal acquisition, storage, analysis, and processing

Источник: здесь и далее в статье все таблицы и рисунки составлены авторами.

Source: Hereinafter in this article all tables and figures were made by the authors.



Работа с данными может вестись как на локальном персональном компьютере, в рамках разработанного десктопного программного обеспечения, так и на облачном web-сервисе.

Серверное программное обеспечение организует трансфер данных между базами данных системы, S3 хранилищами, микросервисами анализа данных и программами анализа, обработки и визуализации данных. При этом осуществляется доступ к серверу системы обоих вариантов реализации с целью использования нейросетевых моделей для сегментации, классификации и обработки сигнала в целом. Интерфейс адаптирован для синхронного наблюдения информации с нескольких УСД в режиме реального времени.

Для распределения нагрузки и повышения производительности, анализ сигналов аналитическими и нейросетевыми средствами, а при необходимости дообучение или корректировка алгоритмов анализа, происходит на отдельных выделенных мощностях – микросервисах. Доступ к данному слою архитектуры осуществляется по средствам протокола GRPC из сервера описываемого комплекса. Таким образом, слой анализа и визуализации эксперимента получает доступ к инструменту обработки сигнала без необходимости локального развёртывания моделей машинного обучения и аналитических алгоритмов обработки.

2 Обработки сигналов в условиях выделенных микросервисов

В качестве примера математического аппарата, обрабатывающего сигналы в условиях выделенных микросервисов можно выделить два вида нейронных сетей, ориентированных на задачу сегментации (выделение участков сигнала, имеющих диагностическую или исследовательскую ценность) или задачу классификации (определение принадлежности участка сигнала к одному из состояний).

В рамках исследования разработаны две нейросетевые модели, адаптированных под две задачи: 1) сегментация ЭКГ; 2) классификации сигналов ЭКГ.

Сегментация сигналов ЭКГ. Сегментация сигналов ЭКГ – это процесс выделения на кардиограмме кардиоциклов: зарождение и распространение импульса по предсердиям (зубец Р), срабатывание желудочков для распределения кислорода по большому кругу кровообращения (QRS комплекс) и восстановление миокарда (зубец Т). Локализация данных комплексов в сигнале ЭКГ позволяет с помощью аналитических алгоритмов запрограммировать поиск патологических состояний и незначительных отклонений. Ценность такого подхода заключается в высокой степени объяснимости поведения нейронной сети, так как на выходе данной модели мы имеем чёткую карту распределения этапов работы сердца во времени.

В работе используется модифицированная нами одномерная версия UNet [26] (рисунок 2). Входными данными нейронной сети является вектор длины l , где l — количество измерений в сигнале ЭКГ, полученного с одного отведения. Размер выходного тензора — $(4, l)$. Каждый столбец выходной матрицы содержит 4 значения, отражающих степень уверенности нейронной сети в том, что соответствующая точка сигнала принадлежит к одному из сегментов:

- Р – прохождение импульса по предсердиям;
- QRS – прохождение импульса по желудочкам;

- Т – расслабление и восстановление миокарда;
- Фон – отсутствие явной сердечной активности, интересной для анализа.

Нейронная сеть включает 4 блока, каждый из которых состоит из двух одномерных сверточных слоёв. После каждой свёртки применяются нормализация по батчу и функция активации ReLU. Сжатие сигнала выполняется за счёт использования свёрток с шагом (*stride*) больше 1. После блока сжатия тензор поступает в блок, включающий две последовательные одномерные свёртки, за которыми следуют нормализация по батчу и функция активации ReLU. В конце блока применяется модуль внимания SE (*Squeeze-and-Excitation*), позволяющий адаптивно перенастраивать важность отдельных каналов, усиливая значимые признаки и подавляя менее важные. Выход из предыдущего слоя осуществляется с помощью слоёв транспонированной свёртки (*ConvTranspose1d*). После каждого масштабирования выходной тензор объединяется (конкатенируется) с соответствующим выходом из части энкодера (*skip connection*). Полученный тензор обрабатывается свёрточным блоком. После финального декодера применяется ещё один свёрточный слой с ядром 1, формирующий выход размером $(4, l)$, соответствующий вероятностной маске классов Р, QRS, Т и фон. Так как выходом нейронной сети является матрица размера $(4, l)$ применяется функция *argmax* к столбцам матрицы, чтобы получить вектор длины l или маску, которая ставит в соответствие каждому отсчёту конкретный класс.


Обучение нейронной сети и эксперименты проводились на датасете LUDB [24], который содержит 197 кардиограмм с 12 отведениями длительностью 10 секунд, записанных с частотой дискретизации 500 Гц. Данные были разделены на обучающие и тестовые выборки в соотношении 0,8 и 0,2 соответственно. С учетом возможных проблем и неточностей из сегментации исключены первый и последний сердечные циклы. Для обучения модели использовалась взвешенная функция потерь *CrossEntropyLoss*. Для оценки качества использовалась метрика *macro F1*, усредняющая *F1 score* по всем классам. Данная метрика учитывает, что начало и конец сегмента определены верно, если их отклонение от аннотаций врача не превышает 50 мс. Для реализации архитектуры U-Net и обучения модели был выбран язык Python, фреймворк машинного обучения PyTorch. Таблица 1 демонстрирует динамику *loss* функции и метрики. На эпохе 39 достигнуты локально оптимальные показатели *loss* функции и метрики *macro F1*. Дальнейшее обучение приводит к переобучению.

Таблица 1. Зависимость *loss* функции и целевой метрики от эпохи обучения

Table 1. Loss Function and Target Metric vs. Training Epoch


Номер эпохи	CrossEntropyLoss	Macro F1
0	0.164	0.751
9	0.049	0.996
19	0.047	0.996
29	0.035	0.996
39	0.035	0.997
49	0.035	0.997





Р и с. 2. Архитектура одномерной, адаптированной под сегментацию ЭКГ, модифицированной нейронной сети UNet

F i g. 2. Architecture of a 1D Modified U-Net Neural Network Adapted for ECG Segmentation



Р и с. 3. Сегментация сигналов ЭКГ: а) результаты сегментации обученной нейронной сетью, б) результат сегментации, сделанный экспертом (функциональным диагностом). Цвет означает следующее: синий – фон (места, не имеющие значение для анализа), желтый – сокращение предсердий, зеленый – сокращение желудочков, красный – восстановление миокарда. Чёрными прямоугольниками показаны места в сигнале ЭКГ, где предсказание модели расходится с мнением врача функционалиста).

F i g. 3. ECG signal segmentation: a) results of segmentation by the trained neural network; b) results of manual segmentation by an expert (functional diagnostician).

Colors represent: blue – background (non-significant areas), yellow – atrial contraction, green – ventricular contraction, red – myocardial recovery. The black rectangles indicate the areas in the ECG signal where the model's prediction diverges from the functional diagnostician's opinion.



На рисунке 3(а) показаны результаты сегментации ЭКГ средствами разработанной нейронной сети. На рисунке 3(б) разметка, сделанная экспертом (функциональным диагностом) с помощью инструментов визуализации и разметки модуля. Таким образом, нейросеть с высокой точностью локализует кардиоциклы в сигнале ЭКГ. Следует отметить, что из анализа исключаются первая и последняя секунды сигнала ЭКГ, что традиционно связано с особенностью архитектуры такого типа нейросети.

Классификация сигналов ЭКГ

Задача классификации сигналов ЭКГ, заключается в определении наличия той или иной нозологии исключительно средствами нейронных сетей, без привлечения аналитических методов. В таком случае сеть сама выделяет в сигнале особенности и на их основе строит предположения и предсказания. Источником данных для решения задачи классификации выступили три крупнейших базы ресурса PhysioNet [20]: PTB-XL, Chapman, Georgia. Базы данных были конкатенированы в одну, наиболее шумные сигналы были исключены из рассмотрения. В рамках разработки модели, сконцентрировано внимание на трёх базовых ритмах: нормальном синусовом ритме, синусовой вариации (например, тахикардия, брадикардия) и остальных типах ритмов. Следует отметить, что обучение проводилось на отведениях I и II, для создания экономной по памяти модели, пригодной для инференса большого числа копий модели на маломощных компьютерах. Датасет был адаптирован для применения метрики Ассигасу, за счёт избавления от дисбаланса классов.

Для минимизации конечного размера модели в качестве базовой архитектуры сети выбрана MobileNetV3 [27], адаптированная под входные тензоры в формате (batch, 2, 5000), где batch – количество сигналов ЭКГ. Для реализации small подхода, используются блоки ConvBNAct, InvertedResidual, и SqueezeExcite [28]. Финальная архитектура сети была адаптирована для микрокомпьютеров. В частности, была уменьшена глубина сети, с целью повышения компактности и быстродействия на маломощных компьютерах при запуске нескольких экземпляров сети. Крайний слой сети адаптирован для классификации сигналов ЭКГ пол трём классам.


Обучение модели проводилось средствами фреймворка PyTorch. При этом базовые параметры обучения следующие:

- Оптимизатор: Adam.
- Функция потерь: CrossEntropyLoss.
- Размер батча: 32.
- Число эпох: 30.
- Learning Rate: 1e-3.

На рисунке 4 представлены графики зависимости точности предсказания на тестовой выборке и значения функции потерь от количества эпох обучения. Для решения задачи классификации получена модель, точность которой, соответствует 0.742 метрики Ассигасу (при 15 эпохах обучения).

Таким образом, разработанные модели могут быть основой для микросервисов в предложенной архитектуре комплекса. Дальнейшее развитие исследования видится в расширении обучающей выборки, средствами описанного комплекса, а также в разработке моделей для других видов сигналов (например, сигналов головного мозга ЭЭГ) за счет выделения моделей в отдельный микросервис и возможностью последующей интеграции в развернутые аппаратно-программный

комплекс сбора, хранения, анализа и обработки сигналов.



Р и с. 4. Точность предсказания на тестовой выборке и значения функции потерь от количества эпох обучения:

- а) график зависимости значения функции потерь от количества эпох обучения; б) график зависимости точности предсказания на тестовой выборке от числа эпох обучения.

F i g. 4. Prediction accuracy on the test set and loss function values versus the number of training epochs: a) loss function vs. training epochs; b) test set prediction accuracy vs. training epochs.

Заключение

Представлена система исследования и диагностики состояния человека на основе облачной архитектуры. Предложена архитектура программно-аппаратного комплекса сбора, хранения, анализа и обработки диагностических сигналов. Архитектура программно-аппаратного комплекса состоит из нескольких уровней (модулей). Особенностью программно-аппаратного комплекса является модуль, реализованный в облаке, предоставляющий авторизованным пользователям различные возможности анализа данных. Анализ сигналов аналитическими и нейросетевыми средствами, а при необходимости дообучение или корректировка алгоритмов анализа, происходит на отдельных выделенных мощностях – микросервисах.

Микросервисная архитектура позволяет расширить возможности аппарата обработки данных, за счёт добавления новых сервисов обработки. Так, если появляется необходимость в нетривиальной обработке сигнала, достаточно сформировать отдельный узел для разворачивания анализирующего алгоритма и организовать соответствующий доступ из серверного ПО. Такой подход позволит многократно масштабировать систему и расширять при появлении новых, специфичных задач.



References

- [1] Rykov M.Yu. The evolution of personalized medicine: publications review. *Problems of Social Hygiene, Public Health and History of Medicine*. 2022;30(6):1211-1219. (In Russ., abstract in Eng.) <https://doi.org/10.32687/0869-866X-2022-30-6-1211-1219>
- [2] Kovaleva I.P., Voblaya I.N., Zayarnaya I.A., et al. The Actual Trends in Health Care Development. *Problems of Social Hygiene, Public Health and History of Medicine*. 2026;34(1):5-11. (In Russ., abstract in Eng.) <https://doi.org/10.32687/0869-866X-2026-34-1-5-11>
- [3] Grigorieva N.S., Demkina A.E., Korobeynikova A.N. Digitalization in the Russian healthcare: barriers to digital maturity. *Population and Economics*. 2024;8(1):1-14. <https://doi.org/10.3897/popecon.8.e111793>
- [4] Akbulut S., Colak C. Next-Generation Healthcare: Artificial Intelligence Applications in Disease Management. *Diagnostics*. 2024;14(11):1087. <https://doi.org/10.3390/diagnostics14111087>
- [5] Topol E.J. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*. 2019;25(1):44-56. <https://doi.org/10.1038/s41591-018-0300-7>
- [6] Zhang P., Kamel Boulos M.N. Generative AI in Medicine and Healthcare: Promises, Opportunities and Challenges. *Future Internet*. 2023;15:286. <https://doi.org/10.3390/fi15090286>
- [7] Chen R.J., Wang J.J., Williamson D.F.K., et al. Algorithmic fairness in artificial intelligence for medicine and healthcare. *Nat. Biomed. Eng*. 2023;7:719-742. <https://doi.org/10.1038/s41551-023-01056-8>
- [8] Ryazanova S.V., Komkov A.A., Mazaev V.P. Prospects of medical technologies of artificial intelligence. *Scientific review*. 2022;(4):90-94. (In Russ., abstract in Eng.) <https://doi.org/10.17513/srms.1279>
- [9] Dabagov A.R. Informatization of healthcare and some problems of building integrated medical information systems. *Journal of Radio Electronics*. 2011;(9):13. (In Russ., abstract in Eng.) EDN: OJKRQD
- [10] Kumar A., Singh D. Benchmark Datasets for Analysis in Medical Systems. In: Artificial Intelligence in Modern Healthcare System. *Transactions on Computer Systems and Networks*. Singapore: Springer; 2025. p. 255-284. https://doi.org/10.1007/978-981-96-6703-1_11
- [11] Yang Y., Khorshidi H.A., Aickelin U. A review on over-sampling techniques in classification of multi-class imbalanced datasets: insights for medical problems. *Front. Digit. Health*. 2024;6:1430245. <https://doi.org/10.3389/fdgth.2024.1430245>
- [12] Chava K. Architecting cloud-based infrastructure for scalable and secure health data storage. In: Revolutionizing Healthcare Systems with Next-Generation Technologies: The Role of Artificial Intelligence, Cloud Infrastructure, and Big Data in Driving Patient-Centric Innovation. Deep Science Publishing; 2025. p. 36-51. https://doi.org/10.70593/978-81-988918-5-3_4
- [13] Rudetskiy S.V., Belchenkov A.A., Kalinovskiy V.V., Morozov M.A., Fokht O.A. Evolution of an approach to integration between medical and laboratory information systems. *Manager Zdravoohranenia*. 2023;S:55-64. (In Russ., abstract in Eng.) <https://doi.org/10.21045/1811-0185-2023-S-55-64>
- [14] Monakov D.M., Altunin D.V. Medical information systems: modern realities and prospects. *Russian Journal of Telemedicine and E-Health*. 2022;8(4):46-53. (In Russ., abstract in Eng.) <https://doi.org/10.29188/2712-9217-2022-8-4-46-53>
- [15] Simi Abdul Shukkoor. Cloud-based machine learning for precision medicine: Transforming healthcare delivery in US. *World Journal of Advanced Research and Reviews*. 2025;26(01):3940-3950. <https://doi.org/10.30574/wjarr.2025.26.1.1507>
- [16] Bilakanti G. Cloud-based Data Lakes in Healthcare: Challenges and Opportunities. *International Journal Research of Leading Publication (IJLRP)*. 2023;4(8):1-12. <https://doi.org/10.5281/zenodo.15196922>
- [17] Perna D., Tagarelli A. Deep Auscultation: Predicting Respiratory Anomalies and Diseases via Recurrent Neural Networks. In: 2019 IEEE 32nd International Symposium on Computer-Based Medical Systems (CBMS). Cordoba, Spain: IEEE Press; 2019. p. 50-55. <https://doi.org/10.1109/CBMS.2019.00020>
- [18] Adhikary S., Ghosh A., Nandi S. iBMSR: Intelligent Body Mass Status Recognition from Respiratory Auscultation. In: 15th International Conference on COMMunication Systems & NETworkS (COMSNETS). Bangalore, India; 2023. p. 102-107. <https://doi.org/10.1109/COMSNETS56262.2023.10041309>
- [19] Troisi F., Guida P., Quadriini F., Di Monaco A., Vitulano N., Caruso R., Orfino R., Cecere G., Anselmino M., Grimaldi M. Zero Fluoroscopy Arrhythmias Catheter Ablation: A Trend Toward More Frequent Practice in a High-Volume Center. *Front Cardiovasc Med*. 2022;9:804424. <https://doi.org/10.3389/fcvm.2022.804424>
- [20] Goldberger A.L., Amaral L.A., Glass L., Hausdorff J.M., Ivanov P.C., Mark R.G., Mietus J.E., Moody G.B., Peng C.K., Stanley H.E. PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*. 2000;101(23):E215-20. <https://doi.org/10.1161/01.cir.101.23.e215>
- [21] Clifford G.D., et al. Classification of normal/abnormal heart sound recordings: The PhysioNet. Computing in Cardiology Challenge 2016. In: 2016 Computing in Cardiology Conference (CinC). Vancouver, BC, Canada: IEEE Press; 2016. p. 609-612.
- [22] Clifford G.D., Liu C., Moody B., Lehman L.H., Silva I., Li Q., Johnson A.E., Mark R.G. AF Classification from a Short Single Lead ECG Recording: the PhysioNet. Computing in Cardiology Challenge 2017. *Comput Cardiol (2010)*. 2017;44:10.22489/CinC.2017.065-469. <https://doi.org/10.22489/CinC.2017.065-469>
- [23] Venton J., Harris P.M., Sundar A., Smith N.A.S., Aston P.J. Robustness of convolutional neural networks to physiological electrocardiogram noise. *Philos Trans A Math Phys Eng Sci*. 2021;379(2212):20200262. <https://doi.org/10.1098/rsta.2020.0262>
- [24] Kalyakulina A.I., Yusipov I.I., Moskalenko V.A., et al. LUDB: A New Open-Access Validation Tool for Electrocardiogram Delineation Algorithms. *IEEE Access*. 2020;8:186181-186190. <https://doi.org/10.1109/ACCESS.2020.3029211>



- [25] Aljabri M., AlAmir M., AlGhamdi M., Abdel-Mottaleb M., Collado-Mesa F. Towards a better understanding of annotation tools for medical imaging: a survey. *Multimed Tools Appl.* 2022;81(18):25877-25911. <https://doi.org/10.1007/s11042-022-12100-1>
- [26] Krithika Alias AnbuDevi M., Suganthi K. Review of Semantic Segmentation of Medical Images Using Modified Architectures of UNET. *Diagnostics.* 2022;12(12):3064. <https://doi.org/10.3390/diagnostics12123064>
- [27] Qian S., Ning C., Hu Y. MobileNetV3 for Image Classification. In: 2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE). Nanchang, China: IEEE Press; 2021. p. 490-497. <https://doi.org/10.1109/ICBAIE52039.2021.9389905>
- [28] Koonce B. MobileNetV3. In: Convolutional Neural Networks with Swift for Tensorflow. Berkeley, CA: Apress; 2021. p. 125-144. https://doi.org/10.1007/978-1-4842-6168-2_11

Поступила 19.12.2025; одобрена после рецензирования 16.02.2026; принята к публикации 24.03.2026.

Submitted 19.12.2025; approved after reviewing 16.02.2026; accepted for publication 24.03.2026.

Об авторах:

Борисов Николай Анатольевич, доцент кафедры математического обеспечения и суперкомпьютерных технологий института информационных технологий, математики и механики, ФГАОУ ВО «Национальный исследовательский Нижегородский государственный университет им. Н.И. Лобачевского» (603022, Российская Федерация, Нижний Новгород, пр. Гагарина, д. 23), кандидат технических наук, **ORCID:** <https://orcid.org/0000-0003-3924-8591>, nborisov.itmm@yandex.ru

Карчков Денис Александрович, старший преподаватель кафедры математического обеспечения и суперкомпьютерных технологий института информационных технологий, математики и механики; младший научный сотрудник Научно-исследовательской лаборатории искусственного интеллекта и обработки больших массивов данных, ФГАОУ ВО «Национальный исследовательский Нижегородский государственный университет им. Н.И. Лобачевского» (603022, Российская Федерация, Нижний Новгород, пр. Гагарина, д. 23), **ORCID:** <https://orcid.org/0000-0002-4164-5927>, karchkov.denis@mail.ru

Кузенкова Галина Владимировна, доцент кафедры математического обеспечения и суперкомпьютерных технологий института информационных технологий, математики и механики, ФГАОУ ВО «Национальный исследовательский Нижегородский государственный университет им. Н.И. Лобачевского» (603022, Российская Федерация, Нижний Новгород, пр. Гагарина, д. 23), кандидат химических наук, **ORCID:** <https://orcid.org/0000-0003-4966-2200>, kuzenkovagv@mail.ru

Все авторы прочитали и одобрили окончательный вариант рукописи.

About the authors:

Nikolai A. Borisov, Associate Professor of the Chair of Mathematical Software and Supercomputing Technologies of the Institute of Information Technology, Mathematics and Mechanics, National Research Lobachevsky State University of Nizhny Novgorod (23 Prospekt Gagarina, building 2, Nizhny Novgorod 603022, Russian Federation Russian Federation), Cand. Sci. (Tech.), **ORCID:** <https://orcid.org/0000-0003-3924-8591>, nborisov.itmm@yandex.ru

Denis A. Karchkov, Senior Lecturer of the Chair of Mathematical Software and Supercomputing Technologies of the Institute of Information Technology, Mathematics and Mechanics; Junior Researcher of the Research Laboratory of Artificial Intelligence and Big Data Processing, National Research Lobachevsky State University of Nizhny Novgorod (23 Prospekt Gagarina, building 2, Nizhny Novgorod 603022, Russian Federation Russian Federation), **ORCID:** <https://orcid.org/0000-0002-4164-5927>, karchkov.denis@mail.ru

Galina V. Kuzenkova, Associate Professor of the Chair of Mathematical Software and Supercomputing Technologies of the Institute of Information Technology, Mathematics and Mechanics, National Research Lobachevsky State University of Nizhny Novgorod (23 Prospekt Gagarina, building 2, Nizhny Novgorod 603022, Russian Federation Russian Federation), Cand. Sc. (Chemistry), **ORCID:** <https://orcid.org/0000-0003-4966-2200>, kuzenkovagv@mail.ru

All authors have read and approved the final manuscript.

