

Федеральное государственное автономное образовательное учреждение
высшего образования «Уральский федеральный университет имени
первого Президента России Б.Н. Ельцина»

На правах рукописи

Марков Никита Сергеевич

**Модели машинного обучения для
автоматизированного анализа интервалограмм ритма
сердца в диагностике аритмии**

Специальность 1.2.2 —
Математическое моделирование, численные методы и комплексы
программ

Автореферат
диссертации на соискание учёной степени
кандидата физико-математических наук

Работа выполнена на кафедре вычислительной математики и компьютерных наук ФГАОУ ВО «Уральский федеральный университет имени первого Президента России Б.Н. Ельцина» и в лаборатории трансляционной медицины и биоинформатики ФГБУН Институт иммунологии и физиологии Уральского отделения Российской академии наук.

Научный руководитель: **Соловьёва Ольга Эдуардовна**,
доктор физико-математических наук, профессор,
член-корреспондент РАН

Официальные оппоненты: **Кучумов Алексей Геннадьевич**,
доктор физико-математических наук, доцент,
ФГАОУ ВО «Пермский национальный исследовательский политехнический университет»,
заведующий лабораторией биожидкостей

Тырсин Александр Николаевич,
доктор технических наук, профессор, ФГАОУ
ВО «Уральский федеральный университет
имени первого Президента России Б.Н.
Ельцина», профессор кафедры прикладной
математики и механики

Павловский Евгений Николаевич,
кандидат физико-математических наук, ФГАОУ
ВО «Новосибирский национальный исследовательский государственный университет»,
заведующий лабораторией аналитики потоковых данных и машинного обучения

Защита состоится 15 октября 2025 г. в 13:00 на заседании диссертационного совета УрФУ 1.2.05.22 по адресу: 620000, г. Екатеринбург, пр. Ленина 51, к. 248, Зал диссертационных советов.

С диссертацией можно ознакомиться в библиотеке и на сайте ФГАОУ ВО «Уральский федеральный университет имени первого Президента России Б.Н. Ельцина», <https://dissovet2.urfu.ru/mod/data/view.php?d=12&rid=7424>.

Автореферат разослан «___» августа 2025 года.



Ученый секретарь
диссертационного совета
доктор физ.-мат. наук, доцент

Елфимова Екатерина Александровна

Общая характеристика работы

Актуальность и степень разработанности темы. Ритм здорового сердца задает специализированная функциональная структура — синусовый узел. Нормальный квази-регулярный ритм сердечбиений называется синусовым ритмом. Фибрилляция предсердий (ФП) — это заболевание сердца, при котором синусовый узел перестает быть основным водителем ритма и теряет контроль за циклом сердечбиений. Ритм фибрилляции предсердий характеризуется повышенной средней частотой и квази-хаотической последовательностью сердечбиений, что приводит к развитию опасных осложнений. Встречаемость ФП в населении развитых стран достигает 1-2%, что делает её наиболее распространённой аритмией в медицинской практике [1]. Более раннее выявление эпизодов ФП способствует верному выбору врачебной тактики, что является залогом успешного лечения пациентов с данным нарушением сердечного ритма.

Интервалограмма — динамическая последовательность временных интервалов между сердечными сокращениями — является общим сигналом медицинского назначения. Флуктуации сердечного ритма, регистрируемые интервалограммой, отражают динамическое взаимодействие различных физиологических процессов и представляют собой важный для анализа математический объект [2]. Интервалограммы, при этом, могут считываться с помощью ряда доступных потребительских устройств [3]. С одной стороны, рассчитываемые по интервалограммам индексы вариабельности ритма сердца (ВРС) используются в качестве показателей функционального состояния пациента [4]. С другой стороны, классификация интервалограмм является одним из предпочтительных способов детекции эпизодов ФП [5]. Ввиду этих фактов, использование интервалограмм представляет наибольшую практическую ценность для обнаружения развивающейся аритмии.

Методы на основе нейронных сетей достигают наиболее высоких с позиции точности результатов в задаче классификации сердечных ритмов [6]. Однако эксплуатация нейронных сетей требует больших вычислительных затрат, а сами модели склонны к переобучению под конкретные наборы данных. Этот аспект затрудняет реализацию нейросетевых моделей в системах непрерывного мониторинга здоровья, используемых для суточного мониторирования электрокардиограммы (ЭКГ) и выявления эпизодов ФП у пациентов с подозрением на аритмию. Поэтому до сих пор имеется потребность в разработке и экспериментальной валидации эффективных методов детекции ФП, которые не требуют больших объёмов данных для обучения и могут быть реализованы на устройствах с низким электропотреблением. Одной из таких многообещающих альтернатив является классификация сжатием, использующая эвристическое сжатие информации для выделения нерегулярностей и закономерностей в данных,

превосходящая по качеству модели-«трансформеры» в ряде задач классификации текста [7].

Несмотря на развитие методов машинного обучения, способных к автоматизированному обнаружению эпизодов ФП, своевременная диагностика данного нарушения остается сложной задачей из-за эпизодического характера аритмии и бессимптомности течения болезни [6]. Данная специфика диктует потребность в разработке методов предсказания формирования эпизодов ФП при «молчащем» периоде болезни. Задача осложняется отсутствием достаточно широких наборов данных с экспертной разметкой и сопутствующей ретроспективной информацией о пациентах. Однако, при наличии существенного объема популяционных данных, как, например, в исследовании проведенном в США в клинике Мейо [8], модели на основе глубоких нейронных сетей позволяют проводить подобную диагностику аритмии и поддерживать врачей в постановке правильного диагноза.

Наряду с практическим применением интервалограмм у клиницистов и патофизиологов возникает потребность в изучении лежащих в структуре аритмии механизмов. При этом традиционно ритм при ФП считается хаотическим, из-за чего эпизоды ФП исключаются при анализе функционального состояния пациента с помощью математических индексов ВРС. Однако согласно современным представлениям, интервалограммы при ФП не являются случайными рядами и демонстрируют автокорреляционные характеристики [9]. Это говорит о том, что изучение ВРС в течение эпизода ФП, построение статистических моделей и поиск связей в структуре анализируемых данных может дать дополнительную значимую информацию о течении исследуемой аритмии. Потенциальная взаимосвязь между нормальным синусовым ритмом и хаотическим ритмом при ФП свидетельствует о целесообразности построения прогностических моделей.

Перспектива разработки новых инструментов анализа временных последовательностей и тестирование методов в контексте, ориентированном на более раннее обнаружение и лучшее понимание развивающейся аритмии, определяют актуальность прodelьваемой работы.

Целью данного исследования является разработка эффективных методов анализа временных последовательностей, построение и экспериментальная валидация классифицирующих и регрессионных моделей методами машинного обучения, ориентированные на создание комплекса программ для поддержки принятия врачебных решений.

Для достижения поставленной цели были сформулированы и решены следующие **задачи**:

1. На основе алгоритмов сжатия информации и конечно-разностных методов разработать автоматизированную модель обнаружения эпизодов ФП по временной последовательности — интервалограмме.

2. Оценить качество классификации разработанной моделью в условиях малого количества проб для обучения.
3. Методами регрессионного анализа и отбора значимых признаков разработать статистические модели для исследования связей между характеристиками патологического и нормального ритмов.
4. На основе интервалограмм нормального синусового ритма разработать модели нейронных сетей для предсказания возникновения ФП до начала эпизода аритмии.
5. Разработать комплекс программ, объединяющий предлагаемые модели в общую систему поддержки принятия врачебных решений.

Объект исследования – математические модели и методы анализа временных последовательностей, в том числе интервалограмм.

Предмет исследования – классификаторы ритмов, индексы вариабельности ритма сердца, статистические модели, нейросетевые модели.

Научная новизна результатов диссертационного исследования.

В области математического моделирования:

1. Методы сжатия информации впервые применены для детекции аритмии, на их основе была построена модель классификации временных последовательностей биологических сигналов. Предлагаемая модель, в отличие от существующих решений, предусматривает обучение на малой выборке данных.
2. Впервые построены линейные регрессионные модели, демонстрирующие клинически релевантные статистические связи между характеристиками квази-хаотического ритма ФП и нормального синусового ритма пациентов.
3. На основе свёрточно-рекуррентных нейронных сетей разработана модель, позволяющая предсказывать наступление эпизода аритмии по интервалограмме синусового ритма в диапазоне до 24 часов перед эпизодом аритмии, что может использоваться для ранней диагностики и профилактики ухудшения состояния пациентов.

В области численных методов:

- Предложен новый способ разностного пятиточечного представления интервалограммы, улучшающий чувствительность классификации аритмии по сравнению со стандартными представлениями данной временной последовательности.

В области создания комплекса программ:

1. Создан и апробирован комплекс программ, осуществляющий автоматизированную классификацию аритмии, разметку ЭКГ на нормальный и патологический ритмы, и оценивающий вероятность возникновения аритмии у предположительно здоровых пациентов.
2. Разработан эффективный метод классификации ритмов, допускающий реализацию на носимых устройствах с малым энергопотреблением.

Методология и методы исследования. Предлагаемая модель детекции эпизодов ФП использует конечно-разностные подходы, алгоритмы сжатия информации и методы квантования сигнала. Для экспериментальной валидации точности модели использовались вычислительные процедуры кросс-валидации, меры качества классификации, статистические методы. Разработанная классифицирующая модель использовалась для разметки оригинальных записей ЭКГ, что позволило провести исследование взаимосвязей между вариабельностью синусового ритма и вариабельностью ритма эпизодов ФП. Модели взаимосвязей между ритмами были построены с помощью множественной линейной регрессии после применения методов отбора значимых признаков. Дополнительно применялись корреляционный, кластерный анализ, методы проверки статистических гипотез. Для построения моделей предсказания аритмии применялись свёрточные и рекуррентные нейронные сети. Для эмпирического анализа полученных моделей были задействованы методы построения карт внимания.

Теоретическая значимость заключается в разработке моделей, раскрывающих статистически значимые связи между вариабельностью интервалограмм при нормальном синусовом ритме и при ФП. Продемонстрировано, что алгоритмы сжатия информации могут применяться для классификации временных последовательностей, полученных на основе биомедицинских сигналов. Показано, что глубокое обучение рекуррентных сетей последовательным флуктуациям ритма позволяет предсказывать возникновение эпизодов аритмии по эпизодам нормального ритма.

Практическая значимость заключается в разработке и тестировании методов, которые могут применяться в основе автоматизированных инструментов поддержки принятия врачебных решений. Разработанная модель автоматизированной детекции аритмии может быть реализована на носимых устройствах мониторинга здоровья.

Положения, выносимые на защиту:

1. Разностное представление интервалограммы позволяет использовать алгоритмы сжатия информации для классификации аритмии. Особенностью предлагаемой модели классификации временных последовательностей является высокое качество обучения с малым количеством проб по сравнению с описанными в литературе методами. Согласно вычислительным экспериментам, эффективная классификация возможна с использованием 10-20 наблюдений каждого класса временной последовательности.
2. Регрессионное моделирование выявляет связи показателей вариабельности ритма сердца в течение эпизода ФП с показателями вариабельности нормального синусового ритма. Несмотря на квази-хаотичность аритмии, построенные математические модели

раскрывают статистическую взаимосвязь ключевых характеристик ФП с распределением интервалограммы на синусовом ритме. Найдены индексы патологического ритма, демонстрирующие корреляции с продолжительностью эпизода аритмии.

3. Обученная модель на основе свёрточно-рекуррентных нейронных сетей предсказывает возникновение эпизода ФП в течение 24 часов до наступления пароксизма аритмии по интервалограмме из 64 кардиоинтервалов нормального синусового ритма.
4. Согласно валидационным экспериментам, применение свёрточно-рекуррентных сетей обеспечивает более высокое качество классификации в сравнении с обычными свёрточными сетями, что говорит о важности обучения последовательным изменениям сердечного ритма при исследовании интервалограмм.

Достоверность полученных результатов обеспечивается использованием экспертно размеченных данных пациентов и корректным применением методов статистики. Качество предлагаемых моделей классификации подтверждается вычислительными экспериментами в рамках верифицированных процедур валидации.

Апробация работы. Основные результаты работы докладывались на 12 международных конференциях в Екатеринбурге, Казани и Санкт-Петербурге, в том числе на Международной (54-я Всероссийской) молодежной школе-конференции «Современные проблемы математики и ее приложений», 2023 IEEE Ural-Siberian Conference on Biomedical Engineering, Radioelectronics and Information Technology (USBREIT) и 2023 IEEE Ural-Siberian Conference on Computational Technologies in Cognitive Science, Genomics and Biomedicine (CSGB).

Личный вклад. Все результаты исследований, составляющие основное содержание диссертационной работы, были получены диссертантом самостоятельно. Диссертантом был внесён основной вклад во все выполненные в соавторстве работы [A1—A9], включая предварительную обработку данных, построение моделей, вывод методов, расчёт индексов вариабельности, разработку комплекса программ, валидацию и анализ результатов, написание текстов публикаций. Вклад в совместных публикациях научного руководителя Соловьёвой О.Э. и соавтора Архипова М.В. заключался в постановке задач исследований. Руководителем Соловьёвой О.Э. был также проведён анализ результатов исследований. Соавтор Ушенин К.С. консультировал по используемым методам машинного обучения. Соавтором Божко Я.Г. были предоставлены оригинальные данные ЭКГ, оказано содействие в клинической интерпретации полученных результатов. Соавторы Абросимова М. М., Ребак А. Д. и Новиков Р. Н. внесли вклад при тестировании моделей. Соавтор Котов И. С. принимал участие в разработке прототипов отдельных моделей. Всеми соавторами был внесён вклад в редактирование публикаций по результатам исследований.

Публикации. Основные результаты по теме диссертации изложены в 8 печатных работах в рецензируемых научных изданиях, рекомендованных ВАК РФ и Аттестационным советом УрФУ для защиты диссертации на соискание ученой степени кандидата наук. Из них 7 работ опубликованы в журналах, входящих в международную базу цитирования Scopus, и 1 статья опубликована в журнале из перечня ВАК. По результатам диссертационного исследования был зарегистрирован объект интеллектуальной собственности в виде программы для ЭВМ.

Благодарности. Автор благодарит научного руководителя, д.ф.-м.н., профессора, члена-корреспондента РАН Соловьёву Ольгу Эдуардовну за неоценимую помощь и наставления при подготовке диссертационной работы. Автор выражает благодарность к.ф.-м.н. Ушенину Константину Сергеевичу и к.м.н. Божко Якову Григорьевичу за консультации и поддержку в проведении исследований. Диссертационные исследования проведены при финансовой поддержке гос. темы ИИФ УрО РАН №122022200089-4, гос. темы УГМУ №121040500248-7 и Программы «Приоритет 2030» УрФУ.

Содержание работы

Во введении обосновывается актуальность исследований, проведённых в рамках данной диссертационной работы, формулируются цели и задачи работы, излагаются научная новизна и значимость, представляются основные положения, выносимые на защиту.

Первая глава диссертационной работы представляет собой обзор литературных источников и состоит из пяти разделов. В первом разделе приводятся основные сведения из области анализа сердечного ритма, вводится понятие интервалограммы как временной последовательности, подлежащей численной обработке. Выделяются основные задачи, подразумевающие анализ интервалограмм в контексте ФП. Во втором разделе проводится сравнительный обзор моделей детекции ФП на основе интервалограмм, указывается общая проблема применения опубликованных в литературе методов — необходимость в больших объемах данных для обучения моделей, что ограничивает их эффективность в ряде приложений. В третьем разделе приводится информация о классификации сжатием, предлагаемой для устранения данного недочёта. Представляются ключевые работы в данной области, начиная с основных положений колмогоровский алгоритмической теории информации, из которой последовало определение нормализованного расстояния сжатия и связанные с ней современные исследования. В четвертом разделе приводятся сведения о методологии ВРС — математических методов анализа интервалограммы связанных с функциональным состоянием сердца. В пятом разделе приведён обзор моделей предсказания наличия ФП у пациентов.

Вторая глава посвящена формулировке модели детекции ФП с помощью разностных методов и методов сжатия, вычислительным экспериментам оценки качества классификации моделью в условиях достаточных и ограниченных наборов данных для обучения. Результаты исследования, лежащего в основе данной главы, были опубликованы в статьях [A1–A3].

Пусть (R_i) — это последовательность временных координат R-пиков на записи ЭКГ, соответствующих началу сердечных сокращений, (RR_i) — интервалограмма из временных интервалов между соседними R-пиками: $RR_i = R_i - R_{i-1}$. Для нивелирования линейного тренда в литературе [10] вводится разностное ΔRR -представление интервалограммы: $\Delta RR_i = RR_{i+1} - RR_i = R_{i+1} - 2R_i + R_{i-1}$.

В настоящей работе по аналогии предлагается метод пятиточечного разностного $\Delta 5RR$ -представления интервалограммы:

$$\Delta 5RR_i = \frac{-R_{i+2} + 16R_{i+1} - 30R_i + 16R_{i-1} - R_{i-2}}{12}.$$

Модель классификации формулируется следующим образом. Пусть $\mathbb{R}^M$ — пространство событий. Конечные монотонные последовательности временных координат R-пиков $\mathbf{x} = (x_1, \dots, x_M) \in \mathbb{R}^M$ являются наблюдениями событий. Пусть $(\mathbf{x}_i, y_i)_{i=1..N}$ является обучающей выборкой из N наблюдений событий $\mathbf{x}_{1..N} \in X_{train}$ с известными классами $y_{1..N} \in Y_{train}$.

Последовательности приводятся к одному из представлений интервалограммы (RR, ΔRR или $\Delta 5RR$). Обозначив за $\tilde{x}_{i,j}$ значение j -ого элемента i -ой последовательности после выбранного конечно-разностного преобразования, наблюдения обучающей выборки можно рассматривать как матрицу $\tilde{X} = (\tilde{x}_{i,j})_{1 \leq i \leq N, 1 \leq j \leq m}$. Данная матрица «сворачивается» в одномерную последовательность, и на ней обучается квантователь $\mathbf{q}(\cdot)$, преобразующий вещественные последовательности к символьным последовательностям с алфавитом из Q элементов. Задача обучения квантователя сводится к задаче минимизации центроид, решаемой методом k-means с фиксированными изначальными положениями центроид, где за количество центроид принимается размер алфавита Q — первый гиперпараметр модели.

Пусть $\hat{\mathbf{x}} \in \mathbb{R}^m$ — это подлежащая классификации последовательность в выбранном разностном представлении, $\hat{y}$ — искомый неизвестный класс. Классификация производится путём расчёта нормализованных дистанций сжатия

$$d_i = \frac{C(\mathbf{q}(\hat{\mathbf{x}})\mathbf{q}(\tilde{\mathbf{x}}_i)) - \min(C(\mathbf{q}(\hat{\mathbf{x}})), C(\mathbf{q}(\tilde{\mathbf{x}}_i)))}{\max(C(\mathbf{q}(\hat{\mathbf{x}})), C(\mathbf{q}(\tilde{\mathbf{x}}_i)))},$$

где $\mathbf{q}(\hat{\mathbf{x}})\mathbf{q}(\tilde{\mathbf{x}}_i)$ является конкатенацией классифицируемой последовательности с i -ым наблюдением из обучающей выборки, $C(\cdot)$ — длина последовательности, сжатой методом gzip. Согласно полученным дистанциям

сжатия, искомый класс $\hat{y}$ определяется методом k -ближайших соседей:

$$\begin{aligned} \forall i, j \ 1 \leq i < j \leq N : d_{s(i)} &\leq d_{s(j)}, \\ d_{s(i)} = d_{s(j)} &\implies y_{s(i)} \geq y_{s(j)}. \\ w_{knn} &= \sum_{i=1}^k (-1)^{y_{s(i)}}, \\ \hat{y} &= \begin{cases} 0, & w_{knn} > 0, \\ 1, & w_{knn} < 0. \end{cases} \end{aligned}$$

Здесь $s(i)$ — это сортирующий индекс для дистанций $(d_i)_{1 \leq i \leq N}$ с приоритетом сортировки положительного класса над отрицательным, использующийся для вычисления коэффициента решения w_{knn} . Число ближайших соседей k является вторым гиперпараметром модели.

Помимо гиперпараметров Q (размер алфавита квантования) и k (число ближайших соседей), путём вычислительных экспериментов исследуются ширина окна интервалограммы M и выбор разностного представления (RR, Δ RR или Δ 5RR) в конфигурации модели. Данное исследование было проведено на открытой базе данных MIT-BIH AFDB [11], состоящей из 25 записей ЭКГ длительностью 10 часов. За основную меру качества классификации был взят корреляционный коэффициент Мэтьюса (ККМ).

Проведение вычислительных экспериментов диктовалось двумя процедурами валидации: с использованием полного доступного набора данных и в условиях малого количества проб.

Процедура с использованием полного набора данных представляла собой повторяющуюся пятикратную кросс-валидацию на популяции, что влекло 40 разбиений на обучающую и тестовую популяцию, состоящих из 20 и 5 записей соответственно. После проведения решёточной проверки гиперпараметров был зафиксирован размер алфавита Q для каждой исследуемой величины окна M ($Q = 39, 102, 102$ для $M = 32, 64, 128$ соответственно). Число соседей k было эмпирически зафиксировано на уровне $k_{empiric} = \text{odd}(\sqrt[3]{N})$ где N - количество наблюдений в обучающей выборке, $\text{odd}(\cdot)$ - округление до ближайшего нечетного числа.

В Таблице 1 представлены вычисленные и агрегированные меры качества классификации на полном наборе данных в сравнении между всеми представлениями интервалограммы и размерами окна. Применение численной схемы Δ 5RR вместо Δ RR позволило добиться существенно лучшей классификации для окон среднего и высокого размера $M = 64, 128$, что подтверждается показаниями средних значений и доверительных интервалов ККМ. Классифицирующая модель достигла наилучших результатов для окна $M = 128$ (соответствует эпизоду ЭКГ длительностью 90-120 секунд), где схема Δ 5RR привела к 96.37% чувствительности, 97.74% специфичности и 0.935 ККМ, а Δ RR — к 87.78% чувствительности, 99.00%

Таблица 1 — Классификаторы в терминах средней чувствительности, специфичности и ККМ.

Δ_5RR						
M	k	ДИ-	Средний ККМ	ДИ+	Средняя чувствительность	Средняя специфичность
32	31	0.845	0.854	0.862	93.89%	91.87%
64	25	0.895	0.913	0.929	95.05%	96.84%
128	19	0.916	0.935	0.949	96.37%	97.74%
ΔRR						
M	k	ДИ-	Средний ККМ	ДИ+	Средняя чувствительность	Средняя специфичность
32	31	0.838	0.848	0.857	94.90%	90.36%
64	25	0.833	0.866	0.890	88.55%	97.94%
128	19	0.829	0.874	0.906	87.78%	99.00%
RR						
M	k	ДИ-	Средний ККМ	ДИ+	Средняя чувствительность	Средняя специфичность
32	31	0.736	0.755	0.772	80.68%	93.52%
64	25	0.729	0.767	0.796	79.28%	96.53%
128	19	0.773	0.815	0.845	82.29%	97.87%

специфичности и 0.874 ККМ. Для малого окна $M = 32$ из-за пересечения доверительных интервалов ККМ нельзя говорить о превосходстве одного разностного представления над другим. Оба разностных представления существенно превосходили по качеству классификации базовое RR-представление для всех рассмотренных конфигураций модели.

Эксперименты в рамках валидации с малым количеством проб были призваны оценить качество классификации в условиях ограниченных наборов данных для обучения. Для значений $n = 5, 10, 20, 50, 100$ было проведено по 500 вычислительных экспериментов с обучающей выборкой, состоявшей из n интервалограмм синусового ритма и n интервалограмм ФП. Валидация была проведена для трёх изучаемых размеров окон со сравнением ΔRR и Δ_5RR -представлений.

На Рис. 1 представлены ящичковые диаграммы вычисленных ККМ, исходя из которых можно говорить о том, что предлагаемая модель классификации демонстрирует высокую способность к обобщению. Для некоторых комбинаций окна M и количества проб n присутствовали выбросы, говорящие о возникновении малых выборок, ведущих к целиком ошибочным классификациям. Тем не менее, 10-20 наблюдений каждого ритма было достаточно для стабильной классификации, и увеличение окна M и расширение обучающей выборки вело к улучшению результата. Для окон средней и высокой длины ($M = 64, 128$) схема Δ_5RR позволила




Рисунок 1 — Ящиковые диаграммы распределений ККМ для разнящегося количества проб n при обучении в условии ограниченного набора данных. Также представлены p -значения критерия Уилкоксона с поправкой на множественное тестирование проведенного для каждого n .

достичь существенного прироста качества классификации, подтверждаемого выводом критерия Уилкоксона с поправкой на множественный тест (все p -значения < 0.027).

В сумме, $\Delta 5RR$ опережает по качеству классификации ΔRR в большинстве рассмотренных случаев. Наилучший результат

$\Delta 5RR$ -представления может быть объяснен тем, что пятиточечная схема позволяет придать больший акцент флуктуациям ритма по сравнению с трехточечной, что приводит к более чуткому квантованию интервалограмм.

Таким образом, предлагается информационная модель классификации временных последовательностей, всецело подходящая для задачи детекции ФП. Предложена численная схема представления интервалограммы, улучшающая эффективность классификации методами сжатия. Модель исследована с помощью вычислительных экспериментов в рамках процедур кросс-валидации. В условиях достаточного набора данных модель демонстрирует уровень качества классификации, сравнимый с другими методами обнаружения ФП [10; 12]. Однако главной ценностью модели является эффективность классификации в парадигме малого количества проб. В отличие от требующих дообучения нейросетей в приложениях к детекции ритмов [13], предлагаемая модель не требует приорной информации. В перспективе, предлагаемый подход может использоваться для создания персонализированных классификаторов ритмов.

Третья глава исходит из предположения, что некоторые свойства ритма сердечбиений при ФП могут быть связаны с вариабельностью нормального синусового ритма. Традиционно индексы ВРС не вычисляются на эпизодах ФП из-за хаотичности ритма. Однако, согласно более современным представлениям, интервалограмма при ФП демонстрирует автокорреляционные характеристики у пациентов [9]. Изучение вариабельности ритма в течение эпизода аритмии способно дать дополнительную значимую информацию о структуре ритма, вследствие чего данная глава посвящена построению регрессионных моделей, связывающих индексы при ФП с индексами, рассчитанными на синусовом ритме. На базе исследований, лежащих в основе данной главы, были опубликованы статьи [A5—A8].

В исследовании используется объединённая выборка пациентов, состоящая из оригинальных данных кардиологического отделения Свердловской областной клинической больницы №1 (СОКБ №1) и открытой базы данных суточного мониторингирования сигналов ЭКГ LTAFDB [11]. Разработанная в предыдущей главе модель детекции эпизодов ФП позволила провести автоматическую разметку оригинальных данных и открыла возможность расширить популяцию региональными пациентами. Рис. 2 демонстрирует схему процедуры предобработки данных, состоящую из нескольких шагов: отбора записей, выделения интервалограмм, подсчета индексов ВРС для каждого из анализируемых видов ритма. Всего из двух источников данных было отобрано 37 записей. Каждой отобранной записи соответствовала объединённая RR-интервалограмма для синусового ритма, и объединенная RR-интервалограмма для ритма ФП. Для каждой интервалограммы было рассчитано по 48 индексов ВРС. Согласно раскрываемым признакам ритма и используемым подходам к




Рисунок 2 — Дизайн исследования. Из записи ЭКГ пациентов выделяются длительные эпизоды синусового ритма и ритма ФП. Для каждого типа ритма независимо рассчитываются индексы BPC.

анализу интервалограммы, рассчитываемые индексы делятся на следующие группы: индексы частоты ритма (MeanNN, MedianNN), индексы быстрой вариабельности ритма (RMSSD, SDSD, SD1, SD1d, SD1a, C1a, C1d, pNN50, pNN20), индексы медленной вариабельности ритма (SDNN, MadNN, IQRNN, CVNN, MCVNN, SD2, SD2d, SD2a, SDNNa, SDNNd, C2a, C2d, Ca, Cd), индексы главных компонент графика Пуанкаре (S, SD1/SD2, CVI, CSI, CSI Modified), индексы фрагментации ритма (PIP, IALS, PSS, PAS), индексы асимметрии ритма (AI, PI, SI, GI), геометрические индексы (HTI, TINN), индексы частотного домена (LF, HF, LFn, HF_n, LF/HF), индексы энтропии (SampEn, ApEn).

Каждая запись была представлена с помощью двух векторов индексов (Рис. 2). Далее по тексту аббревиатуры без префикса (RMSSD, SD1, AI и.т.д.) обозначают индексы, подсчитанные при синусовом ритме. Аббревиатуры с префиксом PAF (PAF_RMSSD, PAF_SD1, PAF_AI и.т.д.) обозначают индексы, подсчитанные на ритме ФП.

В дополнение к индексам BPC были также рассчитаны важные с точки зрения клинических приложений показатели, позволяющие оценить возможность восстановления синусового ритма у пациентов. Проведенный корреляционный анализ позволил выделить индекс PAF_HTI, показавший значимую корреляционную связь с показателем AF Ratio — долей эпизодов ФП в отношении ко всей записи ($r = -0.6, p < 0.02$). PAF_HTI фактически

является оценкой остроты пика распределения RR-интервалов. Обратная связь PAF_НТИ и доли ФП на записи говорит о том, что при больших значениях данного индекса, и, следовательно, при более пологой гистограмме RR-интервалограммы с менее острым пиком, общая длительность эпизода аритмии будет меньше.

Согласно первоначальному корреляционному анализу, не существует линейной модели, которая позволяет предсказывать один отдельно взятый индекс ВРС на эпизоде ФП по единственному индексу на синусовом ритме во всех возможных парах. Множественная линейная регрессия, однако, способна предсказывать индексы при ФП используя несколько индексов при синусовом ритме в качестве независимых переменных. Для каждого индекса при ФП были отобраны не более шести наиболее значимых предикторов синусового ритма с помощью метода эластичных сетей и итерационного исключения признаков, после чего были выбраны наилучшие модели. Распространение регрессии на четыре независимых признака приводит к моделям с максимальным скорректированным R^2 равным 0.74. Найденные модели предсказывают следующие индексы: PAF_CVI, PAF_pNN20, PAF_pNN50, PAF_ApEn, PAF_SDNN, PAF_SD2.

В Таблице 2 представлены наиболее значимые модели, выбранные из полученных семейств согласно критерию Акайке (AIC). Каждая из полученных моделей включала в себя признак, характеризующий общую частоту ритма (индекс частоты ритма: MeanNN), и один из признаков, отражающих разброс RR-интервалов на наблюдаемом отрезке ЭКГ синусового ритма. Так, модель $\text{PAF_pNN50} = 0.08 \cdot \text{MeanNN} - 0.12 \cdot \text{MadNN} - 0.63 \cdot \text{PSS} + 70.33 \cdot \text{CVSD}$, объясняющая мгновенные изменения между последовательными значениями на RR-интервалограмме патологического ритма (скор. $R^2 = 0.71$), включает в себя предикторы MeanNN и MadNN: здесь второй предиктор является медианным абсолютным отклонением RR-интервалов.

Большинство рассмотренных моделей связывают такие ключевые характеристики ВРС ФП, как признаки быстрой и медленной вариабельности патологического ритма, с асимметричностью и эксцессом гистограммы распределения RR-интервалов на синусовом ритме. Так, в модель $\text{PAF_SDNN} = 0.34 \cdot \text{MeanNN} + 1135 \cdot \text{CVNN} - 0.74 \cdot \text{IQRNN} - 230.61 \cdot \text{AI}$, характеризующей общую дисперсию RR-интервалов на патологическом ритме (скор. $R^2 = 0.63$), входят индексы CVNN и IQRNN с разными знаками. CVNN является чувствительным к хвостам распределений параметрическим показателем разброса RR-интервалограммы. С другой стороны, индекс IQRNN является непараметрической характеристикой эксцесса распределения и менее чувствителен к выбросам. Вхождение данных индексов с разными знаками может говорить о том, что острота пика распределени на синусовом ритме сама по себе не имеет существенного влияния на индексы PAF_SDNN и PAF_SD2, но наличие выраженного

Таблица 2 — Многопараметрические линейные модели, описывающие взаимосвязь индексов ВРС при ФП с индексами ВРС синусового ритма.

Зависимый индекс ФП	Независимые предикторы на синусовом ритме				Скор. R^2	AIC
PAF_CVI	0.0047 MeanNN ($p < 0.01$)	+7.2796 CVNN ($p < 0.01$)	-0.0052 IQRNN ($p < 0.01$)	-0.0022 MedianNN ($p = 0.04$)	0.74	-31.77
PAF_pNN20	0.0830 MeanNN ($p < 0.01$)	-0.1166 MadNN ($p < 0.01$)	-62.6899 PSS ($p < 0.01$)	+70.3369 CVSD ($p = 0.04$)	0.71	229.55
PAF_pNN50	0.1179 MeanNN ($p < 0.01$)	-0.1988 MadNN ($p < 0.01$)	-76.3139 PSS ($p < 0.01$)	+148.0655 CVSD ($p < 0.01$)	0.71	249.82
PAF_ApEn	0.0024 MeanNN ($p < 0.01$)	-0.0087 MadNN ($p < 0.01$)	+0.7153 SampEn ($p < 0.01$)	+5.6343 MCVNN ($p = 0.01$)	0.69	-24.81
PAF_SDNN	0.3352 MeanNN ($p < 0.01$)	+1135.0674 CVNN ($p < 0.01$)	-0.7422 IQRNN ($p < 0.01$)	-230.6075 AI ($p < 0.05$)	0.63	348.44
PAF_SD2	0.4186 MeanNN ($p < 0.01$)	+1493.9636 CVNN ($p < 0.01$)	-0.9419 IQRNN ($p < 0.01$)	-346.8794 AI ($p = 0.02$)	0.61	370.42

хвоста гистограммы и выбросы на синусовом ритме могут быть признаком увеличенной дисперсии RR-интервалов на эпизодах аритмии.

Эти наблюдения подчеркивает модель $PAF_CVI = 0.005 \cdot \text{MeanNN} + 7.28 \cdot \text{CVNN} - 0.005 \cdot \text{IQRNN} - 0.002 \cdot \text{MedianNN}$, характеризующая быстрые и медленные флуктуации ритма сердцебиений на эпизодах ФП (скор. $R^2 = 0.74$). Здесь три предиктора совпадают с моделями для PAF_SDNN и PAF_SD2, однако четвёртый предиктор (в Табл. 2 это MedianNN с отрицательным знаком) указывает на направление скошенности гистограммы распределения. Связь с PAF_CVI свидетельствует о том, что пациенты, у кого распределение RR-интервалограммы на синусовом ритме скошено с хвостом в сторону малых задержек активации, в моменты эпизода ФП будут иметь высокие значения индексов, характеризующих быстрые и медленные флуктуации ритма сердцебиений.

Дополнительным фактором, проливающим свет на причину, почему множественная линейная регрессия позволяет описать ВРС при ФП, является то, что регрессия косвенным образом вводит нелинейные связи между индексами. Поскольку CVNN определяется формулой $CVNN = \frac{SDNN}{\text{MeanNN}}$, то первый и второй предиктор моделей для PAF_SDNN, PAF_SD2 и PAF_CVI находятся в нелинейном взаимоотношении, балансируя вклад

друг друга в зависимости от средней частоты сердцебиений. В моделях появляется нелинейная характеристика, которая не может быть получена с помощью простой линейной модели с одним параметром.

Подводя итог, данная глава демонстрирует, что ритм при ФП не является полностью произвольным процессом в силу обнаруженных путём моделирования связей с характеристиками синусового ритма. Ввиду всего вышесказанного возникает вопрос: если синусовый ритм связан с патологическим, то можно ли идентифицировать пациентов с «молчащей» ФП, используя только нормальный ритм без обнаруженной аритмии в анализируемой интервалограмме?

В четвертой главе строятся нейросетевые модели с задачей распознать, принадлежит ли интервалограмма синусового ритма здоровому пациенту, либо же пациенту с недиагностированной ФП за некоторое время до эпизода аритмии. К применению предлагаются свёрточно-рекуррентные нейронные сети, что мотивировано результатами предыдущей главы: изменения медленных флуктуаций RR-интервалов, возникновение задержек, нехарактерных для общего распределения интервалограммы синусового ритма могут быть распознаны с помощью механизмов долгой-краткосрочной памяти. Путём вычислительных валидационных экспериментов устанавливается качество классификации. В результате исследования, лежащего в основе данной главы, была опубликована статья [A4].

Данные суточного мониторингирования ЭКГ, использовавшиеся в рамках настоящей главы, как и в предыдущей главе были получены из двух источников: открытого хранилища медицинских сигналов PhysioNet [11] и базы данных СОКБ №1. Базы данных LTAFDB (84 записей) и NSR2DB (49 записей) составляли обучающую выборку — из них было извлечено 172108 интервалограмм синусового ритма длиной $m = 64$. База данных СОКБ №1 (26 записей) составляла валидационную выборку — из неё было извлечено 25976 интервалограмм синусового ритма длиной $m = 64$. Исходя из данных полагается, что модель усматривает 24-часовой временной промежуток предсказания начала эпизода аритмии.

С помощью библиотеки Tensorflow Keras были реализованы две нейросетевые модели бинарной классификации: свёрточная нейронная сеть (СНС), и свёрточно-рекуррентная нейронная сеть (СРНС). Архитектуры обеих моделей включали в себя четыре блока остаточной свертки для извлечения признаков RR-интервалограммы, использовавших схему «бутылочного горлышка» по аналогии с архитектурой ResNet. Модели отличались операциями, выполняемыми между остаточными блоками и финальным слоем бинарной классификации. В модели СНС использовался оператор объединения глобальных средних для сокращения временных признаков. Модель СРНС включала два последовательных слоя долгой-краткосрочной памяти размерностью 32 и 16 для дополнительного




Рисунок 3 — Архитектуры двух реализованных моделей нейронных сетей. Обозначения слоёв соответствуют библиотеке Tensorflow Keras.

обучения временным флуктуациям между последовательными RR-интервалами. В целом, модель СНС состояла из 13368 обучаемых параметров, СРНС включала в себя дополнительные 11473 обучаемых параметров. Архитектуры моделей представлены на Рис. 3.

Для сравнения качества классификации СРНС и СНС с обеими моделями было проведено 10 раундов вычислительного эксперимента. С каждым раундом по 20% здоровых пациентов и по 20% пациентов с ФП случайным образом отбирались и удалялись из обучающей популяции, и модели обучались алгоритмом Adam на одинаковых выборках (размер батча — 4, темп обучения — 10^{-5}). Из каждого раунда выбирались эпохи с наименьшим значением функции ошибки (бинарной кросс-энтропии) на валидационной выборке. Для каждого вычислительного раунда были рассчитаны значения чувствительности, специфичности, точности и ККМ. Результаты представлены в Таблице 3.

В среднем, для модели СРНС были зафиксированы более высокие значения ККМ по сравнению с моделью СНС (0.642 против 0.588, $p = 0.04$). Будучи коэффициентом корреляции между наблюдаемыми и ожидаемыми бинарными классификациями, средний ККМ > 0.6 говорит о значимой предсказательной способности модели СРНС. Обе модели продемонстрировали сравнительно близкую специфичность (90.77% против 92.77%, $p = 0.13$), но модель СРНС продемонстрировала лучшую чувствительность (71.45% против 62.41%, $p < 0.01$), тем самым показывая

Таблица 3 — Результаты классификации в сравнении между моделями. Критерий Уилкоксона для связанных выборок использовался для оценки значимости разницы между вычисленными показателями.

Модель	Средний ККМ	Средняя чувствительность	Средняя специфичность	Средняя точность
СРНС	0.642	71.45%	90.77%	82.47%
СНС	0.588	62.41%	92.57%	79.60%
Критерий Уилкоксона	$p = 0.04$	$p < 0.01$	$p = 0.13$	$p = 0.06$

лучший результат при идентификации пациентов с аритмией. Из данного результата можно сделать вывод о том, что последовательные флуктуации RR-интервалов в интервалограммах синусового ритма, распознаваемые рекуррентной компонентой нейронной сети, могут играть существенную роль в диагностике «молчащей» ФП.

В отличие от передовых моделей [8], использующих ЭКГ в 12 отведениях для предсказания эпизода ФП за 31 день до пароксизма, модели разработанные в настоящей главе используют более общий биомаркер — интервалограмму — для 24-часового прогнозирования. Таким образом, интерес представляет более глобальное ретроспективное исследование с дальнейшим изучение прогностической пригодности флуктуаций нормального синусового ритма, удаленных от момента эпизода ФП.

В пятой главе приводится информация о разработанном комплексе программ, объединяющим предлагаемые в диссертационной работы модели и методы в единую систему поддержки принятия врачебных решений. На основе данной главы была зарегистрирована программа для ЭВМ [A9].

Программная реализация была осуществлена на языке Python 3. Схема комплекса программ представлена на Рис. 4. Комплекс состоит из трёх блоков. Блок 1 производит обработку входящего сигнала ЭКГ и идентификацию временных координат R-пигов, давая на выходе набор интервалограмм в представлениях, необходимых для дальнейшей численной обработки моделями. Блок 2 представляет собой реализацию классифицирующей модели из второй главы, и производит автоматизированную разметку записи ЭКГ на два ритма, соответствующую присвоенными моделью классам интервалограмм. Блок 3 применяет к интервалограммам разработанную в четвёртой главе модель СРНС в случае отрицательного вывода предыдущего блока. В результате работы комплекса производится вывод вероятности наличия ФП у пациента.

Все используемые в программных модулях внешние библиотеки имеют открытый исходный код, вследствие чего программы могут быть адаптированы для любых устройств. Критические с позиции сложности вычислений модули имеют параллельную реализацию. Разработанный




Рисунок 4 – Схема разработанного комплекса программ. Снизу представлена легенда цветовых обозначений и стрелок конвейера данных.

комплекс программ может использоваться для автоматизированной диагностики ФП и поддержки принятия врачебных решений специалистами. Блок 2 может найти применение на носимых устройствах мониторинга ЭКГ с низким электропотреблением ввиду повсеместности алгоритмов сжатия, что мотивирует их оптимизацию на уровне оборудования.

Заключение

Основные результаты диссертационной работы могут быть сформулированы следующим образом:

1. Разработана модель детекции ФП, использующая конечно-разностное представление интервалограммы, квантование сигнала и алгоритмы сжатия информации для классификации временных последовательностей. Универсальные методы сжатия были впервые применены для классификации сердечных ритмов. При использовании окна интервалограммы, соответствующем 90-120 секундам

записи ЭКГ, модель достигает 96.37% средней чувствительности, 97.74% средней специфичности и 0.935 среднего коэффициента корреляции Мэтьюса в рамках экспериментальной валидации с применением полной базы данных MIT-BIH AFDB. Наилучшее качество классификации было достигнуто с использованием предложенного метода пятиточечного $\Delta 5RR$ -представления интервалограммы.

2. Предложенная модель классификации временных последовательностей не требует больших объёмов данных для обучения и, согласно результатам вычислительных экспериментов, позволяет проводить достоверную классификацию, используя обучающую выборку из 10-20 наблюдений. Впервые предложен подход к классификации сердечных ритмов в парадигме обучения с малым количеством проб без использования приорных знаний. Низкие требования к объёму данных дают обоснование вычислительной эффективности методологии и допускают её применение на носимых устройствах с низким электропотреблением.
3. Результаты регрессионного моделирования с индексами ВРС демонстрируют связь патологического ритма ФП с флуктуациями нормального синусового ритма. Впервые были построены линейные модели для предсказания показателей ВРС при ФП, достигающие значений скорректированного $R^2 > 0.6$, и связывающие ключевые характеристики быстрой и медленной вариабельности ФП со вторым и третьим моментом распределения интервалограммы на синусовом ритме. Показано, что характеристика плотности вероятности ритма при ФП связана с длительностью эпизода аритмии у пациента.
4. Разработаны модели нейронных сетей, предсказывающие наличие эпизодической формы ФП у пациента по интервалограммам нормального синусового ритма в течение суток до наступления эпизода аритмии. Экспериментальная валидация моделей была проведена на региональной популяции пациентов: средние точность, чувствительность, специфичность и коэффициент корреляции Мэтьюса наилучшей модели составили 82.47%, 71.45%, 90.77% и 0.642 соответственно. Включение рекуррентной компоненты в архитектуру нейронной сети улучшило чувствительность классификации, что подтвердило важность обучения флуктуациям ритма для предсказания наступления аритмии.
5. Разработан и внедрён комплекс программ, комбинирующий предложенную модель детекции эпизодов ФП с моделью предсказания наступления аритмии в единую систему. Комплекс программ может использоваться для ранней диагностики ФП и поддержки принятия врачебных решений.

Дальнейшая разработка темы может следовать нескольким перспективным направлениям. Интересны возможности дальнейшей модификации модели детекции ФП путем применения моделей конечного контекста в качестве специализированных методов сжатия с расширением методологии на другие разновидности медицинских данных и биологических сигналов. Кроме того, при наличии большого количества ретроспективных данных, регрессионные линейные модели с индексами ВРС могут быть приведены к моделям рисков развития ФП у пациентов, а также может быть достигнуто дальнейшее внедрение модели предсказания эпизода аритмии по синусовому ритму. Интерес представляет и применение других нейросетевых архитектур — сиамских нейронных сетей и «трансформеров».

Публикации автора по теме диссертации

Статьи, опубликованные в рецензируемых научных изданиях, рекомендованных ВАК РФ и Аттестационным советом УрФУ

- A1. *Марков, Н.С.* Модель детекции фибрилляции предсердий, основанная на дифференцировании и сжатии интервалограмм [Текст] // Труды Института системного программирования РАН. — 2025. — Т. 37, № 2. — С. 281–300. — (1.25 п.л.) (K1).
- A2. *Abrosimova M., Rebak A., Novikov R., Markov N.* Classification with PPMd Compression in Few-Shot Learning: The Case of Eye-Tracking Dyslexia Detection [Текст] // IEEE Ural-Siberian Conference on Biomedical Engineering, Radioelectronics and Information Technology (USBREIT). — IEEE. 2024. — P. 204–207. — (0.25 п.л. / 0.175 п.л.) (Scopus).
- A3. *Markov N., Ushenin K., Bozhko Y., Solovyova O.* Compressor-Based Classification for Atrial Fibrillation Detection [Текст] // IEEE Ural-Siberian Conference on Computational Technologies in Cognitive Science, Genomics and Biomedicine (CSGB). — IEEE. 2023. — P. 122–127. — (0.375 п.л. / 0.325 п.л.) (Scopus).
- A4. *Markov N., Ushenin K., Bozhko Y.* A Convolutional Recurrent Model for the Identification of Patients with Atrial Fibrillation Based on Heart Rate Variability Data During Sinus Rhythm [Текст] // IEEE Ural-Siberian Conference on Biomedical Engineering, Radioelectronics and Information Technology (USBREIT). — IEEE. 2023. — P. 072–075. — (0.25 п.л. / 0.2 п.л.) (Scopus).

- A5. *Markov N., Kotov I., Ushenin K., Bozhko Y.* Statistical model for describing heart rate variability in normal rhythm and atrial fibrillation [Текст] // IEEE Ural-Siberian Conference on Computational Technologies in Cognitive Science, Genomics and Biomedicine (CSGB). — IEEE. 2022. — P. 130–133. — (0.25 п.л. / 0.125 п.л.) (Scopus).
- A6. *Архипов М.В., Марков Н.С., Божко Я.Г., Ушенин К.С., Соловьёва О.Э.* Имеет ли смысл изучение вариабельности сердечного ритма при пароксизмальной форме фибрилляции предсердий во время регистрации эпизода аритмии в структуре записи суточного мониторингирования электрокардиограммы? [Текст] // Российский кардиологический журнал. — 2022. — Т. 27, № 7. — С. 26–36. — (0.6875 п.л. / 0.5 п.л.) (Scopus).
- A7. *Марков Н.С., Божко Я.Г., Ушенин К.С., Архипов М.В., Соловьёва О.Э.* Выделение фенотипов пароксизмальной формы фибрилляции предсердий на основе характеристик вариабельности сердечного ритма [Текст] / Н. С. Марков [и др.] // Казанский медицинский журнал. — 2021. — Т. 102, № 5. — С. 778–787. — (0.625 п.л. / 0.325 п.л.) (Scopus).
- A8. *Markov N., Ushenin K., Bozhko Y., Arkhipov M., Solovyova O.* Heart Rate Variability Reveals Two Phenotypes of Atrial Fibrillation [Текст] / N. Markov [et al.] // IEEE Ural-Siberian Conference on Computational Technologies in Cognitive Science, Genomics and Biomedicine (CSGB). — IEEE. 2021. — 460–463 (Scopus). — (0.25 п.л. / 0.125 п.л.) (Scopus).

Зарегистрированные программы для ЭВМ

- A9. *Марков Н.С., Соловьёва О.Э.* Свидетельство о гос. регистрации программы для ЭВМ. Cardiac rhythmogram compression for detection of atrial fibrillation [Текст] / И. иммунологии и физиологии Уральско-го отделения Российской академии наук. — № 2024618859 ; заявл. 12.04.2024 ; опубл. 17.04.2024, 2024617609 (Рос. Федерация).

Список литературы

1. *Филатов, А. Г.* Эпидемиология и социальная значимость фибрилляции предсердий [Текст] / А. Г. Филатов, Э. Г. Тарашвили // Анналы аритмологии. — 2012. — Т. 9, № 2. — С. 5–13.
2. Beat to beat variability in cardiovascular variables: noise or music? [Текст] / M. L. Appel [et al.] // Journal of the American College of Cardiology. — 1989. — Vol. 14, no. 5. — P. 1139–1148.

3. Can Wearable Devices Accurately Measure Heart Rate Variability? A Systematic Review [Текст] / K. Georgiou [et al.] // *Folia Medica*. — 2018. — Vol. 60, no. 1. — P. 7–20.
4. Бавеский, Р. М. Вариабельность сердечного ритма: теоретические аспекты и возможности клинического применения [Текст] / Р. М. Бавеский, Г. Г. Иванов // *Ультразвуковая и функциональная диагностика*. — 2001. — № 3. — С. 108–127.
5. Larburu, N. Comparative study of algorithms for Atrial Fibrillation detection [Текст] / N. Larburu, T. Lopetegi, I. Romero // 2011 Computing in Cardiology. — IEEE. 2011. — P. 265–268.
6. A Review on the State of the Art in Atrial Fibrillation Detection Enabled by Machine Learning [Текст] / A. Rizwan [et al.] // *IEEE Reviews in Biomedical Engineering*. — 2020. — Vol. 14. — P. 219–239.
7. “Low-Resource” Text Classification: A Parameter-Free Classification Method with Compressors [Текст] / Z. Jiang [et al.] // *Findings of the Association for Computational Linguistics: ACL 2023*. — 2023. — P. 6810–6828.
8. An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction [Текст] / Z. I. Attia [et al.] // *The Lancet*. — 2019. — Vol. 394, no. 10201. — P. 861–867.
9. Ventricular response in atrial fibrillation: random or deterministic? [Текст] / K. M. Stein [et al.] // *American Journal of Physiology-Heart and Circulatory Physiology*. — 1999. — Vol. 277, no. 2. — H452–H458.
10. Tatenno, K. Automatic detection of atrial fibrillation using the coefficient of variation and density histograms of RR and Δ RR intervals [Текст] / K. Tatenno, L. Glass // *Medical and Biological Engineering and Computing*. — 2001. — Vol. 39. — P. 664–671.
11. PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals [Текст] / A. L. Goldberger [et al.] // *Circulation*. — 2000. — Vol. 101, no. 23. — e215–e220.
12. Andersen, R. S. A novel approach for automatic detection of Atrial Fibrillation based on Inter Beat Intervals and Support Vector Machine [Текст] / R. S. Andersen, E. S. Poulsen, S. Puthusserypady // 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). — IEEE. 2017. — P. 2039–2042.
13. Few-shot transfer learning for personalized atrial fibrillation detection using patient-based siamese network with single-lead ECG records [Текст] / Y. Ng [et al.] // *Artificial Intelligence in Medicine*. — 2023. — Vol. 144. — e102644.