

(19)



**Евразийское
патентное
ведомство**

(11) **041365**(13) **B1**

(12) ОПИСАНИЕ ИЗОБРЕТЕНИЯ К ЕВРАЗИЙСКОМУ ПАТЕНТУ

(45) Дата публикации и выдачи патента
2022.10.17

(21) Номер заявки
202092258

(22) Дата подачи заявки
2020.10.21

(51) Int. Cl. **A61B 5/24 (2021.01)**
A61B 5/318 (2021.01)

(54) СПОСОБ И СИСТЕМА АВТОМАТИЧЕСКОГО АНАЛИЗА ЭКГ

(31) **2020124218**

(32) **2020.07.21**

(33) **RU**

(43) **2022.01.31**

(71)(73) Заявитель и патентовладелец:
**ПУБЛИЧНОЕ АКЦИОНЕРНОЕ
ОБЩЕСТВО "СБЕРБАНК
РОССИИ" (ПАО СБЕРБАНК) (RU)**

(72) Изобретатель:
**Егоров Константин Сергеевич,
Аветисян Манвел Согомонович,
Соколова Елена Владимировна (RU)**

(74) Представитель:
Герасин Б.В. (RU)

(56) **WO-A1-2019100566**
CN-A-105748063

U. RAJENDRA ACHARYA et al., "Automated Detection of Arrhythmias Using Different Intervals of Tachycardia ECG Segments with Convolutional Neural Network", Information Sciences, April 2017, 22 л., [онлайн] [найденно 01.07.2021]. Найденно в <https://www.researchgate.net/publication/315821873_Automated_Detection_of_Arrhythmias_Using_Different_Intervals_of_Tachycardia_ECG_Segments_with_Convolutional_Neural_Network>

JEN HONG TAN et al., "Application of stacked convolutional and long short-term memory network for accurate identification of CAD ECG signals", Computers in Biology and Medicine, January 2018, 20 л., [онлайн] [найденно 01.07.2021]. Найденно в <https://www.researchgate.net/publication/322213305_Application_of_stacked_convolutional_and_long_short-term_memory_network_for_accurate_identification_of_CAD_ECG_signals>

(57) Изобретение относится к компьютерно реализуемым способам автоматического анализа ЭКГ. Техническим результатом от реализации заявленного способа является повышение точности анализа ЭКГ. Указанный технический результат достигается благодаря осуществлению компьютерно реализуемого способа автоматического анализа ЭКГ, выполняемый с помощью по меньшей мере одного процессора и содержащий этапы, на которых получают сигнал ЭКГ по меньшей мере одного пациента; осуществляют обработку полученного сигнала с помощью первой модели машинного обучения (МО), причем в ходе указанной обработки осуществляется выделение временных координат QRS-комплексов сигнала; с помощью второй модели машинного обучения на базе классификационной свёрточной нейронной сети (CNN) осуществляют обработку отрезков сигнала заранее заданного размера, центрированных по положению QRS-комплекса на основании временных координат, выделенных первой моделью МО; формирование усредненного вектора сердечбиения QRS-комплекса; осуществляют классификацию данных сердечбиения пациента с помощью третьей модели МО с помощью обработки упомянутых временных координат QRS-комплексов сигнала, полученных первой моделью МО, и усредненного вектора сердечбиения QRS-комплекса, формируемого второй моделью МО.

B1**041365****041365****B1**

Область техники

Изобретение относится к автоматизированному способу и системе автоматического анализа электрокардиограммы (ЭКГ) с помощью алгоритмов машинного обучения.

Уровень техники

Холтеровское мониторирование - это длительная запись ЭКГ (24 ч и более), которая содержит большое количество ценной диагностической информации о пациенте. Интерпретация длительных сигналов является трудоемкой задачей для врача функциональной диагностики, который анализирует ЭКГ, потому что каждое сердцебиение должно быть классифицировано по отдельности.

Сердечно-сосудистые заболевания остаются основной причиной смерти во всем мире по данным Всемирной организации здравоохранения (ВОЗ) [1]. Своевременный скрининг и диагностика таких заболеваний могут значительно снизить вызываемую ими смертность и инвалидизацию населения.

Электрокардиограмма является одним из самых доступных и распространенных инструментов для записи сердечного ритма, который облегчает диагностику широкого спектра сердечных патологий. Учитывая тот факт, что нарушения сердечного ритма могут происходить нерегулярно, для выявления таких событий необходим мониторинг в течение длительного периода времени.

Записи холтеровского ЭКГ содержат сотни тысяч сердцебиений, и в идеале положение каждого из них должно быть точно определено и классифицироваться индивидуально. По этой причине кардиологи используют коммерческое программное обеспечение для кластеризации сердцебиений по внешнему виду и для их дальнейшей классификации, а затем вручную проверяют и корректируют результаты автоматической классификации.

Кардиолог проверяет каждый кластер и исправляет ошибки классификации, если это необходимо, как описано в статье [3]. Задача интерпретации долгосрочных записей Холтера остается сложной, что раскрыто в статье [15]. В одном исследовании автоматическая интерпретация сигналов ЭКГ выявила несинусовый ритм сердца только с точностью 53,5% [14]. Другое исследование [5] показало, что среди ЭКГ с автоматическим диагнозом мерцательной аритмии или трепетания предсердий диагноз был неверным почти в 10% случаев.

Почти в половине случаев ошибочный диагноз не был исправлен врачом, верифицирующим автоматический анализ. Клиническое влияние неверной интерпретации ЭКГ на основе существующего автоматического ПО также оценивалось в статье [6], где было продемонстрировано, что неправильный автоматический диагноз (АД) значительно влияет на точность интерпретации ЭКГ записи врачом. В частности, точность диагностики, достигнутая кардиологами-ординаторами, упала на 43,20%, когда им был показан неверный АД.

Автоматизированная интерпретация сигнала ЭКГ традиционно реализуется с помощью алгоритмов извлечения признаков (начало и смещение различных волн, измерения различных интервалов, параметров амплитуды и т.д.), а также решающими правилами, которые задаются экспертно. Чтобы повысить точность таких методов, к данной задаче был применен ряд алгоритмов машинного обучения. Эти методы позволили использовать более информативные признаки, например методы преобразования времени в частоту (например, вейвлет-преобразование) для извлечения признаков из сигналов переменной длины, как показано в статье [12]. Тем не менее, проблема автоматической интерпретации сигналов ЭКГ по-прежнему остается недостаточно изученной, несмотря на все усилия, описанные в статьях [4] и [2]. Кроме того, с появлением методов, основанных на глубоком обучении, возникли новые ожидания, что качество автоматической интерпретации ЭКГ с использованием современных глубоких нейронных сетей может быть сопоставимо с кардиологами [13].

В одной из таких работ [9] описывается, как многоступенчатая модель применялась к задаче детекции мерцательной аритмии. В частности, сигнал был разделен на 10-минутные сегменты, для которых было выполнено шумоподавление и частотный анализ с использованием вейвлет-преобразования. Кроме того, из спектрограмм с использованием CNN (сокращение от англ. Convolutional Neural Network - сверточная нейронная сеть) были извлечены признаки, в то время как BRNN (сокращение от англ. Bidirectional Recurrent Neural Network - двунаправленная рекуррентная нейронная сеть) с механизмом внимания использовались для детекции временных характеристик в извлеченных признаках, в результате чего последний классификационный слой вычисляет вероятность наличия мерцательной аритмии. Однако недостатком применения такой модели является склонность к переобучению, повышенная вычислительная сложность, возможность рассмотрения только одной патологии.

Еще одна работа по применению глубокого обучения к задаче интерпретации ЭКГ представлена в статье [10], где 34-слойная CNN превзошла кардиолога в обнаружении широкого спектра аритмий сердца, используя большой набор аннотированных данных и очень глубокую CNN. Такой подход имеет ряд недостатков. Во-первых, обучающий и тестовый наборы данных в статье [10] были сформированы таким образом, чтобы сделать их более сбалансированными, т.е. принимая на вход только 2 30-секундных окна для каждого пациента, таким образом, вероятно, делая метрику ложноположительных результатов неточной. Во-вторых, приведенная в статье модель работает с записями ЭКГ только с одним отведением.

Что касается проблемы шума в записях ЭКГ, то она изучается в статье [11]. Авторы определили 5 классов шума, упорядоченных по клиническому влиянию шума на клинические параметры, которые

должны быть измерены в ЭКГ. Были предложены различные измерения уровня шума, такие как отклонение базовой линии, помехи в линии электропередачи и стандартное отклонение шума. А также построена карта шума, которая характеризует временное распределение шума. В статье [11] показано, что уровень шума может быть чрезмерно высоким для автоматической или человеческой интерпретации сигналов ЭКГ.

Общим недостатком существующих решений в данной области является низкая точность определения клинической картины и отсутствие возможности анализа шумных данных.

Раскрытие изобретения

В заявленном изобретении предлагается новый подход к автоматическому анализу ЭКГ. В нем представлена архитектура CNN, которая позволяет получать одинаковые признаки для дальнейшей их классификации и сегментации, что позволяет применять ее при различном числе отведений и в условиях временного отсоединения одного или нескольких электродов. Кроме того, в данном решении используется модель сегментации и классификации ЭКГ (CNN + GBDT (сокращение от англ. Gradient Boosting Detection Tree - градиентный бустинг на решающих деревьях)), что позволяет модели учитывать не только локальные признаки QRS-комплекса - это желудочковый комплекс, который регистрируется во время возбуждения желудочков сердца, но и глобальные признаки, полученные при анализе всей записи целиком.

Эффективность данного решения подтверждается существенным приростом точности анализа ЭКГ. Данный подход приближается к уровню точности опытных кардиологов, что будет продемонстрировано в эксперименте, описанном ниже.

Таким образом, решается техническая проблема точного автоматического анализа ЭКГ.

Техническим результатом, достигающимся при решении данной проблемы, является повышение точности анализа ЭКГ.

Указанный технический результат достигается благодаря осуществлению компьютерно реализуемого способа автоматического анализа ЭКГ, выполняемого с помощью по меньшей мере одного процессора и содержащего этапы, на которых

получают сигнал ЭКГ по меньшей мере одного пациента;

осуществляют обработку полученного сигнала с помощью первой модели машинного обучения (МО), причем в ходе указанной обработки осуществляется выделение временных координат QRS комплексов сигнала;

с помощью второй модели МО на базе классификационной свёрточной нейронной сети (CNN) осуществляют

обработку отрезков сигнала заранее заданного размера, центрированных по положению QRS-комплекса на основании временных координат, выделенных первой моделью МО;

формирование усредненного вектора сердцебиения QRS-комплекса;

осуществляют классификацию данных сердцебиения пациента с помощью третьей модели МО с помощью обработки упомянутых временных координат QRS-комплексов сигнала, полученных первой моделью МО, и усредненного вектора сердцебиения QRS-комплекса, формируемого второй моделью МО.

В одном из частных вариантов реализации способа сигнал ЭКГ по меньшей мере одного пациента содержит показания при отключенных и подключенных электродах.

В другом частном варианте реализации способа полученный сигнал ЭКГ преобразовывают.

В другом частном варианте реализации способа на этапе предварительной обработки полученного сигнала выполняют

заполнение сигнала от отключенных электродов линейной интерполяцией между последней ненулевой точкой до отключения и первой ненулевой точкой после разъединения;

устранение блуждания изолинии путем вычитания двух проходов усредняющего фильтра с окном в 400 мс;

применение фильтра нижних частот с частотой среза 40 Гц;

понижение частоты дискретизации сигнала.

В другом частном варианте реализации способа первая модель МО реализована на базе сегментационной свёрточной нейронной сети (CNN).

В другом частном варианте реализации способа заранее заданный отрезок времени установлен в 2 с.

В другом частном варианте реализации способа осуществляют классификацию данных сердцебиения пациента с помощью третьей модели МО на основе градиентного бустинга над решающими деревьями.

Кроме того, заявленный технический результат достигается за счет системы автоматического анализа ЭКГ содержащей

по меньшей мере один процессор;

по меньшей мере одну память, соединенную с процессором, которая содержит машиночитаемые инструкции, которые при их выполнении по меньшей мере одним процессором обеспечивают выполнение способа автоматического анализа ЭКГ.

Краткое описание чертежей

Признаки и преимущества настоящего изобретения станут очевидными из приводимого ниже подробного описания изобретения и прилагаемых чертежей.

Фиг. 1 иллюстрирует пример реализации способа автоматического анализа ЭКГ,

фиг. 2 - анализ сигнала ЭКГ первой моделью МО,

фиг. 3 - анализ сигнала ЭКГ второй моделью МО,

фиг. 4 - общий вид системы автоматического анализа ЭКГ.

Осуществление изобретения

Данное техническое решение может быть реализовано на компьютере, в виде автоматизированной информационной системы (АИС) или машиночитаемого носителя, содержащего инструкции для выполнения вышеупомянутого способа.

Техническое решение может быть реализовано в виде распределенной компьютерной системы.

В данном решении под системой подразумевается компьютерная система, ЭВМ (электронно-вычислительная машина), ЧПУ (числовое программное управление), ПЛК (программируемый логический контроллер), компьютеризированные системы управления и любые другие устройства, способные выполнять заданную, четко определённую последовательность вычислительных операций (действий, инструкций).

Под устройством обработки команд подразумевается электронный блок либо интегральная схема (микропроцессор), исполняющая машинные инструкции (программы).

Устройство обработки команд считывает и выполняет машинные инструкции (программы) с одного или более устройства хранения данных, например, таких устройств, как оперативно запоминающие устройства (ОЗУ) и/или постоянные запоминающие устройства (ПЗУ). В качестве ПЗУ могут выступать, но не ограничиваясь, жесткие диски (HDD), флеш-память, твердотельные накопители (SSD), оптические носители данных (CD, DVD, BD, MD и т.п.) и др.

Программа - последовательность инструкций, предназначенных для исполнения устройством управления вычислительной машины или устройством обработки команд.

Данные ЭКГ были собраны из нескольких клиник одной из восточноевропейских стран. Данные состоят из 5095 амбулаторных записей ЭКГ с двумя отведениями продолжительностью 24 ч (в табл. 1 представлены статистики, относящиеся к датасету) и частотой 250 Гц. Вся персональная информация о пациентах была удалена клиниками. Каждая запись была аннотирована опытными кардиологами с использованием коммерческого программного обеспечения для анализа ЭКГ.

Разметка представляет собой положения отдельных QRS-комплексов, а также метки классов, такие как широкие или узкие QRS-комплексы, аритмические события (экстрасистолы и паузы) и различные типы пауз. Разметка получена полуавтоматическим методом - вначале проприетарный коммерческий алгоритм провел автоматическую разметку записи, затем опытный специалист функциональной диагностики провел вариацию и исправление ошибок алгоритма. Алгоритм, участвовавший в разметке данных, представлен в итоговой таблице (см. табл. 2) под названием "Коммерческое ПО 1".

Комплекс QRS - это желудочковый комплекс, который регистрируется во время возбуждения желудочков сердца. Это самый большой комплекс на ЭКГ. В нем различают несколько остроконечных зубцов как положительных (направлены вверх), так и отрицательных (направлены вниз).

Кроме того, записи ЭКГ содержат большое количество шумных и нечитаемых участков, а также часто встречалась ситуация, когда один из электродов был отключен в течение некоторого времени. Набор данных был разделен на обучающую, валидационную и тестовую выборки в пропорции 74%, 20% и 6% соответственно (3804, 1000 и 291 записей в каждой выборке).

Валидационная выборка получена случайным разбиением общего набора данных, в то время как тестовая выборка выбрана таким образом, что плотность патологий в ней увеличена на 50%. Это необходимо для того, чтобы обеспечить в тестовой выборке достаточное количество редких патологий. При этом тестовый набор записей был дополнительно аннотирован комитетом из трех независимых сертифицированных практикующих кардиологов, и итоговое решение (англ. "ground truth") определялось путем голосования этих экспертов. Решение специализированных врачей применялось для последующей тренировки и отладки используемых в настоящем решении моделей машинного обучения.

Таблица 1

Статистика датасета

Количество записей	5 095
Общая продолжительность	5 232 дня 21 час 6 минут
Общее количество QRS	554 057 612
Количество широких QRS	6 515 633 (1,2%)

Чтобы уменьшить шум в сигнале, были применены следующие шаги предварительной обработки к данным. Первым шагом было заполнение сигнала от отключенных электродов линейной интерполяцией между последней ненулевой точкой до отключения и первой ненулевой точкой после разъединения. Целью этого шага является устранение экстремальных высокочастотных всплесков в точках, где электроды отключены и повторно подключены. Вторым шагом было устранено блуждание изолинии путем вычитания двух проходов усредняющего фильтра с окном в 400 мс. Третьим шагом было применение фильтра нижних частот с частотой среза 40 Гц. Последним шагом было понижение частоты дискретизации сигнала. Во время этапа обучения вычитали медиану поканально для каждого окна обучения, чтобы еще больше приблизить изолинию к нулю, и нормализовывали амплитуду путем деления амплитуды сигнала на стандартное отклонение амплитуды в каждом окне обучения.

Как показано на фиг. 1, способ автоматического анализа ЭКГ состоит из нескольких этапов. На вход первой МО подается сигнал ЭКГ по меньшей мере одного пациента. Первым этапом является обработка сигнала ЭКГ с помощью модели сегментации CNN с архитектурой энкодер-декодер, на котором осуществляют выделение временных координат QRS-комплексов сигнала. Для каждого канала имеется отдельный CNN энкодер с идентичной структурой, но разными весами. Выходы энкодеров усредняются для того, чтобы гарантировать, что оба энкодера генерируют одинаковые признаки из разных каналов и дополняют друг друга (см. фиг. 2).

Это решение основано на том факте, что практически в каждой записи имеются длительные периоды (иногда до 100% времени), в которых один из электродов отсоединен или канал имеет очень низкий индекс качества сигнала (SQI). В то время как в статье [9] авторы, сталкиваясь с аналогичной проблемой, обучают нейронную сеть только на каналах с самым высоким SQL, в заявленном решении было обнаружено, что использование всех каналов в любое время позволяет нейронной сети самой научиться распознавать шум или отсутствующие сигналы. Цель заключалась в том, чтобы создать модель, которая работает на любом количестве отведений, а каждый присоединенный электрод повышает общее качество, в то время как отсоединение электрода не приводит к его ухудшению. Это достигается за счет специальной архитектуры нейронной сети, в которой каждый входной канал обрабатывается отдельной нейронной сетью - энкодером. Выходные признаки энкодеров затем усредняют и подаются в единый декодер-классификатор. Усреднение выходов энкодеров обязывает сеть учить одни и те же выходные признаки для разных каналов.

На втором этапе с помощью второй классификационной МО CNN, осуществляют обработку отрезков сигнала заранее заданного размера, центрированных по положению QRS-комплекса на основании временных координат, выделенных первой моделью МО и осуществляют формирование усредненного вектора сердечбиения QRS-комплекса.

На третьем этапе осуществляют классификацию на основе градиентного бустинга над решающими деревьями. Использование градиентного бустинга над решающими деревьями повышает эффективность этапа классификации сердечбиений путем включения в модель признаков пациента, полученных со всей записи целиком. В то время как CNN на первом этапе обрабатывает только 30 с сигнала, а CNN второй ступени обрабатывает 2 с сигнала, в результате чего было выявлено, что важно добавлять характеристики целой записи и использовать их в окончательной классификации.

Аугментация.

Доказано, что аугментация является эффективным методом улучшения обучения нейронных сетей. В заявленном решении основная аугментация выбрана эмпирически: обнуление одного из каналов с вероятностью 0,9 и добавление вместо него сильного гауссовского шума, что вынуждает модель обучаться, используя только действующие каналы.

Другие использованные аугментации распространены в области обработки ЭКГ и других сигналов [17]: добавление гауссовского шума к обоим каналам, растяжение/сжатие с коэффициентом (0,7-1,3) и умножение амплитуды канала на случайный коэффициент (0,5-1,5).

Сэмплирование и функции потерь.

Из-за большого дисбаланса широких/узких сердечбиений в данных (примерно 1:100) при обучении в нейронную сеть подавались примеры с искусственно завышенной частотой широких комплексов. В экспериментах заявленного решения наилучшие результаты были достигнуты при соотношении широких/узких 3:17. При тестировании различных функций потерь Dice loss показал лучшие результаты на этапе сегментации, а BCE loss на этапе классификации.

Обучение нейронных сетей.

В заявленном решении обе CNN нейронные сети обучались 100000 шагов с размером батча 64. Использовался оптимизатор Адама с $B1 = 0,9$ и $B2 = 0,999$, скорость обучения = 0,001 с экспоненциальным затуханием с коэффициентом 0,97 каждые 1000 шагов. Каждый батч формировали путем отбора широких сердечных сокращений с вероятностью 0,15 и узких с вероятностью 0,85.

Третий этап классификации был сделан с использованием градиентного бустинга над решающими деревьями с использованием библиотеки LightGBM [18]. Модель была обучена на валидационном наборе данных, который был разделен на 700 пациентов для обучения и 300 пациентов для проверки на текущей стадии. Обучение было остановлено после 461 итерации на основе метрики IoU (англ. Intersection

over Union), полученной на валидационном наборе данных. Набор признаков для текущего этапа был сгенерирован с использованием признаков, полученных на предыдущих этапах.

На этом этапе были использованы следующие признаки.

1. Вектор размерности 32, взятый с предпоследнего слоя классификационной нейронной сети.
2. Вектор среднего значения векторов из 1 пункта для всех QRS-комплексов пациента.
3. Стандартное отклонение векторов из 1 пункта для всех QRS-комплексов пациента.
4. Медианное значение векторов из 1 пункта для всех QRS-комплексов пациента.
5. Медианная частота сердечных сокращений в окне 100 и 10 ударов сердца около текущего QRS-комплекса.
6. Отношение RR-интервала текущего QRS-комплекса к значениям 5 пункта.

Таки образом, модель получила возможность использовать как локальные признаки каждого QRS-комплекса, так и признаки, полученные в результате обработки всей записи целиком, что существенно повышает её точность.

Результаты проведенных экспериментов приведены в табл. 2.

Для сравнения данной модели были выбраны два широкоиспользуемых коммерческих ПО для автоматической расшифровки ЭКГ, созданных двумя разными поставщиками.

Кроме того, модель заявленного решения сравнивали с разметкой опытных кардиологов, которые валидируют автоматическую разметку, полученную с помощью коммерческого ПО, произведенного поставщиком 2.

В заявленном решении качество моделей измеряли с помощью сегментационной метрики IoU. Результат считался истинно положительным для задачи детекции QRS-комплекса, если модель обнаруживала сердцебиение в интервале 150 мс от истинного. Сравнение выполнялось на тестовом наборе данных, состоящем из 291 записи, аннотированной комитетом из трех кардиологов. Этот набор данных был аннотирован независимо от исходного набора данных для обучения, что позволило оценить работу отдельного кардиолога.

Как видно из табл. 2, в заявленном решении модель превосходит две выбранные коммерческие ПО для автоматической интерпретации ЭКГ в задаче определения положения QRS-комплекса, а также в классификации сердечных сокращений на узкие и широкие. Более того, предлагаемая модель достигла уровня точности, сопоставимого с опытными кардиологами по этим задачам, как показано в табл. 2.

Таблица 2

Сравнение эффективности между выбранными методами детекции и классификацией QRS-комплексов

Метод	Детекция QRS-комплекса (IoU)	Классификация (IoU)
Коммерческое ПО 1	0.939	0.078
Коммерческое ПО 2	0.966	0.190
Нейронная сеть	0.980	0.740
Нейронная сеть + Градиентный бустинг	0.980	0.801
Кардиолог	0.978	0.863

Кроме того, заявленный метод проверялся на базе данных аритмии MIT-BIH и сравнивали результаты различных подходов, описанных в литературе, с аналогичными показателями заявленной модели (см. табл. 3) [20].

База данных MIT-BIH - это тестовый набор для оценки эффективности детекции аритмии, а также для фундаментальных исследований сердечной динамики, который использовался примерно исследователями около 500 раз по всему миру с 1980 г. [21]. В связи с тем, что этот набор данных не подходит для задачи классификации, заявленную модель оценивали только в контексте задачи детекции QRS-комплекса.

Как показано в табл. 3, заявленный подход к проблеме детекции сердцебиения показал более высокий уровень качества (согласно метрикам), чем сравниваемые с ним подходы для решения аналогичной задачи.

Таблица 3

Сравнение эффективности обнаружения QRS-комплексов на базе данных MIT-BIH

Работа	Recall (%)	Precision (%)
Pan and Tompkins (1985)	90.95	99.56
Elgendi et al. (2009)	87.90	97.60
Chouakri et al. (2011)	98.68	97.24
Rodriguez-Jorge et al. (2014)	96.28	99.71
NN + GBDT (наша работа)	98.11	99.91

Результаты сравнения эффективности показывают, что заявленный способ автоматического анализа ЭКГ является более точным и эффективным по сравнению с существующими аналогами. Заявленное решение предлагает канальную архитектуру CNN и объединяет ее с моделью GBDT, которая может использовать признаки пациентов. Кроме того, было продемонстрировано на наборе из 291 24-часовой амбулаторной записи ЭКГ с двумя отведениями, что заявленный способ автоматического анализа ЭКГ значительно превосходит два коммерчески доступных ПО, широко используемых кардиологами в стране, приближаясь к уровню качества опытных специалистов функциональной диагностики.

На фиг. 4 представлен пример общего вида вычислительной системы (300), которая обеспечивает реализацию заявленного способа или является частью компьютерной системы, например сервером, персональным компьютером, частью вычислительного кластера, обрабатывающим необходимые данные для осуществления заявленного технического решения.

В общем случае система (300) содержит объединенные общей шиной информационного обмена один или несколько процессоров (301), средства памяти, такие как ОЗУ (302) и ПЗУ (303), интерфейсы ввода/вывода (304), устройства ввода/вывода (1105), и устройство для сетевого взаимодействия (306). Процессор (301) (или несколько процессоров, многоядерный процессор и т.п.) может выбираться из ассортимента устройств, широко применяемых в настоящее время, например, таких производителей, как Intel™, AMD™, Apple™, Samsung Exynos™, MediaTek™, Qualcomm Snapdragon™ и т.п. Под процессором или одним из используемых процессоров в системе (300) также необходимо учитывать графический процессор, например GPU NVIDIA или Graphcore, тип которых также является пригодным для полного или частичного выполнения способа, а также может применяться для обучения и применения моделей машинного обучения в различных информационных системах.

ОЗУ (302) представляет собой оперативную память и предназначено для хранения исполняемых процессором (301) машиночитаемых инструкций для выполнения необходимых операций по логической обработке данных. ОЗУ (302), как правило, содержит исполняемые инструкции операционной системы и соответствующих программных компонент (приложения, программные модули и т.п.). При этом в качестве ОЗУ (302) может выступать доступный объем памяти графической карты или графического процессора.

ПЗУ (303) представляет собой одно или более устройств постоянного хранения данных, например жесткий диск (HDD), твердотельный накопитель данных (SSD), флэш-память (EEPROM, NAND и т.п.), оптические носители информации (CD-R/RW, DVD-R/RW, BlueRay Disc, MD) и др.

Для организации работы компонентов системы (300) и организации работы внешних подключаемых устройств применяются различные виды интерфейсов В/В (304). Выбор соответствующих интерфейсов зависит от конкретного исполнения вычислительного устройства, которые могут представлять собой, не ограничиваясь, PCI, AGP, PS/2, IrDa, FireWire, LPT, COM, SATA, IDE, Lightning, USB (2.0, 3.0, 3.1, micro, mini, type C), TRS/Audio jack (2.5, 3.5, 6.35), HDMI, DVI, VGA, Display Port, RJ45, RS232 и т.п.

Для обеспечения взаимодействия пользователя с вычислительной системой (300) применяются различные средства (305) В/В информации, например клавиатура, дисплей (монитор), сенсорный дисплей, тач-пад, джойстик, манипулятор мышь, световое перо, стилус, сенсорная панель, трекбол, динамики, микрофон, средства дополненной реальности, оптические сенсоры, планшет, световые индикаторы, проектор, камера, средства биометрической идентификации (сканер сетчатки глаза, сканер отпечатков пальцев, модуль распознавания голоса) и т.п.

Средство сетевого взаимодействия (306) обеспечивает передачу данных посредством внутренней или внешней вычислительной сети, например Интранет, Интернет, ЛВС и т.п. В качестве одного или более средств (306) может использоваться, но не ограничиваясь, Ethernet карта, GSM модем, GPRS модем, LTE модем, 5G модем, модуль спутниковой связи, NFC модуль, Bluetooth и/или BLE модуль, Wi-Fi модуль и др.

Представленные материалы раскрывают предпочтительные примеры реализации изобретения и не должны трактоваться как ограничивающие иные, частные примеры его воплощения, не выходящие за пределы испрашиваемой правовой охраны, которые являются очевидными для специалистов соответствующей области техники.

Источники информации.

1. WHO statistics of cardiovascular disease (CVD)[Online]. Available:
<https://www.who.int/health-topics/cardiovascular-diseases>
2. Estes N. A. M.: Computerized Interpretation of ECGs: Supplement Not a Substitute. *Circulation: Arrhythmia and Electrophysiology*, 6(1), 2–4 (2013)
<https://doi.org/10.1161/circep.111.000097>
3. Adamec J., Adamec R.: ECG Holter Guide to Electrocardiographic Interpretation. Springer, 3–5 (2008) <https://doi.org/10.1007/978-0-387-78187-7>
4. Kaplan, B. S., Uysal A. K., Sora Gunal E., Ergin S., Gunal S., Gulmezoglu M. B.: A survey on ECG analysis. *Biomedical Signal Processing and Control*, 43, 216–235 (2018) <https://doi.org/10.1016/j.bspc.2018.03.003>
5. Lindow, T., Kron, J., Thulesius, H., Ljungström, E., Pahlm, O.: Erroneous computer-based interpretations of atrial fibrillation and atrial flutter in a Swedish primary health care setting. *Scandinavian Journal of Primary Health Care*, 37:4, 426–433 (2019) <https://doi.org/10.1080/02813432.2019.1684429>
6. Bond R. R., Novotny T., Andrsova I., Koc L., Sisakova M., Finlay D., . . . Malik M. Automation bias in medicine: The influence of automated diagnoses on interpreter accuracy and uncertainty when reading electrocardiograms. *Journal of Electrocardiology*. (2018) <https://doi.org/10.1016/j.jelectrocard.2018.08.007>
7. Osowski S., & Tran Hoai Linh. ECG beat recognition using fuzzy hybrid neural network. *IEEE Transactions on Biomedical Engineering*, 48(11), 1265–1271 (2001) <https://doi.org/10.1109/10.959322>
8. Author, F., Author, S.: Title of a proceedings paper. In: Editor, F., Editor, S. (eds.) *CONFERENCE 2016, LNCS*, vol. 9999, pp. 1–13. Springer, Heidelberg (2016). <https://doi.org/10.1007/1234567890>
9. Shashikumar, S., Shah, A., Clifford, G., Nemati, S.: Detection of Paroxysmal Atrial

- Fibrillation using Attention-based Bidirectional Recurrent Neural Networks. In: KDD '18: Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, pp. 715–723. Association for Computing Machinery, New York (2018). <https://doi.org/10.1145/3219819.3219912>
10. Rajpurkar, P., Hannun, A., Haghpanahi, M., Bourn, C., Ng, A.: Cardiologist-Level Arrhythmia Detection with Convolutional Neural Networks. arXiv:1707.01836.
 11. Everss-Villalba, E., Melgarejo-Meseguer, F. M., Blanco-Velasco, M., Gimeno-Blanes, F. J., Sala-Pla, S., Rojo-Alvarez, J. L., García-Alberola, A.: Noise Maps for Quantitative and Clinical Severity Towards Long-Term ECG Monitoring. Sensors (Basel, Switzerland), 17(11), 2448. <https://doi.org/10.3390/s17112448>
 12. Essam, H., Kilany, M., Hassanien, A. E.: ECG signals classification: a review. International Journal of Medical Engineering and Informatics. Pp. 376-396. 10.1504/IJIEI.2017.10008807.
 13. Hong, Sh., Zhou, Y., Shang, J., Xiao, C & Sun, J.: Opportunities and Challenges in Deep Learning Methods on Electrocardiogram Data: A Systematic Review. arXiv:2001.01550.
 14. Shah, A. P., Rubin, S. A.: Errors in the computerized electrocardiogram interpretation of cardiac rhythm. Journal of Electrocardiology, 40(5):385– 390, 2007.
 15. Schlöpfer, J., Wellens, H. J.: Computer-Interpreted Electrocardiograms: Benefits and Limitations, Journal of the American College of Cardiology, Volume 70, Issue 9, 2017, Pp. 1183-1192, ISSN 0735-1097, 10.1016/j.jacc.2017.07.723.
 16. Li, Q., Mark, R. G., Clifford, G. D.: Robust heart rate estimation from multiple asynchronous noisy sources using signal quality indices and a Kalman filter. Physiol. Meas. 2008;29:15–32. doi: 10.1088/0967-3334/29/1/002.
 17. Salamon, J., Bello, J. P.: Deep Convolutional Neural Networks and Data Augmen-

- tation for Environmental Sound Classification. IEEE Signal Processing Letters, vol. 24, no. 3, pp. 279-283, March 2017.
18. Ke, G., Meng, Q., Finley, T., Wng, T., Chen, W., Ma, W., Ye, Q., Liu, T.: Light-GBM: A Highly Efficient Gradient Boosting Decision Tree. Advances in Neural Information Processing Systems 30, pp. 3149–3157, NIPS 2017.
19. Paszke A., Gross S., Chintala S., Chanan G., Yang E., DeVito Z., Lin Z., Desmaison A., Antiga L., and Lerer A.: Automatic differentiation in pytorch. In NIPS-W, 2017.
20. Rodriguez J., Mexicano R., Bila A., Ponce J, Cervantes R., Salvador: Feature Extraction of Electrocardiogram Signals by Applying Adaptive Threshold and Principal Component Analysis. Journal of Applied Research and Technology, 46, 1253–1258. (2014) <https://doi.org/10.1109/IS3C.2014.324>
21. Moody G. B., Mark G. B.: The impact of the MIT-BIH Arrhythmia Database. IEEE Engineering in Medicine and Biology Magazine, vol. 20, no. 3, pp. 45–50, (May-June 2001) <https://doi.org/10.1109/51.93272>

ФОРМУЛА ИЗОБРЕТЕНИЯ

1. Компьютерно реализуемый способ автоматического анализа ЭКГ, выполняемый с помощью вычислительной системы, содержащей три модели машинного обучения, при этом способ выполняет этапы, на которых

- получают сигнал ЭКГ по меньшей мере одного пациента;
- осуществляют предварительную обработку полученного сигнала;
- заполнение сигнала от отключенных электродов линейной интерполяцией между последней ненулевой точкой до отключения и первой ненулевой точкой после разъединения;
- устранение блуждающей изолинии путем вычитания двух проходов усреднённого фильтра;
- применение фильтра нижних частот;
- понижение частоты дискретизации сигнала;
- осуществляют обработку предварительно обработанного полученного сигнала с помощью первой модели машинного обучения (МО), причем в ходе указанной обработки осуществляется выделение временных координат QRS-комплексов сигнала;
- с помощью второй модели машинного обучения на базе классификационной свёрточной нейронной сети (CNN) осуществляют
- обработку отрезков предварительно обработанного полученного сигнала заранее заданного размера, центрированных по положению QRS-комплекса на основании временных координат, выделенных первой моделью МО;
- формирование усредненного вектора сердечбиения QRS-комплекса;
- осуществляют классификацию данных сердечбиения пациента с помощью третьей модели МО на основе градиентного бустинга над решающими деревьями, при этом осуществляют обработку упомянутых временных координат QRS-комплексов сигнала, полученных первой моделью МО, и усредненного вектора сердечбиения QRS-комплекса, формируемого второй моделью МО.

2. Способ по п.1, характеризующийся тем, что сигнал ЭКГ по меньшей мере одного пациента содержит показания, когда по меньшей мере один электрод отключен и при этом по меньшей мере один электрод подключен к пациенту.

3. Способ по п.1, характеризующийся тем, что на этапе предварительной обработки полученного сигнала


- устраняют блуждания изолинии путем вычитания двух проходов усредняющего фильтра с окном в 400 мс;
- применяют фильтр нижних частот с частотой среза 40 Гц.

4. Способ по п.1, характеризующийся тем, что первая модель машинного обучения (МО) реализована на базе сегментационной свёрточной нейронной сети (CNN).


5. Способ по п.1, характеризующийся тем, что заранее заданный отрезок времени установлен в 2 с.

6. Система автоматического анализа ЭКГ, содержащая по меньшей мере один процессор;


по меньшей мере одну память, соединенную с процессором, которая содержит машиночитаемые инструкции, которые при их выполнении по меньшей мере одним процессором обеспечивают выполнение способа по любому из пп.1-5.




Фиг. 1



Фиг. 2



Фиг. 3



Фиг. 4



Евразийская патентная организация, ЕАПВ

Россия, 109012, Москва, Малый Черкасский пер., 2