

Аветисян Арам Арутюнович

**Методы и программные средства для выявления и
анализа патологий по электрокардиограммам**

Специальность 2.3.5 —
«Математическое и программное обеспечение вычислительных
систем, комплексов и компьютерных сетей»

Автореферат
диссертации на соискание ученой степени
кандидата технических наук

Работа выполнена в Федеральном государственном бюджетном учреждении науки Институте системного программирования им. В.П. Иванникова Российской Академии Наук.

Научный руководитель: кандидат технических наук
Маркин Юрий Витальевич

Официальные оппоненты: **Крылов Андрей Серджевич**,
доктор физико-математических наук, профессор,
профессор кафедры математической физики Фа-
культета вычислительной математики и киберне-
тики Федерального государственного бюджетно-
го образовательного учреждения высшего образо-
вания «Московский государственный университет
им.М.В.Ломоносова»,

Бухановский Александр Валерьевич,
доктор технических наук, профессор,
директор мегафакультета трансляционных инфор-
мационных технологий Федерального государствен-
ного автономного образовательного учреждения
высшего образования «Национальный исследова-
тельский университет ИТМО»,

Ведущая организация: Автономная некоммерческая организация высшего
образования «Университет Иннополис»

Защита состоится 17 декабря 2026 г. в 12-00 на заседании диссертационного
совета 24.1.120.01 при Федеральном государственном бюджетном учреждении
науки Институте системного программирования им. В.П. Иванникова Россий-
ской академии наук по адресу: 115035, г. Москва, ул. Садовническая, д. 41, ст.
2.

С диссертацией можно ознакомиться в библиотеке и на сайте Федерального го-
сударственного бюджетного учреждения науки Института системного програм-
мирования им. В.П. Иванникова Российской академии наук.

Автореферат разослан «_____» _____ 20__ г.

Ученый секретарь
диссертационного совета 24.1.120.01
кандидат физико-математических наук

Турдаков Денис Юрьевич

Общая характеристика работы

Актуальность темы исследования. Электрокардиография является одним из наиболее доступных, распространенных и клинически значимых методов функциональной диагностики сердечно-сосудистой системы. ЭКГ применяется при диагностике заболеваний, профилактических обследованиях, массовом скрининге и длительном мониторингировании состояния пациентов. Рост числа регистрируемых цифровых электрокардиограмм приводит к увеличению объема данных, требующих анализа специалистами, и повышает потребность в автоматизации их обработки и интерпретации. Автоматические методы анализа позволяют ускорить обработку больших объемов ЭКГ-исследований и могут использоваться для поддержки врача при выявлении электрокардиографических синдромов и патологических состояний.

Одной из основных проблем разработки методов автоматической интерпретации ЭКГ является отсутствие наборов данных, объем и разнообразие которых достаточны для обучения нейросетевых моделей и объективной оценки их качества на различных группах пациентов и диагностических состояниях. Для этого требуется большое число записей с согласованными экспертными заключениями, формирование которых требует участия квалифицированных специалистов и значительных временных затрат. В результате доступные наборы данных не всегда обеспечивают необходимое качество и разнообразие разметки.

При этом объём накопленных цифровых записей существенно превышает объем данных с качественными экспертными заключениями. Значительная часть таких записей не может непосредственно использоваться в традиционном обучении с учителем, несмотря на содержащуюся в них информацию о структуре и вариативности сигналов. Это делает актуальной задачу разработки методов, способных использовать неразмеченные данные на этапе предварительного обучения и тем самым снижать зависимость качества моделей от объема экспертной разметки.

Отдельной задачей автоматического анализа является определение временных границ основных морфологических элементов сигнала, необходимых для последующего вычисления интервалов и формирования дополнительных характеристик записи. Получение такой разметки является более трудоемкой задачей, чем присвоение диагностической метки всей записи, поскольку требует анализа отдельных фрагментов сигнала. Существующие выборки с разметкой границ, как правило, имеют ограниченный объём, а сама разметка может различаться между наборами данных и экспертами. Это ограничивает возможности обучения и объективной оценки моделей сегментации и повышает значимость методов, позволяющих использовать дополнительные данные без ручной поэлементной разметки.

Дополнительное ограничение возникает при использовании сокращенных конфигураций регистрации. Полная многоканальная запись содержит больше

информации о наблюдаемом процессе, однако в портативных и носимых устройствах часто доступно меньшее число каналов. Снижение размерности входного сигнала приводит к потере части информации и может ухудшать качество классификации. Поэтому актуальной является задача переноса знаний, полученных на более информативных многоканальных данных, на модели, работающие с уменьшенным числом доступных каналов.

Значительная часть клинических данных хранится распределенно в информационных системах отдельных организаций, а их передача и централизованное объединение могут быть ограничены требованиями к защите персональной информации и особенностями инфраструктуры. Вместе с тем совместное использование данных нескольких источников позволяет увеличить объем и разнообразие обучающей выборки. При распределенном обучении дополнительной проблемой становится неоднородность локальных данных и качества их разметки: систематические ошибки отдельных участников могут приводить к формированию некорректных клиентских обновлений и снижению качества общей модели.

Таким образом, актуальными проблемами являются ограниченность экспертно размеченных данных, большие трудозатраты детальной разметки, различия между источниками данных, снижение информативности при уменьшении числа доступных каналов и невозможность прямого объединения распределенных клинических выборок. Перспективными направлениями решения этих проблем являются использование неразмеченных данных при обучении моделей, перенос знаний между различными конфигурациями входного сигнала и федеративное обучение с оценкой качества клиентских обновлений. Разработка и исследование таких методов составляют актуальную задачу автоматического анализа медицинских временных рядов.

Степень разработанности темы исследования. В работах отечественных и зарубежных исследователей широко представлены методы автоматического анализа ЭКГ. Для выявления электрокардиографических синдромов активно применяются сверточные, рекуррентные и трансформерные архитектуры нейронных сетей, позволяющие извлекать необходимые для автоматического анализа признаки непосредственно из временных рядов ЭКГ. Для сегментации сигналов используются как классические алгоритмы обработки, так и современные нейросетевые подходы.

Одной из основных проблем при разработке нейросетевых методов анализа ЭКГ остается ограниченность объема данных с качественной экспертной разметкой, получение которой требует значительных временных затрат и участия квалифицированных специалистов. Для преодоления этого ограничения значительное развитие получили методы предварительного обучения на данных без экспертных диагностических меток, в частности методы контрастного обучения, в которых представления формируются за счет использования внутренней структуры данных и различных преобразований исходных объектов. Такие методы позволяют использовать большие массивы неразмеченных записей и уменьшать зависимость последующего обучения от объема размеченной выборки. Од-

новременно развиваются нейросетевые методы сегментации, однако их эффективность по-прежнему существенно зависит от объема и качества доступной экспертной разметки. Дополнительной проблемой является снижение информативности ЭКГ при уменьшении числа доступных каналов.

Другим существенным ограничением является распределенное хранение клинических данных в медицинских организациях, затрудняющее формирование единой обучающей выборки из-за ограничений на передачу исходных записей. Для ее решения активно исследуются методы федеративного обучения, позволяющие формировать общую модель без передачи исходных данных между участниками. Однако передача отдельными участниками некорректных обновлений модели может приводить к снижению качества федеративного обучения. Несмотря на развитие методов устойчивой агрегации, задача снижения влияния таких обновлений на качество общей модели остается актуальной.

Несмотря на большое число существующих работ, сохраняются задачи эффективного использования неразмеченных данных, повышения качества сегментации при ограниченной экспертной разметке, переноса знаний при уменьшении числа доступных каналов и устойчивого обучения на распределенных данных с неоднородным качеством разметки.

Объект исследования — методы автоматического анализа медицинских временных рядов на примере цифровых электрокардиографических сигналов.

Предмет исследования — методы и алгоритмы обучения нейросетевых моделей классификации и сегментации медицинских временных рядов в условиях ограниченного объема размеченных данных, изменения числа доступных каналов входного сигнала и распределенного хранения обучающих выборок.

Целью диссертационной работы является разработка и реализация методов и программных средств автоматического анализа медицинских временных рядов на примере анализа цифровых электрокардиограмм.

Для достижения поставленной цели необходимо было решить следующие **задачи**:

1. Проанализировать актуальные задачи автоматического анализа цифровых электрокардиограмм, рассмотреть существующие методы их решения и выявить ограничения этих методов.
2. Провести сравнительное исследование нейросетевых моделей классификации патологических состояний по цифровым электрокардиограммам и выполнить обучение выбранной модели на клинических данных.
3. Разработать и реализовать метод сегментации цифровых ЭКГ с определением границ основных морфологических элементов в условиях ограниченного объема экспертно размеченных записей.
4. Разработать и реализовать метод контрастного предобучения нейросетевых моделей классификации, учитывающий метаданные пациентов при формировании признаков представлений.

5. Разработать и реализовать метод переноса знаний, полученных при предобучении на многоканальных данных, для повышения качества классификации при уменьшении числа доступных каналов входного сигнала.
6. Разработать и реализовать алгоритм федеративного обучения нейросетевых моделей классификации, основанный на оценивании полезности клиентских обновлений для идентификации аномальных обновлений и их учета при агрегации параметров модели.

Основные положения, выносимые на защиту:

1. Метод сегментации цифровых электрокардиографических сигналов с определением границ основных морфологических элементов, позволяющий повышать качество сегментации в условиях ограниченного объема экспертной разметки за счет использования автоматически сформированной псевдоразметки дополнительных записей.
2. Методы контрастного предобучения нейросетевых моделей, позволяющие повышать качество классификации за счет использования дополнительной информации о структуре данных: индивидуальных характеристик объектов при формировании признаков представлений и зависимостей между различными каналами одного сигнала при переносе знаний на задачу с уменьшенным числом доступных каналов.
3. Метод федеративного обучения нейросетевых моделей классификации, основанный на оценивании полезности клиентских обновлений, позволяющий выявлять и снижать влияние аномальных обновлений при агрегации параметров глобальной модели.

Перечисленные положения относятся к направлениям исследований 4, 8 и 9 паспорта специальности 2.3.5 «Математическое и программное обеспечение вычислительных систем, комплексов и компьютерных сетей»:

- п. 4 «Интеллектуальные системы машинного обучения, управления базами данных и знаний, инструментальные средства разработки цифровых продуктов»;
- п. 8 «Модели и методы создания программ и программных систем для параллельной и распределенной обработки данных, языки и инструментальные средства параллельного программирования»;
- п. 9 «Модели, методы, алгоритмы, облачные технологии и программная инфраструктура организации глобально распределенной обработки данных».

Научная новизна:

1. Разработаны архитектура и метод сегментации цифровых ЭКГ, позволяющие использовать автоматически сформированную псевдоразметку дополнительных записей для повышения качества определения границ основных морфологических элементов при ограниченном объеме экспертно размеченных данных.

2. Разработан метод контрастного предобучения нейросетевых моделей классификации, основанный на использовании индивидуальных характеристик пациента при формировании признаков представлений.
3. Разработан метод переноса знаний, полученных при контрастном предобучении на многоканальных сигналах, на задачу классификации при уменьшенном числе доступных каналов.
4. Разработан алгоритм федеративного обучения нейросетевых моделей, позволяющий ограничивать влияние аномальных клиентских обновлений при формировании глобальной модели за счет их идентификации на основе оценки полезности.

Теоретическая значимость работы заключается в развитии методов анализа биомедицинских временных рядов в условиях ограниченного объема размеченных данных, изменения конфигурации входного сигнала и распределённого хранения обучающих выборок. В диссертации развиваются подходы к контрастному предобучению с использованием дополнительной информации об объектах, подходы с использованием автоматически сформированной псевдоразметки дополнительных записей и методы переноса знаний между моделями, работающими с различным числом каналов. Полученные результаты также развивают методы федеративного обучения за счет оценивания полезности клиентских обновлений для идентификации аномальных обновлений и использования полученных оценок при агрегации параметров глобальной модели.

Практическая значимость работы определяется возможностью применения разработанных методов и нейросетевых моделей в системах автоматического анализа цифровых электрокардиограмм и поддержки принятия врачебных решений. Разработанные подходы позволяют:

1. Выполнять автоматическую классификацию патологических состояний по многоканальным цифровым сигналам;
2. Автоматически определять границы основных морфологических элементов сигнала для последующего расчета интервалов и интерпретации записи;
3. Использовать наборы данных без диагностических заключений для предварительного обучения нейросетевых моделей и повышения качества классификации электрокардиографических синдромов;
4. Выполнять перенос знаний, полученных при обучении на многоканальных данных, для повышения качества классификации при уменьшенном числе доступных каналов;
5. Оценивать полезность клиентских обновлений для идентификации аномальных обновлений и учитывать полученные оценки при федеративном обучении нейросетевых моделей классификации электрокардиографических синдромов.

Результаты диссертационного исследования использованы при разработке программного обеспечения для автоматического анализа электрокардиограмм «Диагностическое ПО для нейросетевой классификации ЭКГ ИСП РАН». На

указанное медицинское изделие Федеральной службой по надзору в сфере здравоохранения выдано регистрационное удостоверение от 28 декабря 2024 года № РЗН 2024/24366.

Апробация работы. Основные результаты диссертации были изложены на следующих конференциях:

1. Открытая конференция ИСП РАН, 2021;
2. Открытая конференция ИСП РАН, 2023;
3. XXXI Российский национальный конгресс «Человек и лекарство», 2024;
4. 2024 IEEE 48th Annual Computers, Software, and Applications Conference (COMPSAC 2024);
5. Digital Innopolis Days x AI IN 2024;
6. 2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2025);
7. AAAI Conference on Artificial Intelligence (AAAI 2026);

Личный вклад. Все представленные в рамках диссертационной работы результаты получены лично автором.

Публикации. По теме диссертации опубликовано 8 работ, в том числе 4 статьи – в рецензируемых журналах из перечня рекомендованных ВАК РФ. Также получено 2 свидетельства о государственной регистрации программы для ЭВМ. В публикациях [1,3,4,7] автором сформулированы постановка задачи и методика её решения, разработан план проведения экспериментов, принято участие в реализации программного кода, выполнены экспериментальные исследования, анализ и интерпретация полученных результатов, а также подготовка текста публикаций. В публикациях [2,5] автор совместно с соавторами участвовал в постановке задачи, проведении экспериментальных исследований, проверке и валидации результатов, а также в подготовке материалов к публикации. В публикациях [6,8] совместно с соавторами сформулирована постановка задачи, разработан план экспериментов, выполнены проверка и валидация полученных результатов и подготовка текста публикации.

Содержание работы

Во введении обосновывается актуальность исследования методов автоматизированного анализа электрокардиограмм, характеризуется степень разработанности темы, определяются объект и предмет исследования, формулируются цель и задачи диссертационной работы, излагаются положения, выносимые на защиту, раскрываются научная новизна, теоретическая и практическая значимость полученных результатов, а также приводятся сведения об апробации, личном вкладе и публикациях по теме работы.

В первой главе выполняется обзор методов автоматизированного анализа электрокардиограмм и формулируются основные проблемы, определяющие постановку задач диссертационной работы. Рассматриваются особенности ЭКГ как многоканального временного сигнала, методы классификации патологических состояний и сегментации морфологических элементов, подходы к обучению на неразмеченных данных, а также методы федеративного обучения.

Стандартная электрокардиограмма включает 12 отведений, которые регистрируют электрическую активность сердца в различных направлениях и содержат взаимодополняющую информацию. Основные элементы сердечного цикла показаны на рисунке 1.

Наряду с 12-канальной записью широко используются сокращённые конфигурации, включая одноканальные ЭКГ, характерные для носимых устройств. Уменьшение числа отведений упрощает регистрацию, однако приводит к потере части информации, доступной при многоканальной записи.




Рисунок 1 — Элементы кардиоцикла

К числу основных задач автоматизированного анализа ЭКГ относятся классификация патологических состояний и сегментация характерных элементов сердечного цикла. В задаче классификации модель по всей записи определяет наличие одного или нескольких диагностических состояний. Современные подходы основаны преимущественно на глубоких нейронных сетях, включая одномерные свёрточные архитектуры, трансформеры и крупные предварительно обученные модели. При этом результаты существенно зависят не только от архитектуры, но и от объёма, происхождения и распределения обучающих данных. Модель, демонстрирующая высокое качество на одном наборе ЭКГ, может заметно снижать результаты при переносе на данные другого медицинского центра или другого оборудования. Поэтому одной из рассматриваемых далее задач является оценка влияния источника и объёма обучающих данных на качество классификации.

Вторая базовая задача состоит в сегментации записи — определении временных границ характерных элементов одного сердечного цикла: зубца *P*, ком-

плекса QRS и зубца T . Эти элементы соответствуют последовательным участкам формы ЭКГ-сигнала и используются при вычислении временных и морфологических характеристик записи. В отличие от диагностической классификации, для которой метки могут быть извлечены из медицинских заключений, сегментация требует отдельной врачебной разметки каждого цикла. Вследствие этого объём выборок с точной разметкой границ существенно меньше объёма накопленных клинических ЭКГ, что ограничивает обучение нейросетевых моделей и обуславливает целесообразность использования неразмеченных данных.

В работе используются как открытые, так и клинические наборы данных. Для классификации применяются PTB-XL, содержащий 21 799 12-канальных ЭКГ, и клинический архив ISP, включающий более 1,5 млн 12-канальных записей. Для сегментации используются LUDB и ISPdeli с экспертной разметкой границ P , QRS и T . Существенные различия в объёмах и типах разметки указанных наборов позволяют исследовать как перенос моделей между различными источниками данных, так и использование неразмеченных записей для повышения качества сегментации.

Одним из способов использования больших неаннотированных массивов данных является самообучение. В таких методах обучающий сигнал формируется непосредственно из данных без привлечения диагностических меток. Особое внимание в работе уделяется контрастному обучению, при котором модель должна сближать представления связанных объектов и разводить представления независимых записей. Качество такого обучения во многом определяется способом формирования положительных пар. В стандартных подходах в качестве положительных пар используются различные аугментированные варианты одной записи; однако для медицинских данных дополнительную информацию могут давать метаданные пациентов и внутренняя структура многоканальной ЭКГ. Это позволяет использовать близость различных записей по доступным метаданным, а также различные комбинации отведений одной ЭКГ в качестве дополнительных связей при обучении представлений.

Отдельная группа проблем связана с распределённым хранением медицинских данных. ЭКГ различных клиник не всегда могут быть объединены в едином центре, что ограничивает применение традиционного централизованного обучения. В такой постановке совместное обучение может быть организовано посредством федеративного обучения. Федеративное обучение позволяет формировать общую модель без передачи исходных записей между медицинскими организациями. При этом локальные выборки различных клиник могут существенно различаться по составу пациентов, частоте патологий и качеству разметки, вследствие чего клиентские обновления становятся неоднородными.

Для устойчивого федеративного обучения важно учитывать некорректные клиентские обновления. В классических работах часто рассматриваются так называемые византийские клиенты, способные передавать произвольные или целенаправленно искажённые обновления. В рассматриваемой медицинской постановке вредоносное обновление может возникать и без целенаправленной атаки —

например, вследствие систематических ошибок разметки или различий локальных правил кодирования. Такие обновления не обязательно являются выраженными геометрическими выбросами, поэтому методы, ориентированные только на взаимное расположение клиентских векторов, могут оказаться недостаточно эффективными. Альтернативой является оценка функциональной полезности обновлений на небольшой доверенной серверной выборке.

В выводах первой главы формулируются направления исследований и перечисляются темы глав диссертации.

Во второй главе рассматриваются методы автоматического анализа многоканальных ЭКГ применительно к двум задачам — классификации электрокардиографических синдромов и сегментации характерных элементов сигнала. В рамках задачи классификации проводится сравнение современных предварительно обученных моделей и специализированных нейросетевых архитектур, исследуется влияние объёма обучающей выборки и оценивается адаптация к новому источнику данных. Для задачи сегментации предлагается модель ECG-CODE и способ её дополнительного обучения с использованием автоматически сформированной псевдоразметки большого массива ЭКГ. Разработка метода сегментации соответствует первому пункту научной новизны и раскрывает первое положение, выносимое на защиту.

На первом этапе исследовалась задача классификации патологических состояний по 12-канальным ЭКГ. Цель экспериментов состояла в сравнении современных моделей, предварительно обученных на больших массивах электрокардиографических данных, с компактными специализированными архитектурами, обучаемыми непосредственно на целевой задаче. Такое сравнение позволяет определить, обеспечивает ли крупномасштабное предварительное обучение само по себе преимущество при решении прикладной диагностической задачи.

В качестве основных источников данных использовались открытый набор PTB-XL и клинический набор ISP. В основных экспериментах на ISP использовались 900 000 записей для обучения и 100 000 для тестирования; разделение выполнялось по пациентам.

Рассматривались четыре патологии сердца: фибрилляция предсердий (AFIB), полная блокада левой ножки пучка Гиса (CLBBB), атриовентрикулярная блокада первой степени (1AVB) и желудочковая экстрасистолия (PVC). Они различаются характером диагностически значимых признаков и позволяют оценить работу моделей как на нарушениях ритма, так и на изменениях морфологии и временных интервалов ЭКГ.

Сравнение включало два класса подходов. Предварительно обученные модели ECGFounder, ECG-JERA, ST-MEM и HuBERT-ECG используют представления, сформированные на больших массивах ЭКГ в ходе предварительного обучения. В качестве альтернативы рассматривались одномерные свёрточные архитектуры resnet1d50 и densenet1d121, обучаемые непосредственно на целевой выборке. Такое сравнение позволяет оценить, даёт ли масштаб предварительного обучения преимущество перед специализированной моделью при

одинаковой прикладной задаче. В качестве основной интегральной метрики использовалось геометрическое среднее чувствительности и специфичности

$$G\text{-mean} = \sqrt{Se \cdot Sp}. \quad (1)$$

Результаты сравнения нейросетевых моделей на тестовых данных ISP приведены в таблице 1.

Таблица 1 — Сравнение нейросетевых моделей на тестовой части набора данных ISP по метрике $G\text{-mean}$

Модель	AFIB	CLBBB	1AVB	PVC
resnet1d50	0.930	0.950	0.869	0.898
densenet1d121	0.984	0.970	0.928	0.959
ECGFounder	0.974	0.943	0.887	0.830
ECG-JEPA	0.960	0.971	0.863	0.864
ST-MEM	0.976	0.964	0.909	0.921
HuBERT-ECG	0.917	0.967	0.679	0.883

Наиболее устойчивые результаты среди рассмотренных моделей продемонстрировала densenet1d121: она обеспечила наибольший $G\text{-mean}$ для AFIB, 1AVB и PVC и была близка к лучшему результату для CLBBB. Особенно заметные различия между архитектурами наблюдались для 1AVB, где $G\text{-mean}$ изменялся от 0.679 для HuBERT-ECG до 0.928 для densenet1d121. Полученные результаты показывают, что предварительное обучение на больших массивах ЭКГ само по себе не гарантирует более высокого качества при решении конкретной клинической задачи. С учётом этого densenet1d121 была выбрана в качестве базовой архитектуры для дальнейших экспериментов.

Следующая серия экспериментов была направлена на анализ влияния объёма обучающих данных. Модель densenet1d121 обучалась на 10, 25, 50 и 100% обучающей выборки ISP. При тестировании на ISP увеличение объёма данных приводило к сравнительно небольшому приросту качества: для AFIB $G\text{-mean}$ изменялся с 0.984 при использовании 10% выборки до 0.988 при использовании полного набора, для CLBBB — с 0.970 до 0.975, а для 1AVB — с 0.928 до 0.938.

Более выраженное влияние объёма обучающих данных наблюдалось при проверке моделей на независимом наборе PTB-XL. Для CLBBB $G\text{-mean}$ увеличился с 0.938 при использовании 10% ISP до 0.984 при использовании полного обучающего набора, а для PVC — с 0.948 до 0.981. Таким образом, увеличение объёма и разнообразия клинических данных оказывается особенно существенным для устойчивости модели при переходе к другому источнику ЭКГ, тогда как внутри одного набора высокое качество достигается значительно быстрее.

Далее исследовалась возможность дополнительной адаптации модели к целевому набору данных. Для этого сравнивались модель, обученная только на PTB-XL; модель, предварительно обученная на ISP без последующей адаптации;

а также варианты, предварительно обученные на половине или полном объёме ISP и затем дообученные на PTB-XL.

Таблица 2 — Влияние дообучения на качество классификации на целевом наборе PTB-XL по метрике G -mean

Модель	AFIB	CLBBB	1AVB	PVC
PTBXL	0.946	0.973	0.889	0.949
ISP_full	0.953	0.984	0.909	0.981
ISP_half_tuned_dn	0.959	0.982	0.920	0.989
ISP_full_tuned_dn	0.960	0.984	0.946	0.989

Результаты эксперимента с дообучением нейросетевых моделей представлены в таблице 2. Дообучение на целевом наборе обеспечивало дополнительное повышение качества. Наиболее выраженный эффект наблюдался для 1AVB: G -mean увеличился с 0.889 при обучении только на PTB-XL и с 0.909 для модели, обученной на ISP без адаптации, до 0.946 после предварительного обучения на полном ISP и последующего дообучения на PTB-XL. Для остальных патологий прирост был менее выраженным, поскольку исходные значения уже находились на высоком уровне. При этом различие между моделями, предварительно обученными на половине и полном объёме ISP, после дообучения было значительно меньше, чем между вариантами без адаптации. Это свидетельствует о том, что для переноса на новый источник существенное значение имеют не только объём исходной выборки, но и последующая адаптация модели к целевому источнику данных.

Таким образом, в первой части главы показано, что эффективность классификации определяется сочетанием архитектуры, объёма и разнообразия исходных данных, а также последующей адаптации к целевой выборке. Специализированная свёрточная модель может демонстрировать качество, сопоставимое с крупными предварительно обученными моделями или превосходящее их, а использование большого клинического массива совместно с дообучением позволяет повысить качество на новом источнике данных.

Вторая часть главы посвящена автоматической сегментации ЭКГ, а именно определению временных границ зубцов P , комплекса QRS и зубца T . Для каждого сердечного цикла определяются шесть характерных точек:

$$P_{\text{on}}, P_{\text{off}}, QRS_{\text{on}}, QRS_{\text{off}}, T_{\text{on}}, T_{\text{off}}.$$

Для обучения и оценки использовались два набора с экспертной разметкой — LUDB и ISPdeli, содержащие соответственно 200 и 475 12-канальных записей с разметкой основных морфологических элементов. Существенно больший по объёму PTB-XL далее использовался как источник ЭКГ без необходимой для задачи сегментации ручной разметки.

Для решения задачи предложена свёрточная нейросетевая модель ECG-CODE (*ECG COmplex DElineation*). На вход модели подаются 12 отведений ЭКГ,

предварительно преобразованные в спектральное представление. Основу архитектуры составляют блоки MobileNet, обеспечивающие последовательное преобразование признаков. Архитектура ECG-CODE представлена на рисунке 2.




Рисунок 2 — Архитектура модели ECG-CODE

Для каждого временного интервала ECG-CODE формирует оценку наличия одного из рассматриваемых морфологических элементов и, если элемент присутствует, оценивает относительные координаты его начала и конца. В связи с этим обучение объединяет две подзадачи: определение наличия элемента и локализацию его границ. Для них используются соответственно компоненты *confidence loss* (CL) и *start-end loss* (SEL):

$$CL = (P_C - T_C)^2, \quad (2)$$

$$SS = (P_S - T_S)^2 + (P_E - T_E)^2, \quad (3)$$

$$SEL = \begin{cases} 0, & SS < \text{accepted_error}, \\ SS \cdot T_C, & SS \geq \text{accepted_error}, \end{cases} \quad (4)$$

где T_C и P_C — истинное и предсказанное значения наличия объекта, а T_S , P_S , T_E и P_E — истинные и предсказанные координаты его начала и конца. Итоговая функция потерь вычисляется как сумма CL и SEL .

Эксперимент по обучению ECG-CODE на LUDB и ISPdeli показал, что наиболее чувствительными к смене источника разметки оказываются границы зубцов P и T . При обучении на LUDB и тестировании на ISPdeli F_1 -мера составляла 0.932 и 0.936 для начала и конца P и 0.963 и 0.919 для начала и конца T . В то же время границы комплекса QRS оставались значительно более устойчивыми, сохраняя F_1 на уровне 0.996–0.997.

Для использования больших объёмов ЭКГ без ручной разметки предложена схема self-training. На первом этапе ECG-CODE, обученная на экспертно

размеченных данных, применялась для автоматической разметки записей РТВ-XL. Для каждой записи сохранялись предсказанные типы волн, координаты их границ и оценка уверенности. Качество псевдометки оценивалось по критерию

$$\text{delineation score} = |0.5 - \text{predicted confidence}|. \quad (5)$$

Для каждого типа объекта (P , QRS и T) записи ранжировались отдельно, после чего для дальнейшего обучения отбирались верхние 50% записей по соответствующей оценке уверенности. Модель сначала обучалась на сформированной псевдоразмеченной выборке, а затем дообучалась на экспертно-размеченном ISPdeli. Полученная модель обозначена как Pseudolabeled ECG-CODE.

Эффективность подхода оценивалась на независимой тестовой части ISPdeli. Результаты приведены в таблице 3.

Таблица 3 — Влияние self-training на качество сегментации на тестовой части ISPdeli

Модель	P_{on}	P_{off}	QRS_{on}	QRS_{off}	T_{on}	T_{off}
ECG-CODE	0.969	0.971	0.997	0.997	0.983	0.980
Pseudolabeled ECG-CODE	0.975	0.976	0.999	0.999	0.987	0.986

Использование псевдоразмеченных данных повысило F_1 -меру для всех шести характерных точек. Наиболее заметный эффект наблюдался для границ зубцов P и T . Для Pseudolabeled ECG-CODE итоговые значения F_1 находились в диапазоне 0.975–0.999 и были сопоставимы с результатами рассмотренных современных методов сегментации или превосходили их.

Во второй главе показано, что для классификации многоканальных ЭКГ специализированная densenet1d121 не уступает крупным предварительно обученным моделям на рассматриваемых задачах, а увеличение объёма клинических данных и последующее дообучение на целевой выборке повышают качество переноса на новый источник. Для задачи сегментации разработана ECG-CODE; использование self-training с псевдоразметкой дополнительных записей повысило точность определения всех рассматриваемых границ.

В третьей главе рассматривается применение самообучения для извлечения информативных представлений ЭКГ из неразмеченных данных. Основное внимание уделяется контрастному обучению и способам формирования положительных пар. Исследуются два подхода: использование метаданных пациента для задания дополнительных положительных связей между записями и использование различных комбинаций отведений одной ЭКГ для переноса информации с 12-канальных сигналов на 1-канальные. Эти методы соответствуют второму и третьему пунктам научной новизны и раскрывают второе положение, выносимое на защиту.

В стандартной постановке контрастного обучения для записи x_i формируется аугментированная версия $\tilde{x}_i$, после чего энкодер обучается сближать их

представления и разделять представления различных записей. В качестве базовых методов в работе используются SimCLR и TS-TCC. Для SimCLR для положительной пары z_i и $\tilde{z}_i$ используется функция потерь NT-Xent

$$\ell(z_i, \tilde{z}_i) = -\log \frac{\exp(\text{sim}(z_i, \tilde{z}_i)/\tau)}{\sum_{k=1}^{2N} \mathbb{I}[k \neq i] \exp(\text{sim}(z_i, z_k)/\tau)}, \quad (6)$$

где $\text{sim}(\cdot, \cdot)$ — косинусное сходство, а τ — температурный параметр. Стандартная компонента определяется как

$$L_{aug} = \frac{1}{2N} \sum_{i=1}^N (\ell(z_i, \tilde{z}_i) + \ell(\tilde{z}_i, z_i)). \quad (7)$$

В стандартном контрастном обучении положительными считаются различные представления одного объекта. В работе предлагается дополнительно использовать доступные метаданные пациента для определения содержательно близких записей ЭКГ.

Для числового признака P_j множество допустимых положительных примеров для записи x_i определяется как

$$\mathcal{P}_j(i) = \{k \neq i : |P_j(x_i) - P_j(x_k)| \leq \text{diff}_j\}. \quad (8)$$

В экспериментах в качестве метаданных использовался возраст пациента; по результатам предварительных экспериментов допустимая разница была выбрана равной двум годам. Для каждой исходной записи выбирался один дополнительный положительный пример из соответствующей группы.

Для таких пар вводится group-based компонента

$$L_{group_j} = -\frac{1}{N} \sum_{i=1}^N \log \frac{\exp(\text{sim}(z_i, z_i^{P_j})/\tau)}{\sum_{k=1}^{2N} \mathbb{I}[k \neq i] \exp(\text{sim}(z_i, z_k)/\tau)}. \quad (9)$$

При этом L_{aug} и L_{group_j} являются отдельными контрастными слагаемыми: для каждого из них используются собственные $2N$ представлений, поэтому нормирующая сумма содержит $2N$, а не $3N$ элементов. Итоговая функция потерь определяется как

$$L = \alpha L_{aug} + (1 - \alpha) \sum_{j=1}^M L_{group_j}. \quad (10)$$

В экспериментах использовался один признак группировки ($M = 1$), а коэффициент α был выбран равным $1/2$. Для TS-TCC group-based составляющая добавлялась к исходной функции потерь метода без изменения его внутренней временной и контекстной контрастной постановки.

Способ формирования батча является важной частью group-based подхода. Для каждого исходного объекта формируется кортеж из трёх связанных записей: самого объекта, его аугментированной версии и одного дополнительного положительного примера из той же метаданной группы. При вычислении отдельных контрастных компонент используются соответствующие пары представлений из этих кортежей. Другие записи, удовлетворяющие условию группировки относительно уже выбранного объекта, не добавляются в батч как независимые элементы, если они не являются назначенными положительными примерами. Это предотвращает ситуацию, когда физиологически близкие объекты одновременно используются как положительные в одной компоненте функции потерь и как отрицательные в другой, то есть уменьшает число ложноотрицательных пар.

Для оценки метода использовался энкодер `densenet1d121`. Предобучение проводилось на 12-канальных ЭКГ ISP без использования диагностических меток, после чего модель дообучалась на PTB-XL. Было проведено сравнение методов SimCLR и TS-TCC с их модификациями SimCLR-GB и TS-TCC-GB с предложенной group-based компонентой. Кроме того, результаты моделей сравнивались с моделью, обученной только с учителем. Результаты эксперимента представлены в таблице 4.

Таблица 4 — Результаты классификации 12-канальных ЭКГ после различных вариантов контрастного предобучения, G -mean

Метод	AFIB	1AVB	PVC
Supervised	0.946	0.889	0.949
SimCLR	0.939	0.892	0.958
SimCLR-GB (Age)	0.941	0.909	0.966
TS-TCC	0.945	0.897	0.971
TS-TCC-GB (Age)	0.951	0.911	0.977

Добавление группировки по возрасту улучшало соответствующий базовый self-supervised метод для всех трёх патологий. Для 1AVB G -mean увеличивался с 0.892 до 0.909 для SimCLR и с 0.897 до 0.911 для TS-TCC; для PVC — с 0.958 до 0.966 и с 0.971 до 0.977 соответственно. Для AFIB эффект был менее выраженным. Таким образом, метаданные, не являющиеся диагностической разметкой, могут использоваться как дополнительный обучающий сигнал на этапе предобучения.

Следующая часть главы посвящена переносу представлений с полной 12-канальной ЭКГ на одноканальный сигнал. Такая задача важна для носимых и портативных устройств, поскольку сокращение числа отведений приводит к потере части диагностической информации, а объём размеченных одноканальных данных ограничен.

Для переноса информации между отведениями предложен метод **LC-CL** (*Lead Combinations with Contrastive Learning*). Основной энкодер обрабатывает

отведение I, которое будет доступно и при последующем применении модели, а вспомогательные энкодеры получают другие комбинации отведений той же ЭКГ.

Функция потерь включает три типа компонент. Для первого отведения используется

$$L_{main} = L_{NTXent} \left(h_l^{(k_1)}, h_m^{(k_1)} \right), \quad (11)$$

а для вспомогательных комбинаций

$$L_{helper}^i = L_{NTXent} \left(h_l^{(k_i)}, h_m^{(k_i)} \right), \quad i = 2, \dots, n. \quad (12)$$

Перенос информации между различными конфигурациями обеспечивает entity loss

$$L_{entity}^j = L_{NTXent} \left(h_l^{(k_1)}, h_m^{(k_j)} \right), \quad j = 2, \dots, n, \quad (13)$$

который сближает представление первого отведения с представлениями других отведений той же записи.

Полная функция потерь задаётся как

$$L = \lambda_1 L_{main} + \sum_{i=2}^n \lambda_i L_{helper}^i + \sum_{j=2}^n \eta_j L_{entity}^j, \quad (14)$$

причём в экспериментах использовались одинаковые коэффициенты

$$\lambda_i = \eta_j = 0.33.$$

Исследовались две конфигурации. В варианте **1vs7** основной энкодер получает отведение I, а вспомогательный — совокупность отведения II и грудных отведений V_1 – V_6 . В конфигурации **1vs1vs6** используются два вспомогательных энкодера: отдельно для отведения II и для группы V_1 – V_6 . После предобучения вспомогательные энкодеры удаляются, и дальнейшая классификация выполняется только по отведению I.

Экспериментальная проверка LC-CL проводилась в два этапа. Для предобучения использовались многоканальные ЭКГ ISP, а последующее дообучение выполнялось по первому отведению РТВ-XL. Дополнительно обобщающая способность проверялась на независимом наборе WatchECG, содержащем 1000 одноканальных ЭКГ с носимых часов от 1000 пациентов. Этот набор использовался только для итогового тестирования и не участвовал в предобучении, дообучении или подборе гиперпараметров.

Чтобы количественно оценить потерю информации при сокращении числа входных отведений, в сравнение были включены две supervised-модели одной постановки: использующая полную 12-канальную запись и работающая только с первым отведением. Во втором случае G -mean был ниже: для AFIB — 0.900 против 0.946, для 1AVB — 0.843 против 0.889, для PVC — 0.874 против 0.949 и

для CLBBB — 0.949 против 0.973. Эти значения используются как ориентир для оценки эффекта предобучения.

Результаты сравнения supervised-обучения, SimCLR, TS-TCC и LC-CL на первом отведении РТВ-XL представлены в таблице 5.

Таблица 5 — Классификация по первому отведению РТВ-XL после различных вариантов предобучения, G -mean

Модель	AFIB	CLBBB	1AVB	PVC
Supervised, 12 отведений	0.946	0.973	0.889	0.949
Supervised, lead I	0.900	0.949	0.843	0.874
SimCLR	0.937	0.967	0.872	0.937
TS-TCC	0.956	0.965	0.880	0.970
LC-CL (1vs7)	0.935	0.979	0.862	0.947
LC-CL (1vs1vs6)	0.940	0.976	0.890	0.945

Использование LC-CL повышало качество относительно supervised-модели с одним отведением для всех четырёх патологий. В зависимости от конфигурации G -mean достигал 0.935–0.940 для AFIB, 0.976–0.979 для CLBBB, 0.862–0.890 для 1AVB и 0.945–0.947 для PVC. Наиболее заметный прирост относительно одноканальной supervised-модели составлял до 7.3 процентного пункта. Тем самым дополнительный контрастный сигнал от других отведений позволяет перенести часть информации многоканальной записи в энкодер, который после предобучения работает только с одним отведением.

Результаты сравнения supervised-обучения, SimCLR, TS-TCC и LC-CL на данных WatchECG представлены в таблице 6.

Таблица 6 — Результаты сравнения методов на 1-канальных ЭКГ WatchECG, G -mean

Модель	AFIB	CLBBB	1AVB	PVC
Supervised	0.927	0.918	0.786	0.850
SimCLR	0.930	0.922	0.809	0.849
TS-TCC	0.940	0.927	0.791	0.859
LC-CL (1vs7)	0.944	0.939	0.825	0.866
LC-CL (1vs1vs6)	0.949	0.948	0.798	0.878

На WatchECG одна из конфигураций LC-CL обеспечивала максимальный G -mean для каждой из четырёх патологий. По сравнению с supervised-моделью значение увеличивалось с 0.927 до 0.949 для AFIB, с 0.918 до 0.948 для CLBBB, с 0.786 до 0.825 для 1AVB и с 0.850 до 0.878 для PVC. Сохранение эффекта на независимых одноканальных записях с носимых часов показывает, что перенос межотведённой информации не ограничивается случаем, когда первое отведение искусственно выделяется из исходной 12-канальной ЭКГ.

Таким образом, в третьей главе предложены два способа использования дополнительной структуры неразмеченных данных при контрастном обучении. Group-based подход использует метаданные пациента для формирования дополнительных положительных пар, а LC-CL переносит информацию между конфигурациями сигнала с различным числом отведений.

В четвёртой главе рассматривается совместное обучение моделей анализа ЭКГ в условиях распределённого хранения клинических данных. Исследование выполнено в двух направлениях. В первой части реализуется и экспериментально проверяется система федеративного обучения, при которой исходные ЭКГ остаются внутри медицинских организаций. Во второй части анализируется устойчивость федерации к систематическим ошибкам локальной разметки и предлагается метод BANT, использующий доверенную серверную выборку для оценки полезности клиентских обновлений. Предложенный метод соответствует четвёртому пункту научной новизны и раскрывает третье положение, выносимое на защиту.

Для экспериментальной проверки федеративного обучения разработана система на основе фреймворка Flower. Центральный узел выполняет оркестрацию процесса и агрегацию клиентских обновлений, тогда как на стороне каждой медицинской организации запускается локальный компонент, осуществляющий обучение на собственных данных. Между участниками передаются только параметры модели и служебная информация; исходные ЭКГ остаются внутри инфраструктуры клиники.

Архитектура системы разделена на инфраструктурный и прикладной уровни и использует компоненты Flower *SuperLink*, *SuperNode*, *ServerApp* и *ClientApp*. Такое разделение позволяет независимо изменять как задачу анализа ЭКГ, так и стратегию федеративной агрегации. Взаимодействие между узлами защищено с помощью TLS, а подключение клиентов контролируется посредством аутентификации по индивидуальным парам ключей. Работоспособность системы проверялась как в режиме симуляции, так и на физически разнесённых вычислительных узлах.

Экспериментальная оценка проводилась на подкорпусе ISP, содержащем 144 650 размеченных ЭКГ. Клиенты формировались по реальному идентификатору медицинской организации, поэтому каждый участник соответствовал отдельному источнику данных. Рассматривались конфигурации с 1, 10, 25 и 50 клиентами. Решалась многометочная (multi-label) задача классификации 1AVB, PVC, AFIB и CLBBB; в качестве базовой модели использовалась ResNet1d18, а клиентские параметры агрегировались стандартным методом взвешенного усреднения FedAvg.

Для оценки эффекта совместного обучения качество федеративной модели сравнивалось с локальной моделью одного клиента и с централизованным обучением на объединённых данных 50 участников. Результаты сравнения представлены в таблице 7.

Таблица 7 — Качество классификации ЭКГ при увеличении числа клиентов в федеративном обучении (G -mean)

Режим обучения	1AVB	PVC	AFIB	CLBBB
1 клиент	0.482	0.547	0.779	0.879
10 клиентов	0.861	0.902	0.941	0.947
25 клиентов	0.889	0.907	0.947	0.961
50 клиентов	0.891	0.903	0.961	0.962
Централизованное обучение на данных 50 клиентов	0.896	0.934	0.958	0.966

Увеличение числа участников существенно повышало качество по сравнению с локальным обучением. При 50 клиентах значения G -mean достигали 0.891 для 1AVB, 0.903 для PVC, 0.961 для AFIB и 0.962 для CLBBB, то есть приближались к результатам централизованной модели на тех же данных.

Дополнительно оценивался перенос на внешний набор PTB-XL без дообучения. Для локальной модели одного клиента G -mean составлял 0.000 для 1AVB, 0.488 для PVC, 0.000 для AFIB и 0.682 для CLBBB. Для федеративной модели, обученной на данных 50 клиентов, соответствующие значения достигали 0.797, 0.909, 0.925 и 0.989. Таким образом, использование данных нескольких медицинских организаций повышало не только качество на основном наборе, но и устойчивость модели при переходе к другому источнику ЭКГ.

Отдельный анализ вычислительной нагрузки показал, что участие в федерации позволяет отдельному клиенту быстрее достичь качества, сопоставимого с самостоятельным локальным обучением: в рассматриваемом эксперименте такой уровень достигался примерно за 9 коммуникационных раундов. При этом полный федеративный цикл требует дополнительных вычислительных и коммуникационных затрат, поэтому преимущество федеративного подхода определяется прежде всего качеством общей модели и возможностью совместного использования распределённых данных, а не сокращением полного времени обучения.

Стандартный FedAvg предполагает, что клиентские обновления формируются на корректно размеченных данных. В медицинской федерации это условие может нарушаться не только вследствие целенаправленных атак, но и из-за систематических ошибок врача, различий в правилах кодирования диагнозов или неполной локальной разметки.

Пусть клиент k располагает набором

$$\mathcal{D}_k = \left\{ \left(x_i^{(k)}, y_i^{(k)} \right) \right\}_{i=1}^{n_k}, \quad (15)$$

а ошибочная разметка задаётся преобразованием

$$\tilde{y}_i^{(k)} = f_k \left(y_i^{(k)} \right). \quad (16)$$

В эксперименте ошибки моделировались инверсией части бинарных меток:

$$\tilde{y}_{i,c}^{(k)} = \begin{cases} 1 - y_{i,c}^{(k)}, & i \in \mathcal{I}_k, c \in \mathcal{C}_{\text{flip}}, \\ y_{i,c}^{(k)}, & \text{иначе.} \end{cases} \quad (17)$$

В отличие от классического сценария с византийскими клиентами, способными передавать произвольные или специально искажённые обновления, здесь небольшая доля ошибочных меток присутствует сразу у большого числа участников. Поэтому соответствующие обновления не обязательно являются выраженными геометрическими выбросами, хотя в совокупности способны ухудшать глобальную модель.

Для повышения устойчивости федеративного обучения предложен метод BANT, в котором клиентские обновления оцениваются по их влиянию на небольшую доверенную выборку с проверенной разметкой.

Пусть на раунде t сервер располагает глобальной моделью w^t , а клиент k возвращает обновление Δ_k^t . Для каждого клиента вычисляется изменение функции потерь на доверенной выборке:

$$\delta_k^t = L_{\text{trust}}(w^t) - L_{\text{trust}}(w^t + \Delta_k^t). \quad (18)$$

Положительное значение δ_k^t означает, что клиентское обновление уменьшает ошибку на доверенных данных.

Текущая нормированная оценка клиента определяется как

$$s_k^t = \frac{[\delta_k^t]_+}{\sum_{j=1}^K [\delta_j^t]_+}, \quad [\delta]_+ = \max\{\delta, 0\}. \quad (19)$$

Для снижения влияния случайных колебаний используется накопленный доверительный вес

$$\alpha_k^t = (1 - \beta)\alpha_k^{t-1} + \beta s_k^t, \quad \alpha_k^0 = \frac{1}{K}. \quad (20)$$

Если ни одно клиентское обновление на текущем раунде не улучшает качество на доверенной выборке, используется равномерное значение $s_k^t = 1/K$. Итоговая модель обновляется по правилу

$$w^{t+1} = w^t + \sum_{k=1}^K \mathbb{I}[\delta_k^t > 0] \alpha_k^t \Delta_k^t. \quad (21)$$

Таким образом, обновления, ухудшающие качество на доверенной выборке, не участвуют в текущей агрегации, однако единичное неудачное обновление не приводит к окончательному исключению клиента, поскольку накопленный

доверительный вес сохраняет информацию о его поведении на предыдущих раундах.

Доверительные веса BANT могут использоваться и как дополнительный сигнал для контроля качества локальных данных. Устойчиво низкое значение α_k^t указывает на то, что обновления клиента регулярно оказываются мало полезными относительно доверенной выборки, и может служить основанием для дополнительной проверки его разметки.

BANT сравнивался как с базовым FedAvg без специальной защиты от ошибочных обновлений, так и с несколькими классами устойчивых методов: FLTrust, Zeno, SafeGuard и Central Clip. Эксперимент проводился на подвыборке ISPfed набора данных ISP, распределённой между 100 клиентами, соответствующими медицинским организациям. Один клиент сохранял исходную разметку, а у остальных 99 контролируемо инвертировалась часть меток. Клиенты были разделены на девять групп с долей повреждения от 1 до 19%, при среднем уровне около 10%. Маска ошибок оставалась неизменной на протяжении всего обучения, моделируя постоянную локальную ошибку, а не разовую атаку.

Отдельная выборка ISPtrust с проверенной разметкой использовалась методами, которым необходимы доверенные серверные данные. Её распределение классов отличалось от основной федеративной выборки ISPfed и содержало более высокую долю патологических записей. Распределение классов в выборках ISPtrust и ISPfed приведено в таблице 8.

Таблица 8 — Распределение классов в основной и доверенной выборках

Выборка	Other	1AVB	PVC	AFIB	CLBBB	LAFB	CRBBB
ISPfed	0.91	0.009	0.020	0.004	0.010	0.039	0.010
ISPtrust	0.77	0.036	0.068	0.025	0.024	0.075	0.052

Результаты сравнения методов федеративного обучения при распределённой ошибочной разметке представлены в таблице 9.

Таблица 9 — Результаты федеративного обучения при распределённой ошибочной разметке

Метод	G -mean	Sensitivity	Specificity
FedAvg	0.711	0.820	0.617
FLTrust	0.581	0.573	0.589
Zeno	0.761	0.640	0.905
SafeGuard	0.474	0.958	0.235
Central Clip	0.647	0.725	0.577
BANT	0.869	0.834	0.905
FedAvg, чистые метки	0.911	0.892	0.930

Распределённая ошибочная разметка снижала G -mean стандартного FedAvg с 0.911 на чистых данных до 0.711. BANT достигал значения 0.869 и

существенно сокращал этот разрыв. Лучший из остальных устойчивых методов, Zeno, обеспечивал G -mean 0.761. Наиболее заметное улучшение BANT наблюдалось по специфичности: 0.905 против 0.617 у FedAvg на повреждённых данных и 0.930 у FedAvg на чистой разметке.

Важно, что эксперимент моделирует не несколько клиентов с полностью произвольными обновлениями, а небольшие систематические ошибки, распределённые практически по всей федерации. Именно в такой постановке обновления отдельных участников могут выглядеть относительно нормальными, но их совокупное влияние постепенно ухудшает глобальную модель.

Накопленные доверительные оценки BANT могут дополнительно использоваться для обратной связи клиентам. Участникам с устойчиво низкими значениями α_k^t может быть рекомендована проверка локальной разметки, а предсказания глобальной модели могут применяться для ранжирования записей, требующих повторного просмотра специалистом. При этом низкий доверительный вес сам по себе не является доказательством ошибки, поскольку причиной может быть статистическое отличие локальной популяции или нерепрезентативность доверенной выборки.

Таким образом, в четвёртой главе показана возможность практической реализации федеративного обучения с сохранением исходных данных в локальных контурах организаций. Для условий распределённой ошибочной разметки предложен метод BANT, оценивающий функциональную полезность клиентских обновлений по доверенной выборке и существенно уменьшающий снижение качества глобальной модели.

В заключении перечислены основные результаты работы:

1. Проведено исследование методов автоматической классификации по многоканальным электрокардиографическим сигналам. Показано, что качество нейросетевых моделей определяется не только выбранной архитектурой, но и объемом и разнообразием обучающих данных, а также адаптацией к целевому источнику. Экспериментально установлено, что использование крупной клинической выборки и последующее дообучение позволяют повысить устойчивость классификации при переносе на данные другого источника.
2. Разработаны архитектура и метод сегментации цифровых электрокардиографических сигналов, позволяющие использовать автоматически сформированную псевдоразметку дополнительных записей в условиях ограниченного объема экспертно размеченных данных. Применение self-training подхода с псевдоразмеченными данными обеспечило повышение качества определения временных границ основных морфологических элементов сигнала.
3. Разработан метод контрастного предобучения нейросетевых моделей классификации, использующий индивидуальные характеристики объектов при формировании дополнительных положительных пар. Экспериментально показано, что включение возраста пациентов в процесс кон-

- трастного обучения позволяет повысить качество последующей классификации по сравнению с базовыми вариантами предобучения.
4. Разработан метод переноса знаний между моделями, работающими с различным числом доступных каналов входного сигнала, основанный на контрастном обучении различных комбинаций каналов одной записи. Метод позволяет использовать информацию многоканального сигнала на этапе предобучения и повышать качество классификации модели, работающей при уменьшенном числе доступных каналов. Эффективность подхода подтверждена как на первом отведении многоканальных записей, так и на независимых одноканальных данных.
 5. Разработан метод федеративного обучения нейросетевых моделей классификации, основанный на оценивании полезности клиентских обновлений по доверенной серверной выборке. Метод позволяет выявлять и ограничивать влияние аномальных обновлений при агрегации параметров глобальной модели и повышает устойчивость федеративного обучения в условиях систематических ошибок локальной разметки.

Публикации

1. Avetisyan A. et al. Deep neural networks generalization and fine-tuning for 12-lead ECG classification // Biomedical Signal Processing and Control. 2024. Vol. 93. P. 106160.
2. Ananov V. V., Skorik S. N., Shaklein V. V., Avetisyan A. A., Teregulov Y. E., Turdakov D. Y., Karpulevich E. A. Assessment of the impact of non-architectural changes in the predictive model on the quality of ECG classification // Proceedings of the Institute for System Programming of the RAS. 2021. Vol. 33, no. 4. P. 87–98.
3. Skorik S., Avetisyan A., Diatlinko E., Mindiiarova R., Markin Y. Transferring Knowledge from 12-lead to 1-lead ECGs via Contrastive Learning // 2024 IEEE 48th Annual Computers, Software, and Applications Conference (COMPSAC). 2024. P. 1825–1830.
4. Avetisyan A., Khachaturov N., Asatryan A., Tigranyan S., Markin Y. Self-trained model for ECG complex delineation // 2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2025. P. 1–5.
5. Skorik S., Avetisyan A. SSSD-ECG-nle: New Label Embeddings with Structured State-Space Models for ECG generation // 2024 Ivannikov Memorial Workshop (IVMEM). 2024. P. 55–61.
6. Molodtsov G., Medyakov D., Skorik S., Khachaturov N., Tigranyan S., Aletov V., Avetisyan A., Takáč M., Beznosikov A. BANT: Byzantine Antidote via Trial Function and Trust Scores // Proceedings of the AAAI Conference on Artificial Intelligence. 2026. Vol. 40, no. 29. P. 24431–24440.
7. Дятлинко Е. С., Ибрагимов А. А., Аветисян А. А. Групповое контрастивное обучение для анализа медицинских данных // Doklady Mathematics. 2026. Т. 531, № 1. С. 96–107.

8. Молодцов Г. Л., Медяков Д. О., Скорик С. Н., Хачатуров Н., Тигранян Ш. Т., Алетов В. И., Аветисян А. А., Безносиков А. Н. Защита от византийских атак через доверительное взвешивание устройств // Успехи математических наук. 2025. Т. 80, № 6 (486). С. 191–194.
9. Аветисян А. А., Ананьев В. В., Скорик С. Н., Уханов В. Д., Карпулевич Е. А., Турдаков Д. Ю., Шаклеин В. В. Инструмент для развертывания нейросетевой модели предсказания патологий по данным 12-канальных электрокардиограмм : свидетельство о государственной регистрации программы для ЭВМ. Российская Федерация, 2021.
10. Аветисян А. А., Скорик С. Н., Тигранян Ш. Т., Асатрян А. А., Дятлинко Е. С., Миндиярова Р. В., Мартиросян А. А., Хачатуров Н. А., Бурсов А. И., Маркин Ю. В. Программа классификации синдромов для 12-канальных цифровых ЭКГ на основе нейросетевой модели : свидетельство о государственной регистрации программы для ЭВМ. Российская Федерация, 2024.