

УДК 004.93'11, 004.032.26

АВТОМАТИЧЕСКАЯ ДИАГНОСТИКА СЕРДЕЧНОЙ АРИТМИИ ВО ВСТРОЕННЫХ СИСТЕМАХ



В.А. Реджепов

Аспирант кафедры электронных
вычислительных машин, БГУИР
vladimir.redzhepov@gmail.com



Д.Ю. Перцев

Доцент кафедры электронных
вычислительных машин, БГУИР,
кандидат технических наук,
доцент
pertsev@bsuir.by

В.А. Реджепов

Окончил Белорусский государственный университет информатики и радиоэлектроники. Область научных интересов связана с разработкой методов и алгоритмов цифровой обработки сигналов и изображений.

Д.Ю. Перцев

Окончил аспирантуру Белорусского государственного университета информатики и радиоэлектроники (2016), защитил диссертацию в совете 05.13.01 (2020). Область научных интересов связана с разработкой методов и алгоритмов в системах технического зрения.

Аннотация. Техническое развитие носимых устройств привело к появлению простых и компактных встраиваемых систем мониторинга ЭКГ. При этом анализ результата является одним из ключевых показателей эффективности для коммерческих систем мониторинга. Это связано с тем, что классификация, как один из элементов анализа, позволяет идентифицировать аномальный сигнал ЭКГ и, следовательно, предложить соответствующее лечение. Поскольку для этого необходимы вычислительные мощности, обычно рассматривается клиент-серверный подход. Это означает, что встраиваемая система является лишь системой записи и хранения данных в традиционной системе мониторинга ЭКГ. Однако для обеспечения диагностики в режиме реального времени была введена необходимость классификации ЭКГ во встроженных системах. В данной статье рассматриваются существующие методы автоматической диагностики сердечных аритмий и предлагается решение для идентификации сердечной аритмии во встроженных системах.

Ключевые слова: ЭКГ, сердечная аритмия, цифровая обработка сигнала, фильтрация, реальное время, машинное обучение, классификация, *TinyML*, встроженные системы.

Введение. Сердечно-сосудистые заболевания (ССЗ) являются основной причиной смерти во всем мире, от которой по оценкам каждый год умирает 17,9 млн. человек. ССЗ представляют собой группу болезней сердца и кровеносных сосудов, в которую входят ишемическая болезнь сердца, заболевания сосудов головного мозга, ревматическая болезнь сердца и другие патологии. Более четырех из пяти смертей от ССЗ происходит в результате инфаркта и инсульта, причем треть из этих случаев смерти носит преждевременный характер и отмечается среди людей в возрасте до 70 лет [1]. В диагностике ССЗ важное место занимает мониторинг электрокардиограммы (ЭКГ) на наличие аритмий.

Сердечная аритмия – патологическое состояние, приводящее к нарушению частоты, ритмичности и последовательности возбуждения и сокращения сердечной мышцы –

миокарда. Аритмия – любой ритм сердца, отличающийся от нормального синусового ритма. При таком патологическом состоянии может существенно нарушаться нормальная сократительная активность сердца, что, в свою очередь, может привести к целому ряду серьёзных осложнений. Правильным, или регулярным, является синусовый ритм, который в пределах наблюдения задаётся только активностью синусового узла, правильный ритм которого принято называть “нормальным синусовым ритмом”, если он попадает в диапазон 60-90 ударов в минуту. Небольшие колебания периода сердечных сокращений, менее 0,1 секунды, считаются нормальной (физиологической) синусовой аритмией, связанной с естественной вариабельностью ритма сердца; их не считают патологическим нарушением. Отклонения от нормального состояния считаются нарушением, то есть аритмиями. Термин «аритмия» объединяет различные по механизму, клиническим проявлениям и прогностическому значению нарушения образования и проведения электрического импульса [2].

Для увеличения вероятности обнаружения аритмий необходимо проводить анализ суточной записи ЭКГ. Исследование представляет собой непрерывную регистрацию электрокардиограммы в течение 24 часов и более (48, 72 часа, иногда до 7 суток). Запись ЭКГ осуществляется при помощи специального портативного аппарата – рекордера (регистратора), который пациент носит с собой (на ремне через плечо или на поясе) [3]. Данный подход требует, чтобы устройство содержало достаточный объем памяти для хранения записей ЭКГ. Затем записанные данные передаются на сервер, где осуществляется их предварительная обработка и классификация автоматическими методами или медицинским персоналом. В таком случае пациент узнает о результатах исследования только после анализа записей [4]. Классификация, осуществляемая встроенной системой, позволяет получить предупреждение, что в сигнале ЭКГ есть аномалии в режиме реального времени. Портативные системы данного класса, как правило, не обладают большими объемами памяти и предполагают применение специальных методов, позволяющих использовать ограниченные ресурсы вычислительной системы. В последнее время стало возможно использовать технологии машинного обучения (ML) во встраиваемых системах на базе микроконтроллеров с низким энергопотреблением. Данный подход позволяет обучить модель на вычислительном кластере, а затем интегрировать ее во встроенную систему.

Классификация образов и диагностические решения. Конечной целью анализа биомедицинских сигналов является классификация данного сигнала с целью отнесения его к одной из нескольких известных категорий и получение диагностического решения, относящегося к состоянию пациента. Врач или медицинский специалист может достигнуть этой цели путём визуального или слухового анализа представленного сигнала: ему оказывает помощь сравнительный анализ данного сигнала с другими, для которых известны диагностические заключения. Кроме того, специалисты используют общепринятые протоколы и наборы правил. Существенную роль в этом процессе играют базовые знания, клинический опыт, квалификация и интуиция врача. Некоторые виды измерений, которые могут быть сделаны по данному сигналу, также могут оказать помощь в его анализе. Например, врач может измерить по графику ЭКГ ширину QRS-комплекса.

Когда анализ сигнала выполняется с использованием компьютерных алгоритмов, типичным результатом является получение некоторого набора численных параметров. Когда численные параметры относятся непосредственно к характеристикам сигнала, таким как ширина QRS-комплекса или длительность RR-интервала в сигнале ЭКГ, клинический специалист имеет возможность использовать эти параметры в логике принятия диагностических решений. Однако, когда вычисляются такие параметры, как коэффициенты авторегрессионной (AR) модели или спектральные статистики, аналитик вряд ли окажется в состоянии понять и использовать их. Более того, по мере увеличения числа рассчитываем

ых компьютером параметров связанная с ними диагностическая логика становится слишком сложной и неприемлемой для анализа, выполняемого человеком. В таких случаях желательно, чтобы процессы классификации и принятия решений могли выполняться компьютером.

Прежде всего, необходимо иметь в виду, что биомедицинские сигналы являются лишь одним из источников информации для постановки диагноза: классификация данного сигнала с точки зрения его принадлежности к одной из многочисленных категорий может помочь в процедуре диагностики, но почти никогда не является единственным фактором. Тем не менее, классификация образов, основанная на анализе сигнала, действительно является важным аспектом анализа биомедицинских сигналов [5].

Базы данных для обучения алгоритмов. Согласно последним исследованиям [6], для отработки точности алгоритма, проверки и обучения систем искусственного интеллекта существует ряд международных открыто публикуемых баз данных электрокардиографических сигналов:

- *PTB Diagnostic ECG Database*;
- *MIT-BIH Arrhythmia Database*;
- *St Petersburg INCART 12-lead Arrhythmia Database*;
- *MIT-BIH Supraventricular Arrhythmia Database*;
- *AHA Database*;
- *UofT ECG database*;
- *Telemetric and Holter ECG Warehouse (THEW)*;
- *PHYSIOBC*.

PTB Diagnostic ECG Database состоит из 549 записей, полученных от 290 пациентов. Возраст составляет от 17 до 87 лет, что дает подробную информацию на уровне пациента, в том числе возраст, пол, диагноз, положительный медицинский анамнез, лекарства, предыдущие операции, наличие ишемической болезни сердца или любого другого сердечного заболевания. В этой базе данных используются ЭКГ с 12 отведениями и отведения Франка (x , y и z). Разрешение составляет 16 бит, 17 каналов (15 для ЭКГ, 1 для дыхания и 1 для линии напряжения), максимальное напряжение шума 10 мкВ [7].

MIT-BIH Arrhythmia Database находится в ведении Отделения медицинских наук и технологий Массачусетского технологического института в Центре биомедицинской инженерии. Он состоит из 48 получасовых записей, каждая из которых была получена от 47 пациентов в период с 1975 по 1979 год. Эти записи были оцифрованы с использованием 360 отсчетов в секунду на канал с разрешением 11 бит и диапазоном 10 мВ. Данные, содержащиеся в каждом долье пациента, включают дату регистрации, возраст, пол и назначенные лекарства [8].

St Petersburg INCART 12-lead Arrhythmia Database состоит из 75 записей электрокардиографии, извлеченных из 32 записей Холтера, которые представляют в общей сложности 32 пациента (17 мужчин и 15 женщин) в возрасте от 18 до 80 лет и средним возрастом 58 лет. Ни у одного из пациентов нет имплантированного кардиостимулятора, но у них есть различные проблемы с сердцем, включая ишемию миокарда, ишемическую болезнь сердца, нарушения проводимости и аритмии. Были использованы ЭКГ с 12 отведениями с частотой дискретизации 257 выборок в секунду и продолжительностью 30 минут [9].

MIT-BIH Supraventricular Arrhythmia Database была получена в больнице *MIT-Beth Israel Hospital (MIT-BIH)* и содержит 78 записей ЭКГ продолжительностью полчаса, выбранных в качестве примеров наджелудочковых аритмий. Записи были получены между 1990 и 1992 годами, с последующими аннотациями в 1999, 2010 и 2012 годах. В качестве методологии использовалась система *HOBBS (Hypothetical Obliterated Beat Sequences)* [10].

AHA Database доступна только на веб-сайте Научно-исследовательского института неотложной помощи (*ECRI Institute*) в виде запрошенного *DVD* вместе с оплатой пошлины. Включает 154 записи, разделенных на 8 типов аритмий: *Non-PVCs*, *Uniformly Isolated PVCs*, *Isolated Multiform PVCs*, *Bigeminus*, *R-T beats*, *Couplets*, желудочковые ритмы, фибрилляция желудочков или трепетание желудочков. Каждая запись *ЭКГ* (одна на пациента) длится в общей сложности 3 часа, разделенных на периоды не менее 30 минут, каждый для классификации сердечных сокращений. Информация была оцифрована в двух каналах *ЭКГ* с частотой 250 отсчетов в секунду и точностью 12 бит [11].

UofT ECG database состоит из выборки из 1020 пациентов, у которых *ЭКГ* в одном отведении была записана в течение 2-5 минут. Измерения проводились в различных позах тела (стоя, сидя, на треноге и лежа на спине) вместе с физическими упражнениями. Подгруппа из 43 пациентов посетила 6 сеансов записи *ЭКГ* в течение 6 месяцев. Отведения помещали на ладони и пальцы, получая отведение *DI* [12].

THEW – это организация, обслуживаемая Программой наблюдения за сердечно-сосудистыми исследованиями в Медицинском центре Университета Рочестера, проект начался в 2008 году. Он содержит более 3700 оцифрованных сигналов *ЭКГ*, в основном полученные через 24 часа холтеровского мониторинга. Эти записи *ЭКГ* являются частью 13 независимых исследований, которые доступны только участникам. В одном из исследований пациентов с острым инфарктом миокарда участвовало 90 пациентов со 160 записями, которые были взяты из 3 квазиортогональных отведений. Частота дискретизации составляет 200 отсчетов в секунду с амплитудой 10 мкВ [13].

База *PHYSIOBC* разработана в Мексике. Она состоит из записей для 91 пациента и всего содержит 182 записей; возраст пациентов был от 18 до 70 лет. Частота выборки для *ЭКГ* с 12 отведениями составляет 1000 выборок в секунду, а для *ЭКГ* Франка – 500 выборок в секунду. Продолжительность записи составляет от 2 до 5 минут на пациента [14].

Методы распознавания аритмий. Исторически распознавание аритмии проводилось стандартными методами логического и математического анализа цифровых сигналов *ЭКГ*. Однако с развитием машинного обучения задача по распознаванию определенной формы сигнала сердца может быть рассмотрена как классическая задача распознавания образов. Методы анализа аритмий можно разделить на три группы (рисунок 1) [15].



Рисунок 1. Классификация алгоритмов распознавания аритмий

В свою очередь, можно выделить основные этапы обработки данных алгоритмами из представленных групп (рисунок 2).




Рисунок 2. Этапы работы алгоритмов распознавания аритмий: *а* – классические алгоритмы без обучения; *б* – алгоритмы машинного обучения; *в* – алгоритмы глубокого машинного обучения

Общий подход к предварительной обработке данных. ЭКГ является относительно «сильным» сигналом с легко различимыми волнами. Большинство типов помех, которые воздействуют на сигнал ЭКГ, могут быть устранены с помощью полосовых фильтров [5]. Этот шаг предварительной обработки делает сигнал ЭКГ пригодным для последующих процессов. Наиболее распространенные методы, используемые для уменьшения помех, следующие:

- низкочастотные и высокочастотные фильтры Баттерворта;
- вейвлеты Добеши;
- ортогональные вейвлет-фильтры.

Также анализ сигнала для мониторингового наблюдения или диагностики требует идентификации эпох и исследования соответствующих событий. После того, как было идентифицировано какое-либо событие, осуществляется сегментация и анализ соответствующей волны сигнала с использованием таких характеристик, как амплитуда, форма волны (морфология), длительность, интервалы между событиями, распределение энергии, частотное содержание и т. д. Форма и амплитуда QRS-комплекса, как наиболее значимые параметры ЭКГ, являются предметом исследования при любой диагностике и анализе биений сердца. Пан и Томпкинс (*Pan and Tompkins*) [16, 17] предложили алгоритм обнаружения QRS-комплексов, рассчитанный на работу в режиме реального времени и основанный на анализе наклона, амплитуды и ширины QRS-комплекса.

Общий подход к распознаванию и классификации образов. Распознавание или классификацию образов можно определить, как отнесение входных данных к какому-либо из идентифицируемых классов посредством дифференциации существенных признаков или атрибутов данных от фонового сигнала и от деталей, не относящихся к изучаемому явлению. После того, как из сигнала были получены количественные признаки, он может

быть представлен вектором признаков $x = (x_1, x_2, \dots, x_n)^T$, известным также как вектор параметров или вектор образца. Когда величины x_i являются вещественными числами, вектор x представляет собой точку в n -мерном евклидовом пространстве. Ожидается, что векторы сходных объектов формируют кластеры.

Для эффективной классификации образов необходимы такие признаки, которые могут дать непересекающиеся наборы или кластеры для векторов параметров. Это обстоятельство подчеркивает важность правильного выбора процедур предварительной обработки и выделения признаков. Признаки или свойства, являющиеся общими для всех образцов, принадлежащих к определенному классу, известны как внутрикласовые признаки. Дискриминирующие признаки, которые характеризуют различия между классами образов, называются межклассовыми признаками.

Проблема классификации образов заключается в определении разделяющих границ или разработке решающих процедур, для отнесения данных к различным классам образов, основанных на векторах признаков [5].

Выделение признаков. Выделение признаков представляет собой интерактивный процесс, включающий ряд автоматических процедур преобразования данных. При большом количестве измерений-признаков, описывающих характеристики входного сигнала, для сокращения размерности задачи применяется корреляционный и факторный анализ данных. По методу извлечения и методу анализа, признаки можно разделить на следующие категории:

Временные и морфологические признаки. Эти признаки описаны во временной области и представляют из себя амплитуду, наклон и частоту сердечных сокращений (ЧСС). Наиболее частыми характеристиками являются *интервал пересечения порога (TCI)* [18], количество отсчетов пересечения порога (TCSC) [19], *среднее абсолютное значение (MAV)* [20], *стандартная экспонента (STE)* и *модифицированная экспонента (MEA)* [21].

Спектральные признаки. Эти признаки определены в частотной области. Они могут учитывать плотность спектра, нормированные спектральные моменты, которые характеризуют распределение точек спектра, и соответствующая информация о мощности спектра в разных диапазонах частот. Эти алгоритмы экстракции признаков включают *утечку фильтра VF (VFleak)* [22], спектральный алгоритм [23] и алгоритм *медианной частоты (MF)* [24]. *VFleak* – это функция отклика узкополосного полосового фильтра, которая определяет среднюю частотную область сегмента ЭКГ и его выход – утечку фильтра *VF*. Спектральный алгоритм вычисляет информацию о мощности и энергии по разным частотным диапазонам с использованием Фурье-анализа. *Медианная частота* – это центральная частота на распределении частот, найденных в заданном сегменте ЭКГ.

Выбор признаков. Этот шаг позволяет удалить избыточные функции, снизить вычислительные затраты и улучшить общую производительность системы. На этом этапе используются три основные категории методов выбора признаков:

1 Методы оболочки: считаются лучшим подходом для выбора признаков с точки зрения точности, но обладают значительной вычислительной сложностью [25]. В этих методах используется перекрестная проверка путем многократного обучения модели с использованием различных признаков и сравнение результатов. Распространены следующие методы:

- рекурсивное исключение признаков;
- прямой выбор признаков;
- генетические алгоритмы;

2 Методы фильтры: этот подход использует статистические измерения для выбора наилучшего набора характеристик перед процессом обучения. Здесь функция оценивается по методу прокси, а не по точности перекрестной проверки. Используются следующие методы:

- корреляция;
- хи-квадрат;
- дисперсионный анализ;
- ReliefF*;

3 Встроенные методы: данный подход включает методы, которые не подпадают под вышеупомянутые подходы (оболочка или фильтр). *L1*-регуляризация является примером такого метода.

Снижение признаков. На данном этапе выполняется уменьшение числа признаков набора данных. Многие из методов снижения признаков преобразуют выбранные признаки в пространства с пониженной размерностью. Анализ главных компонент, линейный дискриминантный анализ и локально-чувствительный дискриминантный анализ являются примерами методов снижения признаков.

Классификация. Классификация – это основной блок распознавания для решаемой задачи, хотя отдельные процедуры распознавания могут присутствовать и на этапе выделения признаков, и на этапе постклассификационной обработки. Но именно результат, полученный на этапе классификации, является основой для интерпретации сигнала ЭКГ как шокового или нешокового. Процесс классификации может осуществляться в несколько этапов или в несколько итераций, в зависимости от выбранной схемы распознавания. В ряде случаев результаты, полученные на данном этапе, требуют пересмотра всей схемы обработки в целом. Наиболее распространены методы классификации *метод опорных векторов (SVM)*, *наивный баесовский классификатор*, *метод анализа k-ближних соседей (k-NN)*, *деревья решений (DT)*.

Методы глубокого машинного обучения. В последние годы применение глубоких нейронных сетей, вызвали большой интерес в компьютерной диагностике практически всех заболеваний [26; 27]. В зависимости от архитектуры сети глубокого обучения подразделяются на различные классы, такие как полностью связанные сети, сети убеждений и сверточные сети. Одним из основных преимуществ такого подхода является то, что они выполняют извлечение признаков автоматически. Наиболее распространенные архитектуры, используемые в сигнале ЭКГ, – это *сверточная нейронная сеть (CNN)* и *рекуррентная нейронная сеть (RNN)*.

Создание модели. Для создания модели используется база данных ЭКГ *MIT-BIH Arrhythmia Database* [8]. Источником данных ЭКГ, включенных в эту базу аритмий, является набор из более чем 4000 долговременных записей Холтера, которые были получены лабораторией аритмии в больнице Бет Исраэль в период с 1975 по 1979 год. Примерно 60% этих записей были получены от пациентов, находящихся в стационаре. База данных содержит 23 записи (группа 1), выбранные случайным образом из этого набора, и 25 записей (группа 2), выбранные из того же набора для включения разновидности редких, но клинически важных явлений, которые не могут быть хорошо представлены небольшой случайной выборкой записей Холтера. Каждая из 48 записей длится чуть более 30 минут.

Первая группа записей призвана служить репрезентативной выборкой различных форм сигналов и артефактов, с которыми детектор аритмии может столкнуться при обычном клиническом использовании. Ленты с записями отбирались случайным образом для выделения из них получасовых отрезков. Выбранные таким образом сегменты исключались только в том случае, если ни один из двух сигналов ЭКГ не имел достаточного качества для анализа людьми-экспертами.

Записи во второй группе были выбраны для включения сложных желудочковых, узловых и наджелудочковых аритмий и нарушений проводимости. Некоторые из этих записей были выбраны потому, что особенности ритма, вариаций морфологии *QRS* или

качества сигнала могут представлять значительные трудности для детекторов аритмии; эти записи приобрели значительную известность среди пользователей баз данных.

Испытуемыми были 25 мужчин в возрасте от 32 до 89 лет и 22 женщины в возрасте от 23 до 89 лет.

Для работы с записями базы данных используется фреймворк *wfdb-python* [28], который позволяет считывать записи (рисунок 3) и работать с ними как с массивами данных.




Рисунок 3. Вид сигнала ЭКГ одной из записей базы данных

Первым шагом в подготовке данных является извлечение *RR-интервалов* из записей базы данных для определения *вариабельности сердечного ритма (BCP)*, где *R* – точка, соответствующая пику комплекса *QRS* волны ЭКГ и *R-R* – интервал между последовательными *R* (рисунок 4).




Рисунок 4. Представление *QRS*-комплекса и *RR*-интервала на ЭКГ

После обработки всех записей получается массив данных, который содержит все *RR* интервалы из базы данных. Полученные интервалы разбиваются на сегменты по 10 записей в каждом и определяется количество аномальных ударов. Затем эти данные разделяются на две подгруппы, одна из которых будет использоваться для обучения, а вторая – для проверки работоспособности обученной модели. Метки, присутствующие в

записях, позволяют однозначно определить класс обнаруженного события. Для обучения модели используется фреймворк *TensorFlow* [29]. Результаты обучения модели [30] представлены на рисунке 5.




Рисунок 5. Точность обучения и проверки модели

Заключение. Рассмотрены методы автоматического анализа ЭКГ с целью получения предупреждения, что в сигнале ЭКГ есть аномалии. На примере тестового набора из *MIT-BIH Arrhythmia Database* оценена точность работы модели [30]. Достигнутая точность составила 92%. Полученную модель планируется использовать во встроенной системе совместно с фреймворком *TinyML* [31] для анализа сигнала ЭКГ в режиме реального времени на наличие аритмии.

Список литературы

- [1] Cardiovascular diseases [Электронный ресурс] / World Health organization. – Режим доступа: https://www.who.int/health-topics/cardiovascular-diseases#tab=tab_1. – Дата доступа: 11.02.2024.
- [2] Аритмия сердца [Электронный ресурс] / Wikipedia. – Режим доступа: https://ru.wikipedia.org/wiki/Аритмия_сердца. – Дата доступа: 11.02.2024.
- [3] Суточное мониторирование ЭКГ [Электронный ресурс] / Wikipedia. – Режим доступа: https://ru.wikipedia.org/wiki/Суточное_мониторирование_ЭКГ. – Дата доступа: 11.02.2024.
- [4] Kennedy H. The Evolution of Ambulatory ECG Monitoring / H. Kennedy // *Progress in Cardiovascular Diseases*. – 2013. – Vol. 56. – No. 2. – P. 127-132.
- [5] Рангайян Р.М. Анализ биомедицинских сигналов. Практический подход / Пер. с англ. под ред. А.П. Немирко. – М.: ФИЗМАЛИТ, 2010. – 440 с.
- [6] Flores N. Readily available ECG databases / N. Flores, R.L. Avitia, M.A. Reyna, C. Garcí // *Journal of Electrocardiology*. – 2018. – Volume 51. – P.1095-1097. – DOI: 10.1016/j.jelectrocard.2018.09.012.
- [7] PTB Diagnostic ECG Database [Электронный ресурс] / PhysioNet. – Режим доступа: <https://www.physionet.org/content/ptbdb/1.0.0/>. – Дата доступа: 11.02.2024.
- [8] MIT-BIH Arrhythmia Database [Электронный ресурс] / PhysioNet. – Режим доступа: <https://www.physionet.org/content/mitdb/1.0.0/>. – Дата доступа: 11.02.2024.
- [9] St Petersburg INCART 12-lead Arrhythmia Database [Электронный ресурс] / PhysioNet. – Режим доступа: <https://physionet.org/content/incartdb/1.0.0/>. – Дата доступа: 11.02.2024.
- [10] MIT-BIH Supraventricular Arrhythmia Database [Электронный ресурс] / PhysioNet. – Режим доступа: <https://physionet.org/content/svdb/1.0.0/>. – Дата доступа: 11.02.2024.

- [11] АНА Database [Электронный ресурс] / ECRI. Режим доступа: <https://www.ecri.org/>. – Дата доступа: 11.02.2024.
- [12] UofT ECG Database [Электронный ресурс] / BioSec.lab. – Режим доступа: <https://www.comm.utoronto.ca/~biometrics/databases.html>. – Дата доступа: 11.02.2024.
- [13] Telemetric and Holter ECG Warehouse [Электронный ресурс] / THEW. – Режим доступа: <http://thew-project.org/>. – Дата доступа: 11.02.2024.
- [14] PHYSIOBC [Электронный ресурс] / physiobc.org. – Режим доступа: <http://www.physiobc.org/>. – Дата доступа: 11.02.2024.
- [15] Липчак Д.А. Обзор методов автоматической диагностики сердечной аритмии для принятия решений о необходимости проведения дефибрилляции / Д.А. Липчак, А.А. Чупов // *Ural Radio Engineering Journal*. – 2021. – №5(4). – С.380-409. – DOI: 10.15826/urej.2021.5.4.004.
- [16] Pan J. A Real-Time QRS Detection Algorithm / J. Pan, W.J. Tompkins // *IEEE Transactions on Biomedical Engineering*. – 1985. – P. 230-236.
- [17] Clifford G.D. Signal processing methods for heart rate variability analysis. PhD Thesis. Michaelmas Term. 2002. 244 p.
- [18] Thakor N.V. Ventricular Tachycardia and fibrillation detection by a sequential hypothesis testing algorithm / N.V. Thakor, Y.S. Zhu, K.Y. Pan // *IEEE Transactions on Biomedical Engineering*. – 1990. – №37(9). – P.837-843. – DOI:10.1109/10.58594.
- [19] Arafat M.A. A simple time domain algorithm for the detection of ventricular fibrillation in electrocardiogram / M.A. Arafat, A.W. Chowdhury, M.K. Hasan // *Signal, Image and Video Processing*. – 2011. – №5(1). – P.1-10. – DOI: 10.1007/s11760-009-0136-1.
- [20] Anas E. Sequential algorithm for life threatening cardiac pathologies detection based on mean signal strength and EMD functions / E. Anas, S.Y. Lee, M.K. Hasan // *BioMedical Engineering OnLine*. – 2010. – №9(1). – DOI:10.1186/1475-925X-9-43.
- [21] Amann A. Reliability of old and new ventricular fibrillation detection algorithms for automated external defibrillators / A. Amann, R. Tratnig, K. Unterkofler // *BioMedical Engineering OnLine*. – 2005. – №4:60. – DOI: 10.1186/1475-925X-4-60.
- [22] Granitto P. M. Recursive feature elimination with random forest for PTR-MS analysis of agroindustrial products / P.M. Granitto, [etc.] // *Chemometrics and Intelligent Laboratory Systems*. – 2006. – №83(2). – P.83-90. – DOI: 10.1016/j.chemolab.2006.01.007.
- [23] Barro S. Algorithmic sequential decision-making in the frequency domain for life threatening ventricular arrhythmias and imitative artefacts: a diagnostic system / S. Barro, [etc.] // *Journal of Biomedical Engineering*. – 1989. – №11(4). – P.320-328. – DOI: 10.1016/0141-5425(89)90067-8.
- [24] Pławiak P. Novel genetic ensembles of classifiers applied to myocardium dysfunction recognition based on ECG signals / P. Pławiak // *Swarm and Evolutionary Computation*. – 2018. – №39. – P.192-208. – DOI: 10.1016/j.swevo.2017.10.002.
- [25] Blum A.L. Selection of relevant features and examples in machine learning / A.L. Blum, P. Langley // *Artificial Intelligence*. – 1997. – №97(1-2). – P.245-271. – DOI:10.1016/S0004-3702(97)00063-5.
- [26] Miotto R. Deep learning for healthcare: Review, opportunities and challenges / R. Miotto, [etc.] // *Briefings in Bioinformatics*. – 2018. – №19(6). – P.1236-1246. – DOI: 10.1093/bib/bbx044.
- [27] Esteva A. A guide to deep learning in healthcare / A. Esteva, [etc.] // *Nature Medicine*. – 2019. – №25(1). – P.24-29. – DOI: 10.1038/s41591-018-0316-z.
- [28] WFDB-python [Электронный ресурс] / Native Python WFDB package. – Режим доступа: <https://github.com/MIT-LCP/wfdb-python>. – Дата доступа: 11.02.2024.
- [29] TensorFlow [Электронный ресурс] / An end-to-end machine learning platform. – Режим доступа: <https://www.tensorflow.org/>. – Дата доступа: 11.02.2024.
- [30] TinyRhythmAnalyzer [Электронный ресурс] // TinyML-powered ECG arrhythmia detection on Arduino Nano 33 BLE Sense. – Режим доступа: <https://github.com/tonyfu97/TinyRhythmAnalyzer/tree/main/model>. – Дата доступа: 11.02.2024.
- [31] TinyML [Электронный ресурс] // tinyML Foundation. – Режим доступа: <https://www.tinyml.org/>. – Дата доступа: 11.02.2024.

Авторский вклад

Реджепов Владимир Александрович – описание методов автоматической диагностики аритмии, тестирование модели нейронной сети, формирование структуры статьи.

Перцев Дмитрий Юрьевич – руководство исследованием, анализ полученных результатов.

AUTOMATIC DIAGNOSTICS OF CARDIAC ARRHYTHMIA IN EMBEDDED SYSTEMS

V. Redzhepov

Post-graduate student,

*Department of Electronic Computing Machines
of BSUIR*

D. Pertsau

Associate Professor, PhD,

*Department of Electronic Computing Machines
of BSUIR*

Abstract. The technological development of wearable devices has led to the emergence of simple and compact embedded ECG monitoring systems. At the same time, result analysis is one of the key performance indicators for commercial monitoring systems. This is because classification, as one element of the analysis, makes it possible to identify an abnormal ECG signal and therefore propose appropriate treatment. Since this requires computing power, a client-server approach is usually considered. This means that the embedded system is only a data recording and storage system in a traditional ECG monitoring system. However, to enable real-time diagnosis, the need for ECG classification in embedded systems has been introduced. This paper reviews existing methods for automatic diagnosis of cardiac arrhythmias and proposes a solution for identifying cardiac arrhythmias in embedded systems.

Keywords: ECG, arrhythmia, digital signal processing, real time, machine learning, classification, TinyML, embedded systems.