

Обзорная статья / Review Article

DOI 10.15826/urej.2021.5.4.004

УДК 004.93(621.384)

Обзор методов автоматической диагностики сердечной аритмии для принятия решений о необходимости проведения дефибрилляции

Д. А. Липчак¹✉, А. А. Чупов^{1, 2}

¹ АО «ПО «Уральский оптико-механический завод» имени Э.С. Яламова», Россия, 620100, г. Екатеринбург, ул. Восточная, 336

² Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, Россия, 620002, г. Екатеринбург, ул. Мира, 32

✉ lipchak@uomz.eu

Аннотация

Фибрилляция желудочков сердца считается наиболее часто встречающейся причиной внезапной остановки сердца. Такая фибрилляция и часто предшествующая ей желудочковая тахикардия – это ритмы сердца, которые могут реагировать на экстренную электрошоковую терапию и вернуться к нормальному синусовому ритму при ранней диагностике после остановки сердца с восстановлением адекватной насосной функции сердца. Однако ручная проверка сигналов ЭКГ на наличие паттерна такой аритмии является сложной аналитической задачей, требующей немедленного принятия решения в стрессовой ситуации, практически невыполнимой в отсутствие квалифицированного медицинского специалиста. Поэтому для автоматической диагностики острых состояний широкое применение получили системы компьютерной классификации аритмий с функцией принятия решения о необходимости проведения электрокардиотерапии с параметрами высоковольтного импульса, вычисленного адаптивно для каждого пациента. В данной работе рассмотрены методы анализа электрокардиографического сигнала, снимаемого с электродов наружного автоматического или полуавтоматического дефибриллятора, с целью принятия решения о необходимости оказания дефибрилляции, применимые во встроенном программном обеспечении автоматических и полуавтоматических внешних дефибрилляторов. Работа включает обзор применимых методов фильтрации, а также последующих алгоритмов извлечения, классификации и сжатия характерных признаков для сигнала ЭКГ.

Ключевые слова

аритмия, цифровая обработка сигнала, фильтрация, машинное обучение, автоматический наружный дефибриллятор, дефибрилляция

Для цитирования

Липчак Д. А., Чупов А. А. Обзор методов автоматической диагностики сердечной аритмии для принятия решений о необходимости проведения дефибрилляции. *Ural Radio Engineering Journal*. 2021;5(4):380–409. DOI: 10.15826/urej.2021.5.4.004.

© Липчак Д. А., Чупов А. А., 2021

Methods of Signal Analysis for Automatic Diagnosis of Shockable Cardiac Arrhythmias: A Review

D. A. Lipchak¹✉, A. A. Chupov^{1, 2}

¹ Joint Stock Company “Production Association “Urals Optical & Mechanical Plant” named after Mr. E.S. Yalamov”,
33 B Vostochnaya Str., Yekaterinburg, 620100, Russia

² Ural Federal University named after first President of Russia B.N. Yeltsin,
32 Mira Str., Yekaterinburg, 620002, Russia

✉ lipchak@uomz.eu

Abstract

Ventricular fibrillation is considered the most common cause of sudden cardiac arrest. The fibrillation, and ventricular tachycardia often preceding it, are cardiac rhythms that may respond to emergency electroshock therapy and return to normal sinus rhythm when diagnosed early after cardiac arrest with the restoration of adequate cardiac pumping function. However, manually checking ECG signals on the existence of a pattern of such arrhythmias is a risky and time-consuming task in stressful situations and practically impossible in the absence of a qualified medical specialist. Therefore, systems of the computer classification of arrhythmias with the function of making a decision on the necessity of electric cardioversion with the parameters of a high-voltage pulse calculated adaptively for each patient are widely used for the automatic diagnosis of such conditions. This paper discusses methods of analyzing the electrocardiographic signal taken from the electrodes of an external automatic or semi-automatic defibrillator in order to make a decision on the necessity for defibrillation, which are applicable in the embedded software of automatic and semi-automatic external defibrillators. The paper includes an overview of applicable filtering techniques as well as subsequent algorithms for extracting, classifying and compressing features for the ECG signal.

Keywords

arrhythmia, digital signal processing, filtering, machine learning, automatic external defibrillator, defibrillation

For citation

Lipchak D. A., Chupov A. A. Methods of Signal Analysis for Automatic Diagnosis of Shockable Cardiac Arrhythmias: A Review. *Ural Radio Engineering Journal*. 2021;5(4):380–409. (In Russ.) DOI: 10.15826/urej.2021.5.4.004.

1. Введение

Даже когда портативные дефибрилляторы стали реальностью в 1960-х годах [1], прошли годы, прежде чем такие устройства получили применение вне больниц и бригад скорой медицинской помощи. Так как напряжения, используемые при про-

ведении электрошоковой терапии, лежат в области от единиц до десятков киловольт, использование дефибриллятора является процедурой высокого класса риска для пациента, а в случае ошибочного неправильного применения – и для оператора, следовательно, оборудование для проведения срочной электрокардиотерапии в отсутствие квалифицированного медицинского персонала должно обладать дополнительным функционалом исключения ситуации неправильной эксплуатации. Инженерное решение впервые было предложено в Портленде, Орегон, США, в 1978 году [2]. Врачи А. Диак и У. Велборн совместно с инженером Р. Руллманом разработали портативный автоматический наружный дефибриллятор (далее – АНД), который мог бы безопасно использовать неподготовленный пользователь в чрезвычайной ситуации, Heart Aid, первый коммерчески доступный АНД. Устройство содержало отдельный датчик, который оператор помещал в дыхательные пути пациента. Компьютерная программа определяла частоту сердечных сокращений по показаниям ЭКГ и могла определять, присутствует ли ритм, требующий применения дефибрилляционного разряда. С появлением алгоритмов, отвечающим клиническим требованиям к точности и специфичности определения ритмов сердца, подлежащих и неподлежащих дефибрилляции, применение дополнительного датчика перестало быть необходимым, а задача принятия дефибриллятором решения о необходимости и допустимости нанесения электрического разряда полностью перешла в область автоматического анализа цифрового сигнала электрокардиограммы.

Если рассматривать механизм человеческого принятия решения, то, с точки зрения кардиологии, говорят о дефибриллируемых или шоковых ритмах, причем в термине ритма подразумевают не только частотные, но и морфологические особенности формы волны ЭКГ – в случае обнаружения шокового ритма требуется незамедлительное проведение дефибрилляции. Согласно клиническим рекомендациям по оказанию скорой медицинской помощи при внезапной сердечной смерти [3–8], к шоковым ритмам относятся:

А. Фибрилляция желудочков. Фибрилляция желудочков представляет собой нескоординированные и дезинтегрированные сокращения волокон миокарда, приводящие к невозможности формирования сердечной волны. К предфибрилляторными формам желудочковых тахикардий относят альтернирующие и пируэтные желудочковые тахикардии, полиморфные желудочковые тахикардии. С точки зрения анализа сигнала, желудочковая фибрилляция считается крупноволновой, если на ЭКГ она имеет амплитуду от пика до пика более 200 мкВ [9].

Желудочковая тахикардия называется высокочастотной, если ЧСС превышает некоторый заранее заданный порог. Величина порога не регламентируется, однако наиболее часто для него принимают 160–200 ударов в минуту [10; 11].

В. Желудочковая тахикардия без пульса. Частота желудочковой тахикардии настолько высокая, что во время диастолы полости желудочков не в состоянии заполниться достаточным количеством крови, что приводит к резкому снижению сердечного выброса (отсутствию пульса) и, следовательно, к неадекватному кровообращению. Желудочковая тахикардия без пульса по прогнозам приравнивается к фибрилляции желудочков, крупноволновая желудочковая фибрилляция и высокочастотная желудочковая тахикардия.

Согласно той же классификации выделяют следующие нешоковые ритмы, которые не подлежат дифибрилляции (далее – НШРС):

С. Асистолия. Асистолия – это отсутствие сердечных сокращений и признаков электрической активности, подтвержденных в трех отведениях на ЭКГ.

Д. Электромеханическая диссоциация. Электромеханическая диссоциация – это тяжелое угнетение сократимости миокарда с падением сердечного выброса и артериального давления, но при сохраняющихся сердечных комплексах на ЭКГ. Первичная электромеханическая диссоциация – миокард теряет возможность выполнять эффективную контракцию при наличии источника электрических импульсов. Сердце быстро переходит на идиовентрикулярный ритм, который вскоре сменяется асистолией. Вторичная электромеханическая диссоциация – резкое сокращение сердечного выброса, не связанное с непосредственным нарушением процессов возбудимости и сократимости миокарда.

Е. Нормальный синусовый ритм и некоторые другие специфические ритмы. Группа НШРС также включает в себя нормальный синусовый ритм, атриа-вентрикулярную тахикардию, синусовую брадикардию, трепетание предсердий, фибрилляцию предсердий, идиовентрикулярные ритмы, блокады различного рода и степени, другие ритмы, воздействие на которые дефибрилляцией терапевтически невыгодно.

Выделяют также переходные ритмы сердца, для которых дефибрилляция клинически рекомендована, если альтернативная терапия не может быть применена. Например, если рядом с пациентом, испытывающим какой-либо ритм из группы переходных ритмов сердца, находится специалист с должным уровнем квалификации в кардиологии и реаниматологии, то осуществляется медикаментозное лечение, а дефибрилляция заменяется

непрямым массажем сердца. Электрокардиотерапия в этом случае осуществляется только если это является единственным доступным способом терапевтического воздействия. Согласно [12] к переходным ритмам сердца относятся мелковолновая желудочковая, а также иная желудочковая тахикардия, не попавшая в группу ШРС. Однако с точки зрения постановки задачи по разработке систем автоматического компьютерного анализа сигнала ЭКГ в составе встроенного программного обеспечения автоматических и полуавтоматических наружных дефибрилляторов, ритмы, клинически интерпретируемые как переходные, должны быть классифицированы системой как не шоковые, в этом случае оператор должен оказать дефибрилляцию с ручным управлением. Такой подход считается устоявшимся в современных АНД и зафиксирован в клинических протоколах и нормативной документации для разработки автоматизированных систем.

В современных АНД используются программируемые микроконтроллеры и микрокомпьютеры, позволяющие осуществлять классификацию оцифрованного сигнала ЭКГ за времена, превышающие скорость принятия человеком решения. Согласно нормативной документации, все внедряемые в медицинские устройства алгоритмы принятия решений должны быть обязательно верифицированы на данных заранее снятых сигналов ЭКГ.

2. Компьютерная классификация аритмий

2.1. Базы данных для обучения алгоритмов

Согласно последним исследованиям [13], для отработки точности алгоритма, проверки и обучения систем искусственного интеллекта существует ряд международных открыто публикуемых баз данных электрокардиографических сигналов:

PTB Diagnostic ECG

База данных 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) плюс максимальное напряжение шума 10 мкВ¹.

¹ Базу можно найти на сайте: <https://www.physionet.org/physiobank/database/ptbdb/>

MIT-BIH Arrhythmia

Эта база данных находится в ведении Отделения медицинских наук и технологий Гарвардского технологического института (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 лекарства².

INCART – St. Petersburg Institute of Cardiological Technics

Эта база данных 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 минут³.

SUPRA – Supraventricular Arrhythmia

Эта база данных 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)⁴.

АНА

Эту базу данных можно получить только на веб-сайте Научно-исследовательского института неотложной помощи (ECRI Institute) в виде запрошенного DVD вместе с оплатой пошлины. DVD 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, разде-

² База данных размещена на: <https://www.physionet.org/physiobank/database/mitdb/>

³ База данных размещена на: <https://www.physionet.org/pn3/incartdb/>

⁴ База доступна на: <https://physionet.org/>

ленных 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 бит⁵.

UofTDB – База данных Университета Торонто

Эта база данных 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 DI⁶.

THEW – Telemetric and Holter ECG Warehouse

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 участникам⁷. 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.

PHYSIOBC

Это новая база данных, разработанная 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 пациента⁸.

3. Методы

Исторически распознавание аритмий 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, что, в свою очередь, является отличным примером

⁵ База размещена по ссылке: www.ecri.org

⁶ База размещена по ссылке: <http://www.comm.utoronto.ca>

⁷ На сайте www.thew-project.org

⁸ База данных размещена по адресу: www.physiobc.org

для применения алгоритмов классического машинного обучения и глубокого машинного обучения. Таким образом, опубликованные методы анализа можно разделить на три эволюционно обоснованные группы (см. рис. 1).




Рис. 1. Классификация алгоритмов распознавания аритмий
Fig. 1. Methods of arrhythmia Recognition

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

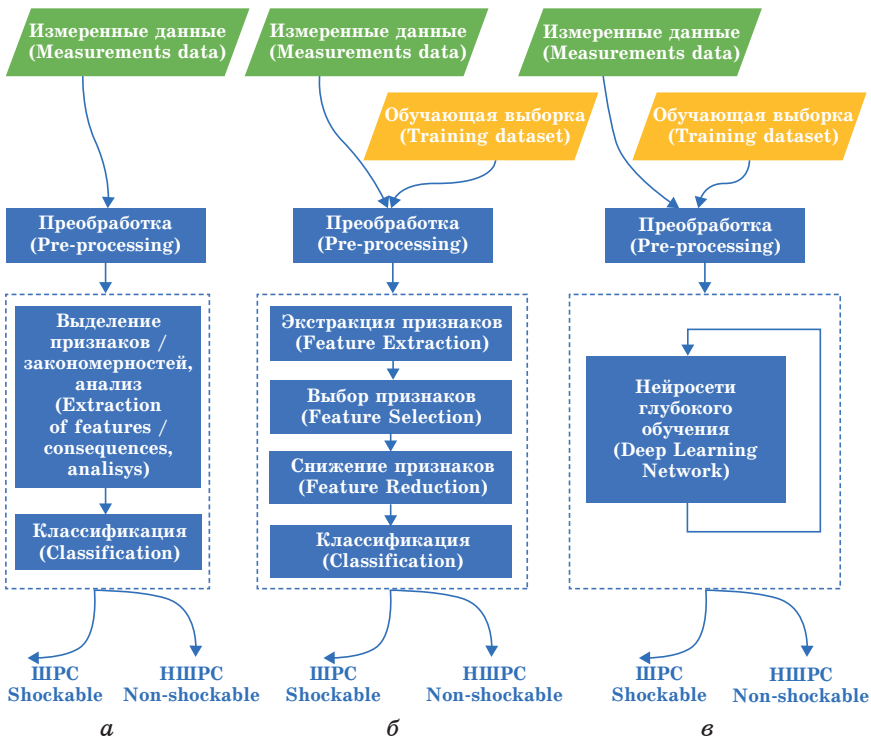


Рис. 2. Этапы работы алгоритмов распознавания аритмий:
а – классические алгоритмы без обучения; б – алгоритмы машинного обучения; в – алгоритмы глубокого машинного обучения
Fig. 2. The arrhythmias' detection algorithm steps: а – for convenient algorithms without machine learning, б – for algorithms using machine learning, в – for deep learning algorithms

3.1. Общие принципы предварительной обработки

Этот предварительный шаг снижает шум сигнала за счет сглаживания сигнала ЭКГ и уменьшения подавления дрейфа и отклонения базовой линии. Этот шаг предварительной обработки делает сигнал ЭКГ пригодным для последующих процессов. Наиболее распространенные методы, используемые для уменьшения шума сигнала, следующие:

- а) низкочастотная и высокочастотная фильтрация Баттерворта второго порядка [14–17; 18];
- б) вейвлет Добеши [19];
- в) ортогональный вейвлет-фильтр [20–21].

Кроме предварительной фильтрации, в качестве предварительной обработки многие работы сегментируют сигналы ЭКГ на удары или сегменты ЭКГ различной продолжительности (например, 2 с и 5 с) перед извлечением признаков. Наиболее распространенный алгоритм, используемый здесь, — это алгоритм Пэна Томпкинса [22], который обнаруживает R-пики ЭКГ для последующей сегментации сигнала на массивы значений, входящих в последующий алгоритм.

3.2. Машинное обучение

Под классическим машинным обучением, применимому к задаче распознавания образов, рассматриваемой в данной работе, подразумевается решение задачи классификации исходных данных, т. е. решение классической задачи обучения с учителем.

3.1.1. 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/Морфологические признаки. Эти признаки описаны во временной области, представляя амплитуду, наклон и частоту сердечных сокращений. Наиболее частыми характеристиками являются интервал пересечения порога (TCI) [23], количество отсчетов пересечения порога (TCSC) [24], среднее абсолютное значение (MAV) [25], стандартная экспонента (STE) и модифицированная экспонента (MEA) [26]. Интервал пересечения порога определяется как временной интервал между последовательными импульсами, который пересекает пороговое

значение. Типичной является установка порогового значения до 20% от максимальных абсолютных значений каждого односекундного сегмента. Точно так же TCSC – это расширенная версия алгоритма детекции пересечения порога с некоторыми изменениями, заключающимися в использовании трехсекундного сегмента вместо односекундного, учете как положительных, так и отрицательных пороговых значений вместо только положительного порога, и в подсчете количества выборок, укладывающихся в предустановленный интервал амплитуд, в пределах заданного временного интервала вместо подсчета импульсов. Критерий стандартный экспоненты определяется как количество точек пересечений сигнала ЭКГ и убывающей экспоненциальной кривой. MEA – это измененная версия STE, которая приподнимает кривую в точке пересечения максимума. Это изменение дает более надежные результаты обнаружения. Кроме того, многие другие временные и морфологические признаки использовались в исследованиях, но они менее типичны. Эти признаки включают вспомогательные счетчики (count1, count2 и count3) [27], bCP [28], x1 и x2 [29]. Эти функции используются для уменьшить количество информации о сигнале ЭКГ.

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) [50], спектральный алгоритм [31] и алгоритм медианной частоты (MF) [52]. VFleak – это функция отклика узкополосного полосового фильтра, которая определяет среднюю частотную область сегмента ЭКГ и его выход – утечка 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.

Кроме того, в литературе используются некоторые другие спектральные характеристики, такие как спектральные характеристики (x3, x4 и x5), представленные в работе [32], или базовое содержание во временной области (bWT), представленное в работе [28].

Временно-частотные/вейвлет-признаки. Вейвлет-анализ широко используется в анализе биомедицинских сигналов различной степени сложности и оказывает исключительные результаты [33]. Примерами признаков, извлекаемых из результатов

вейвлет-преобразования, примененного к сигналу ЭКГ, могут послужить эксцесс [34], измерение доли выбросов, склоняющихся к основному распределению данных выборки, подсчет асимметрии в распределении [35], измерение асимметрии данных вокруг среднего по выборке, стандартное отклонение и другие характеристики.

Признаки сложности (нелинейные признаки) геометрических искажений. Эти признаки включают различные расчеты, связанные со сложностью рассматриваемого сегмента ЭКГ [36, 37]. Наиболее часто используемыми характеристиками, описывающими сложность сегмента ЭКГ, являются результаты количественного анализа повторяемости [38], энтропия [39], энтропия Реньи [39], энтропия образца (SamEn) [40], энтропия перестановок [41], фрактальная размерность (FD) [42], приближительная энтропия (ApEn) [43], спектры высших порядков (HOS) [44] и энергия [45]. Параметры RQA измеряют повторяемость паттернов и определяют сложность сигналов ЭКГ [38]. Главные RQA признаки следующие: частота повторения (RR1, RR2), детерминант (DET1, DET2), энтропия (ENTR1, ENTR2), средняя диагональ, длина (L1, L2), энтропия времени повторения (RP) и самая длинная диагональная линия (DD) [45–48]. Энтропия Шеннона демонстрирует эту информацию, полученную в результате конкретного события обратно пропорционально [48]. SamEn количественно определяет энтропию сегмента ЭКГ. Низкое значение SamEn показывает, что сигнал больше похож на сам себя. Высокое значение SamEn указывает на вероятность возникновения ударных ритмов [40]. Энтропия Реньи (g_e) имеет более высокий динамический диапазон по сравнению с энтропией Шеннона [39]. HOS – это спектральное представление моментов третьего и более высокого порядка, которое определяет нелинейные корреляции нескольких частотных составляющих сигнала ЭКГ [44]. Извлеченные характеристики HOS называются энтропиями HOS 1, 2, 3 и 4. Характеристики HOS оцениваются с использованием биспектра $B(f_1, f_2)$, который является преобразованием Фурье корреляции сигнала 3-го порядка.

Характеристика энергии (e) используется для оценки регулярности сигнала [45]. Кроме того, есть и другие, менее распространенные характеристики сложности, такие как ковариация (CVbin), площадь (abin), частота (Frqbin), эксцесс (Kurt) и sLog Energy [53].

Таким образом, в этой статье основное внимание уделяется нелинейным характеристикам, в частности мерам энергии и энтропии.

3.1.2. Выбор признаков

Этот шаг позволяет удалить количество избыточных функций, снизить вычислительные затраты и улучшить общую производительность системы. На этом этапе используются следующие три основные категории методов выбора признаков:

а) методы-оболочки: считаются лучшим подходом для выбора признаков с точки зрения точности, но обладают значительной вычислительной сложностью [49]. В этих методах используется перекрестная проверка путем многократного обучения модели с использованием различных признаков и сравнение результатов. Здесь распространены следующие методы:

- 1) рекурсивное исключение признаков [50];
- 2) прямой выбор признаков [51];
- 3) генетические алгоритмы [51];

б) методы-фильтры: этот подход использует статистические измерения для выбора наилучшего набора характеристик перед процессом обучения. Здесь функции оцениваются по методу прокси, а не по точности перекрестной проверки. Распространенные техники следующие:

- 1) корреляция;
- 2) хи-квадрат [52];
- 3) дисперсионный анализ (ANOVA) [53];
- 4) ReliefF [54];

в) встроенные методы: этот подход включает методы, которые не подпадают под вышеупомянутые подходы (оболочка или фильтр). L1-регуляризация является примером такого метода [55].

3.1.3. Снижение признаков

На этом этапе устанавливается меньший набор новых переменных, каждая из которых представляет собой смесь входных переменных, включая ту же самую информацию, что и весь набор входных переменных. Многие методы снижения признаков преобразуют выбранные признаки в низкоразмерное пространство. Анализ главных компонент (PCA) [56], линейный дискриминантный анализ (LDA) [56] и локально-чувствительный дискриминантный анализ (LSDA) [57] являются примерами методов снижения признаков.

3.1.4. 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, по-

лученный 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 этом 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).

3.3. Методы глубокого машинного обучения

В последние годы расширенные версии нейронных сетей, называемые глубокими нейронными сетями, вызвали большой интерес в компьютерной диагностике практически всех заболеваний [58; 59]. Глубокие сети состоят из двух или более полностью связанных многослойных персептронов. В зависимости от конструкции сети глубокого обучения подразделяются на различные классы, такие как полностью связанные сети, сети убеждений и сверточные сети. Одним из основных преимуществ сетей глубокого обучения является то, что они выполняют извлечение признаков автоматически. Распространенные сети глубокого обучения, используемые в сигнале ЭКГ, – это сверточная нейронная сеть (CNN) [60; 61] и рекуррентная нейронная сеть (RNN) [62].

4. Результаты

В таблице 1 приведены результаты обзора литературных источников, приведены достоинства и недостатки методов распознавания шоковых аритмий. В обзор вошли работы за период времени 2016–2021 гг., и показаны только те работы, где чувствительность соответствует требованиям нормативной документации – чувствительность алгоритма не менее 90% (при распознавании фибрилляции желудочков при максимальном размахе 200 мкВ или более, в отсутствие артефактов) [63], то есть перспективно применимые к использованию в системах компьютерного распознавания аритмий в составе встроенного программного обеспечения автоматических и полуавтоматических наружных дефибрилляторов.

Однако за счет того, что исследования, приведенные к рассмотрению как актуальные, в табл. 1, тестировались на разных наборах данных и в разных условиях, не представляется возможным дать однозначный ответ на вопрос, какой алгоритм необходимо выбрать при разработке систем автоматического анализа, применимых во встроенном программном обеспечении

Таблица 1. Результаты анализа состояния области знаний
Table 1. Results of the analysis of the state of the knowledge area

Источник	Год	Методы	Базы данных	Преимущества	Недостатки	Эффективность алгоритма
[67]	2016	HBD-нерегулярность, Аффинная нормализация AF-детекция	MIT-BIH	Минимальная предобработка и обучение. Устойчив к разным видам шума. Применим к разным технологиям	Проблема статистической сверхточности. Низкая точность на больших объемах данных. Неизвестна специфичность	Acc = 96.38%
[15]	2017	SVM Personalized features SVM	MIT-BIH, CUDB а CUDB	Низкая сложность Быстрый	Шаблон QRS-комплекса не адаптивный	Acc = 95.5%, SP = 95.6%, AUC = 98.9%
[16]	2017	GA, SFFS with modified VMD SVM	CUDB VFDB	Получена хорошая эффективность с малыми признаками. Проблема статистической сверхточности решена	Времязагрятный	Acc = 99% Sen = 97.36%, SP = 99.61%
[18]	2017	DWT, nonlinear features, Sequential forward feature selection, (SFS), kNN	MIT-BIH CUDB VFDB	Высокая чувствительность при распознавании шоковых ритмов, оптимальный по затратам	Сложность	Acc = 98.34%, Sen = 95.49%, SP = 99.14%
[14]	2018	VF-filter Leakage Measure (Lk) Threshold Crossing Interval (TCI) Centroid Frequency (CF), binary genetic algorithm	CUDB VFDB	Проблема статистической сверхточности решена, менее сложный, достигнута высокая точность при малых признаках	Работает на публичной базе данных, без клинической обстановки, низка производительность	Acc = 95.9%, SP = 96.8%, PPV = 87.6%
[66]	2018	Flexible analytic wavelet transform (FAWT) Log energy entropy (LEE) Permutation entropy (PEnt) Random forest (RF)	MIT-BIH AFDB	Нет необходимости в детекции R-пика и P-волны Устойчивая система	Чувствителен к ошибкам распознавания R-пика, неизвестна специфичность	Acc = 96.84%

Продолжение табл. 1

Источник	Год	Методы	Базы данных	Преимущества	Недостатки	Эффективность алгоритма
[70]	2018	CNN	MITDB	Инвариантен к трансляции. Нет необходимости в признаках, созданных вручную. Не нужна детекция R-пика	Необходим большой объем данных для начала работы. Время обучения CNN по сравнению с моделями, более длительное	Acc = 93.2%, Se = 95.32%, SP = 91.04%
[62]	2018	Short-term Fourier transform (STFT), Stationary wavelet transform (SWT), Deep convolutional neural network (DCNN)	MIT-BIH Atrial Fibrillation Database	Не основывается на распознавании пика. Может быть получена высокая точность на малом сегменте данных	Работает на малом объеме данных. Проблема с детекцией некоторых сигналов. Время затратный. Неизвестна специфичность	Acc = 98.63%
[65]	2018	RNN	MIT-BIH Atrial Fibrillation Database	Не требуется экстракция признаков. Может быть использован для долговременного мониторинга, оптимальный по затратам	Использует короткий сегмент, работает на ограниченной выборке, времязатратный. Неизвестна специфичность	Acc = 99.72%
[64]	2019	Integrated radial basis function (IRBF), and relevance vector machine (RVM)	MIT-,BIH	Использовался для быстрого моделирования без оптимизации параметров. Использовался для быстрого моделирования и распознавания, способность к предсказанию имеет вероятностную значительность	Данные не применимы для реальных применений. Неизвестна специфичность	Acc = 98.16%
[20]	2019	Wavelet-based features, Fuzzy entropy (FE), Renyi entropy (RenE), SVM	MIT-BIH arrhythmia, CUDB VFDB	Нет необходимости преобработки ЭКГ сигнала. Нет необходимости детектирования R-пика	Работает на маленьких выборках	Acc = 97.8% Se = 93.42% SP = 98.35%

Окончание табл. 1

Источ-ник	Год	Методы	Базы данных	Преимущества	Недостатки	Эффектив-ность алгоритма
[71]	2019	CNN-BLSTM	MIT-BIH AF	1. Не затрачивает много времени и ресурсов для детекции и извлечения признаков. 2. Работает в режиме реального времени. 3. Низкая цена	Проблема статистической сверхточности Модель не применена для клинической постановки диагноза Неизвестна специфичность	Acc = 96.59%
[72]	2019	CNN SVM	Private AF	1. Высокая точность на больших объемах данных. 2. Проблема статистической сверхточности решена	Низкая точность на малых объемах данных Неизвестна специфичность	Acc = 96%
[65]	2020	Artificial adaptive systems and fuzzy transformation	AFDB	Быстрая обработка, применимая в реальной жизни, высокая эффективность вычислений	Данные не применимы в реальных применениях. Неизвестна специфичность	Acc = 95%,
[68]	2020	Morphology based deep learning	Private AF data	Уникален среди классических алгоритмов, основанных на правилах, нет шага извлечения признаков	Малое количество инцидентов AF. Использовалось ограниченное количество информации из одного кардиоцикла на одном отведении. Сложность. Неизвестна специфичность	Acc = 96%
[69]	2020	Fixed frequency range empirical wavelet transform, (FFREWt) Filter-bank convolutional neural network	CUDB VFDB	Может быть применен для мультипараметрического анализа сигнала ЭКГ, нет этапа экстракции признаков	Работает на малом количестве объектов. Неизвестна специфичность	Acc = 99.03%,
[73]	2020	CNN t+ improved El-man neural network (IENN)	AFDB MIT-BIH	Непрерывный механизм классификации. Скорость сходимости модели ускоряется в некоторой степени	Сфокусирован только на AF, а также необходима на большем и более различном наборе данных	Acc = 98.8% Sensitivity = 98.6

автоматического наружного дефибриллятора. Для однозначного подтверждения превосходства алгоритма, работающего в готовом устройстве, без возможности проведения облачных или удаленных вычислений, необходим не только постоянный анализ пользовательского опыта использования дефибриллятора, но и подтверждение достаточных временных характеристик вычислений конкретного аппаратного решения.

Несмотря на это, можно наметить некоторые тенденции в исследуемой области:

1) за последние три года становится заметным увеличение числа работ, использующих механизмы глубокого обучения, в частности сверточных нейронных сетей;

2) вейвлет-анализ остается популярным методом как фильтрации, так и извлечения признаков;

3) сочетание нескольких технологий анализа дает новые показатели эффективности алгоритмов;

4) для полного сравнительного анализа, необходимо повторить результаты, указанные в работах с лучшими показателями точности и специфичности алгоритмов, и исследовать их работу в одинаковых условиях, а желательно – с применением конкретного аппаратно-программного корпуса, планируемого для применения в разрабатываемом АНД.

Заключение

В данной работе рассмотрены методы автоматического анализа электрокардиографического сигнала, с целью принятия решения о необходимости оказания дефибрилляции. Сформулированы основные требования к решению задачи распознавания шоковых форм аритмий. Рассмотрено современное состояние области знаний о компьютерном распознавании шоковых аритмий, предложенные работы и методы проанализированы с точки зрения применимости их результатов в системах автоматического анализа во встроенном программном обеспечении автоматических и полуавтоматических внешних дефибрилляторов.

Список литературы

1. Гурвич Н.Л. *Основные принципы дефибрилляции сердца*. М.: Медицина; 1977. 180 с.
2. Diack A. W., Welborn W. S., Rullman R. G., Walter C. W., Wayne M.A. An automatic cardiac resuscitator for emergency treatment of cardiac arrest. *Medical Instrumentation*. 1979;13(2):78–83. PMID: 431428.
3. Багненко С.Ф., Верткин А.Л., Мирошниченко А.Г., Хабутя М.Ш. *Руководство по скорой медицинской помощи*. М.: ГЭОТАР-Медиа; 2006.

4. Обзор обновленных рекомендаций American Heart Association по СЛР и неотложной помощи при сердечно-сосудистых заболеваниях от 2015 г. Режим доступа: <https://association-ar.ru/wp-content/uploads/2019/04/3-Obnovlennye-klinicheskie-rekomendacii-Amerikanskoj-Associacii-Serdca-po-legochnoj-reanimacii.pdf>
5. Clinical Practice Guidelines: Cardiac/Cardiac arrest, Version February 2015, Queensland Government.
6. European Resuscitation Council Guidelines for Resuscitation 2010.
7. Neumar R. W., Shuster M., Callaway C. W., et al. Part 1: executive summary: 2015 American Heart Association Guidelines Update for Cardiopulmonary Resuscitation and Emergency Cardiovascular Care. *Circulation*. 2015; 132(18 Suppl 2):S315–367. DOI: 10.1161/CIR.0000000000000252
8. Hazinski M. F., Nolan J. P., Aicken R., et al. Part 1: executive summary: 2015 International Consensus on Cardiopulmonary Resuscitation and Emergency Cardiovascular Care Science With Treatment Recommendations. *Circulation*. 2015;132(16 Suppl 1):S2–39. DOI: 10.1161/CIR.0000000000000270
9. Warner W. D., Cobb L. A., Dennis D., et al. Amplitude of ventricular fibrillation waveform and outcome after cardiac arrest. *Annals of Internal Medicine*. 1985;102(1):53–55. DOI: 10.7326/0003-4819-102-1-53
10. Mattioni T. A., Nademanee K., Brodsky M., et al. Initial clinical experience with a fully automatic in-hospital external cardioverter defibrillator. *PACE*. 1999;22(11):1648–1655. DOI: 10.1111/j.1540-8159.1999.tb00385.x
11. Zhang X.-S., Lin D. *System and method for complexity analysis-based cardiac tachyarrhythmia detection*. USA, 2002, patent No. 6490478.
12. Kerber R. E., Becker L. B., Bourland J. D., et al. Automatic external defibrillators for public access defibrillation: recommendations for specifying and reporting arrhythmia analysis algorithm performance, incorporating new waveforms, and enhancing safety. *Circulation*. 1997;95(6):1677–1682. DOI: 10.1161/01.cir.95.6.1677
13. Flores N., Avitia R. L., Reyna M. A., Garcí C. Readily available ECG databases. *Journal of Electrocardiology*. 2018;51(6):1095–1097. DOI: 10.1016/j.jelectrocard.2018.09.012
14. Nguyen M. T., Shahzad A., Van Nguyen B., Kim K., Diagnosis of shockable rhythms for automated external defibrillators using a reliable support vector machine classifier. *Biomedical Signal Processing and Control*. 2018;44:258–270. DOI: 10.1016/j.bspc.2018.03.014
15. Cheng P., Dong X. Life-threatening ventricular arrhythmia detection with personalized features. *IEEE Access*. 2017;5:14195–14203. DOI: 10.1109/ACCESS.2017.2723258
16. Nguyen M. T., Van Nguyen B., Kim K. Shockable rhythm diagnosis for automated external defibrillators using a modified variational mode decomposition technique. *IEEE Transactions on Industrial Informatics*. 2017;13(6):3037–3046. DOI: 10.1109/TII.2017.2740435

17. Tripathy R.K., Sharma L.N., Dandapat S. Detection of shockable ventricular arrhythmia using variational mode decomposition. *Journal of Medical Systems*. 2016;40(4):79. DOI: 10.1007/s10916-016-0441-5
18. Figuera C., Irusta U., Morgado E., Aramendi E., Ayala U., Wik L., Kramer-Johansen J., Eftestøl T., Alonso-Atienza F., Machine learning techniques for the detection of shockable rhythms in automated external defibrillators. *PLoS One*. 2016;11. DOI: 10.1371/journal.pone.0159654
19. Oh S.L., Hagiwara Y., Adam M., Sudarshan V.K., Koh J.E., Tan J.H., Chua C.K., Tan R.S., Ng E.Y.K. Shockable versus nonshockable life-threatening ventricular arrhythmias using dwt and nonlinear features of ECG signals. *Journal of Mechanics in Medicine and Biology*. 2017;17(7):1740004. DOI: 10.1142/S0219519417400048
20. Sharma M., Tan R.-S., Acharya U.R. Detection of shockable ventricular arrhythmia using optimal orthogonal wavelet filters. *Neural Computing and Applications*. 2020;32(20):15869–15884. DOI: 10.1007/s00521-019-04061-8
21. Sharma M., Singh S., Kumar A., San Tan R., Acharya U.R. Automated detection of shockable and non-shockable arrhythmia using novel wavelet-based ECG features. *Computers in Biology and Medicine*. 2019;115:103446. DOI: 10.1016/j.compbimed.2019.103446
22. Pan J., Tompkins W.J. A real-time QRS detection algorithm. *IEEE Transactions on Biomedical Engineering*. 1985;BME-32(3):230–236. DOI: 10.1109/TBME.1985.325532
23. Thakor N.V., Zhu Y.S., Pan K.Y. Ventricular Tachycardia and fibrillation detection by a sequential hypothesis testing algorithm. *IEEE Transactions on Biomedical Engineering*. 1990;37(9):837–843. DOI: 10.1109/10.58594
24. Arafat M.A., Chowdhury A.W., Hasan M.K. A simple time domain algorithm for the detection of ventricular fibrillation in electrocardiogram. *Signal, Image and Video Processing*. 2011;5(1):1–10. DOI: 10.1007/s11760-009-0136-1
25. Anas E., Lee S.Y., Hasan M.K. Sequential algorithm for life threatening cardiac pathologies detection based on mean signal strength and EMD functions. *BioMedical Engineering OnLine*. 2010;9(1):43. DOI: 10.1186/1475-925X-9-43
26. Amann A., Tratnig R., Unterkofler K. Reliability of old and new ventricular fibrillation detection algorithms for automated external defibrillators. *BioMedical Engineering OnLine*. 2005;4:60. DOI: 10.1186/1475-925X-4-60
27. Jekova I., Krasteva V. Real time detection of ventricular fibrillation and tachycardia. *Physiological Measurement*. 2004;25(5):1167–1178. DOI: 10.1088/0967-3334/25/5/007
28. Irusta U., Ruiz J., Aramendi E., Ruiz de Gauna S., Ayala U., Alonso E. A high-temporal resolution algorithm to discriminate shockable from nonshockable rhythms in adults and children. *Resuscitation*. 2012;83(9):1090–1097. DOI: 10.1016/j.resuscitation.2012.01.032

29. Ayala U., Irusta U., Ruiz J., Eftestøl T., Kramer-Johansen J., Alonso-Atienza F., Alonso E., González-Otero D. A reliable method for rhythm analysis during cardiopulmonary resuscitation. *BioMed Research International*. 2014;872470. DOI: 10.1155/2014/872470
30. Kuo S., Dillman R. Computer detection of ventricular fibrillation. *IEEE Computers in Cardiology*. 1978:347–349.
31. Barro S., Ruiz R., Cabello D., Mira J. Algorithmic sequential decision-making in the frequency domain for life threatening ventricular arrhythmias and imitative artefacts: a diagnostic system. *Journal of Biomedical Engineering*. 1989;11(4):320–328. DOI: 10.1016/0141-5425(89)90067-8
32. Dzwonczyk R., Brown C.G., Werman H.A. The median frequency of the ECG during ventricular fibrillation: its use in an algorithm for estimating the duration of cardiac arrest. *IEEE Transactions on Biomedical Engineering*. 1990;37(6):640–646. DOI: 10.1109/10.55668
33. Zhdanov A.E. et al. OculusGraphy: Literature Review on Electrophysiological Research Methods in Ophthalmology and Electroretinograms Processing Using Wavelet Transform. In: *2020 International Conference on e-Health and Bioengineering (EHB), Iasi, Romania, 29–30 Oct. 2020*. IEEE; 2020, pp. 1–6. DOI: 10.1109/EHB50910.2020.9280221
34. 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. *Physiological Measurement*. 2008;29(1):15–32. DOI: 10.1088/0967-3334/29/1/002
35. Li Y., Bisera J., Weil M.H., Tang W. An algorithm used for ventricular fibrillation detection without interrupting chest compression. *IEEE Transactions on Biomedical Engineering*. 2012;59(1):78–86. DOI: 10.1109/TBME.2011.2118755
36. Amann A., Tratnig R., Unterkofler K. Detecting ventricular fibrillation by time-delay methods. *IEEE Transactions on Biomedical Engineering*. 2007;54(1):174–177. DOI: 10.1109/TBME.2006.880909
37. Zhang X.S., Zhu Y.S., Thakor N.V., Wang Z.Z. Detecting ventricular tachycardia and fibrillation by complexity measure. *IEEE Transactions on Biomedical Engineering*. 1999;46(5):548–555. DOI: 10.1109/10.759055
38. Singh V., Gupta A., Sohal J.S., Singh A. A unified non-linear approach based on recurrence quantification analysis and approximate entropy: application to the classification of heart rate variability of age-stratified subjects. *Medical & Biological Engineering & Computing*. 2019;57(3):741–755. DOI: 10.1007/s11517-018-1914-0
39. Singh R.S., Saini B.S., Sunkaria R.K. Arrhythmia detection based on time–frequency features of heart rate variability and back-propagation neural network. *Iran Journal of Computer Science*. 2019;2(4):245–257. DOI: 10.1007/s42044-019-00042-1
40. Lake D.E., Richman J.S., Griffin M.P., Moorman J.R. Sample entropy analysis of neonatal heart rate variability. *American Journal*

of *Physiology-Regulatory, Integrative and Comparative Physiology*. 2002;283(3):R789–R797. DOI: 10.1152/ajpregu.00069.2002

41. Yin J., Xiao P., Li J., Liu Y., Yan C., Zhang Y. Parameters analysis of sample entropy, permutation entropy and permutation ratio entropy for RR interval time series. *Information Processing & Management*. 2020;57(5):102283. DOI: 10.1016/j.ipm.2020.102283

42. Sinha N., Das A. Automatic diagnosis of cardiac arrhythmias based on three stage feature fusion and classification model using DWT. *Biomedical Signal Processing and Control*. 2020;62:102066. DOI: 10.1016/j.bspc.2020.102066

43. Acharya U. R., Hagiwara Y., Deshpande S. N., Suren S., Koh J. E. W., Oh S. L., Arunkumar N., Ciaccio E. J., Lim C. M. Characterization of focal EEG signals: a review. *Future Generation Computer Systems*. 2019;91:290–299. DOI: 10.1016/j.future.2018.08.044

44. Nikias C. L., Mendel J. M. Signal processing with higher-order spectra. *IEEE Signal Processing Magazine*. 1993;10(3):10–37. DOI: 10.1109/79.221324

45. Oppenheim A. V., Verghese G. C. Signals, Systems and Inference, complete notes. Class Notes for 6.011: Introduction to Communication, Control and Signal Processing Spring 2010. Available at: https://mitocw.ups.edu.ec/courses/electrical-engineering-and-computer-science/6-011-introduction-to-communication-control-and-signal-processing-spring-2010/readings/MIT6_011S10_notes.pdf (accessed November 29, 2021).

46. Zbilut J. P., Webber C. L. Embeddings and delays as derived from quantification of recurrence plots. *Physics Letters A*. 1992;171(3-4):199–203. DOI: 10.1016/0375-9601(92)90426-M

47. Eckmann J.-P., Kamphorst S. O., Ruelle D. Recurrence plots of dynamical systems. *Europhysics Letters*. 1987;4(9):973–977. DOI: 10.1209/0295-5075/4/9/004

48. Marwan N. A historical review of recurrence plots. *The European Physical Journal Special Topics*. 2008;164(1):3–12. DOI: 10.1140/epjst/e2008-00829-1

49. Blum A. L., Langley P. Selection of relevant features and examples in machine learning. *Artificial Intelligence*. 1997;97(1-2):245–271. DOI: 10.1016/S0004-3702(97)00063-5

50. Granitto P. M., Furlanello C., Biasioli F., Gasperi F. Recursive feature elimination with random forest for PTR-MS analysis of agroindustrial products. *Chemometrics and Intelligent Laboratory Systems*. 2006;83(2):83–90. DOI: 10.1016/j.chemolab.2006.01.007

51. Ververidis D., Kotropoulos C. Fast and accurate sequential floating forward feature selection with the Bayes classifier applied to speech emotion recognition. *Signal Processing*. 2008;88(12):2956–2970. DOI: 10.1016/j.sigpro.2008.07.001

52. Pławiak P. Novel genetic ensembles of classifiers applied to myocardium dysfunction recognition based on ECG signals. *Swarm and Evolutionary Computation*. 2018;39:192–208. DOI: 10.1016/j.swevo.2017.10.002

53. Lehmann E. L., Romano J. P. *Testing Statistical Hypotheses*. 3rd ed. Springer, n.d. (accessed November 29, 2020).
54. Fisher R. A. Statistical methods for research workers. In: Kotz S., Johnson N. L. (eds) *Breakthroughs in Statistics*. Springer; 1992, pp. 66–70. DOI: 10.1007/978-1-4612-4380-9_6
55. Kira K., Rendell L. A. The Feature Selection Problem: Traditional Methods and a New Algorithm. In: *AAAI-92 Proceedings*. 1992, pp. 129–134. Available at: <https://aaai.org/Papers/AAAI/1992/AAAI92-020.pdf> (accessed November 29, 2020).
56. Park M. Y., Hastie T. *L_1 Regularization Path Algorithm for Generalized Linear Models*. 2006. Available at: <https://hastie.su.domains/Papers/glmpath.jrssl.pdf>
57. Raghavendra U., Rajendra Acharya U., Fujita H., Gudigar A., Tan J. H., Chokkadi S. Application of Gabor wavelet and Locality Sensitive Discriminant Analysis for automated identification of breast cancer using digitized mammogram images. *Applied Soft Computing*. 2016;46:151–161. DOI: 10.1016/j.asoc.2016.04.036
58. Miotto R., Wang F., Wang S., Jiang X., Dudley J. T. Deep learning for healthcare: Review, opportunities and challenges. *Briefings in Bioinformatics*. 2018;19(6):1236–1246. DOI: 10.1093/bib/bbx044
59. Esteva A., Robicquet A., Ramsundar B., Kuleshov V., DePristo M., Chou K., Cui C., Corrado G., Thrun S., Dean J. A guide to deep learning in healthcare. *Nature Medicine*. 2019;25(1):24–29. DOI: 10.1038/s41591-018-0316-z
60. Zhang W. Shift-invariant pattern recognition neural network and its optical architecture. In: *Proceedings of Annual Conference of the Japan Society of Applied Physics*. 1988.
61. Lawrence S., Giles C. L., Ah Chung Tsoi, Back A. D. Face recognition: a convolutional neural-network approach. *IEEE Transactions on Neural Networks*. 1997;8(1):98–113. DOI: 10.1109/72.554195
62. Graves A., Mohamed A., Hinton G. Speech recognition with deep recurrent neural networks. In: *2013 IEEE International Conference on Acoustics, Speech and Signal Processing, Vancouver, 26–31 May 2013*. IEEE; 2013, pp. 6645–6649. DOI: 10.1109/ICASSP.2013.6638947.
63. IEC 60601-2-4:2002, Medical electrical equipment – Part 2-4: General requirements for safety– Particular requirements for the safety of cardiac defibrillators.
64. Kong D., Zhu J., Wu S., Duan C., Lu L., Chen D. A novel IRBF-RVM model for diagnosis of atrial fibrillation. *Computer Methods and Programs in Biomedicine*. 2019;177:183–192. DOI: 10.1016/j.cmpb.2019.05.028
65. Buscema P. M., Grossi E., Massini G., Breda M., Della F. Torre, Computer Aided Diagnosis for atrial fibrillation based on new artificial adaptive systems. *Computer Methods and Programs in Biomedicine*. 2020;191:105401. DOI: 10.1016/j.cmpb.2020.105401
66. Kumar M., Pachori R. B., Rajendra Acharya U., Acharya U. R. Automated diagnosis of atrial fibrillation ECG signals using entropy

features extracted from flexible analytic wavelet transform. *Biocybernetics and Biomedical Engineering*. 2018;38(3):564–573. DOI: 10.1016/j.bbe.2018.04.004

67. Islam M.S., Ammour N., Alajlan N., Aboalsamh H., Rhythm-based heartbeat duration normalization for atrial fibrillation detection. *Computers in Biology and Medicine*. 2016;72:160–169. DOI: 10.1016/j.compbimed.2016.03.015

68. Baalman S.W.E.E., Schroevers F.E., Oakley A.J., Brouwer T.F., van der Stuijt W., Bleijendaal H., Ramos L.A., Lopes R.R., Marquering H.A., Knops R.E., de Groot J.R. A morphology based deep learning model for atrial fibrillation detection using single cycle electrocardiographic samples. *International Journal of Cardiology*. 2020;316:130–136. DOI: 10.1016/j.ijcard.2020.04.046

69. Panda R., Jain S., Tripathy R.K., Acharya U.R. Detection of shockable ventricular cardiac arrhythmias from ECG signals using FFREWT filter-bank and deep convolutional neural network. *Computers in Biology and Medicine*. 2020;124:103939. DOI: 10.1016/j.compbimed.2020.103939

70. Acharya U.R., Fujita H., Oh S.L., Raghavendra U., Tan J.H., Adam M., Gertych A., Hagiwara Y. Automated identification of shockable and non-shockable life-threatening ventricular arrhythmias using convolutional neural network. *Future Generation Computer Systems*. 2018;79(3):952–959. DOI: 10.1016/j.future.2017.08.039

71. Dang H., Sun M., Zhang G., Qi X., Zhou X., Chang Q. A novel deep arrhythmia-diagnosis network for atrial fibrillation classification using electrocardiogram signals. *IEEE Access*. 2019;7:75577–75590. DOI: 10.1109/ACCESS.2019.2918792

72. Li Z., Feng X., Wu Z., Yang C., Bai B., Yang Q. Classification of atrial fibrillation recurrence based on a convolution neural network with SVM architecture. *IEEE Access*. 2019;7:77849–77856. DOI: 10.1109/ACCESS.2019.2920900

73. Wang J. A deep learning approach for atrial fibrillation signals classification based on convolutional and modified Elman neural network. *Future Generation Computer Systems*. 2020;102:670–679. DOI: 10.1016/j.future.2019.09.012

References

1. Gurvich N. L. *Basic principles of cardiac defibrillation*. Moscow: Medicine; 1977. 180 p. (In Russ.)
2. Diack A. W., Welborn W.S., Rullman R.G., Walter C. W., Wayne M.A. An automatic cardiac resuscitator for emergency treatment of cardiac arrest. *Medical Instrumentation*. 1979;13(2):78–83. PMID: 431428.
3. Bagnenko S. F., Vertkin A. L., Miroshnichenko A. G., Khabutia M.Sh. *Emergency Medical Guide*. Moscow: GEOTAR-Media; 2006. (In Russ.)
4. Overview of updated American Heart Association recommendations for CPR and emergency care for cardiovascular diseases from 2015. (In Russ.)

Available at: <https://association-ar.ru/wp-content/uploads/2019/04/3-Obnovlennye-klinicheskie-rekomendacii-Amerikanskoj-Associacii-Serdca-po-legochnoj-reanimacii.pdf>

5. Clinical Practice Guidelines: Cardiac/Cardiac arrest, Version February 2015, Queensland Government.

6. European Resuscitation Council Guidelines for Resuscitation 2010.

7. Neumar R. W., Shuster M., Callaway C. W., et al. Part 1: executive summary: 2015 American Heart Association Guidelines Update for Cardiopulmonary Resuscitation and Emergency Cardiovascular Care. *Circulation*. 2015; 132(18 Suppl 2):S315–367. DOI: 10.1161/CIR.0000000000000252

8. Hazinski M. F., Nolan J. P., Aicken R., et al. Part 1: executive summary: 2015 International Consensus on Cardiopulmonary Resuscitation and Emergency Cardiovascular Care Science With Treatment Recommendations. *Circulation*. 2015;132(16 Suppl 1):S2–39. DOI: 10.1161/CIR.0000000000000270

9. Warner W. D., Cobb L. A., Dennis D., et al. Amplitude of ventricular fibrillation waveform and outcome after cardiac arrest. *Annals of Internal Medicine*. 1985;102(1):53–55. DOI: 10.7326/0003-4819-102-1-53

10. Mattioni T. A., Nademanee K., Brodsky M., et al. Initial clinical experience with a fully automatic in-hospital external cardioverter defibrillator. *PACE*. 1999;22(11):1648–1655. DOI: 10.1111/j.1540-8159.1999.tb00385.x

11. Zhang X.-S., Lin D. System and method for complexity analysis-based cardiac tachyarrhythmia detection. USA, 2002, patent No. 6490478.

12. Kerber R. E., Becker L. B., Bourland J. D., et al. Automatic external defibrillators for public access defibrillation: recommendations for specifying and reporting arrhythmia analysis algorithm performance, incorporating new waveforms, and enhancing safety. *Circulation*. 1997;95(6):1677–1682. DOI: 10.1161/01.cir.95.6.1677

13. Flores N., Avitia R. L., Reyna M. A., Garcí C. Readily available ECG databases. *Journal of Electrocardiology*. 2018;51(6):1095–1097. DOI: 10.1016/j.jelectrocard.2018.09.012

14. Nguyen M. T., Shahzad A., Van Nguyen B., Kim K., Diagnosis of shockable rhythms for automated external defibrillators using a reliable support vector machine classifier. *Biomedical Signal Processing and Control*. 2018;44:258–270. DOI: 10.1016/j.bspc.2018.03.014

15. Cheng P., Dong X. Life-threatening ventricular arrhythmia detection with personalized features. *IEEE Access*. 2017;5:14195–14203. DOI: 10.1109/ACCESS.2017.2723258

16. Nguyen M. T., Van Nguyen B., Kim K. Shockable rhythm diagnosis for automated external defibrillators using a modified variational mode decomposition technique. *IEEE Transactions on Industrial Informatics*. 2017;13(6):3037–3046. DOI: 10.1109/TII.2017.2740435

17. Tripathy R. K., Sharma L. N., Dandapat S. Detection of shockable ventricular arrhythmia using variational mode decomposition. *Journal of Medical Systems*. 2016;40(4):79. DOI: 10.1007/s10916-016-0441-5

18. Figuera C., Irusta U., Morgado E., Aramendi E., Ayala U., Wik L., Kramer-Johansen J., Eftestøl T., Alonso-Atienza F., Machine learning techniques for the detection of shockable rhythms in automated external defibrillators. *PLoS One*. 2016;11. DOI: 10.1371/journal.pone.0159654

19. Oh S.L., Hagiwara Y., Adam M., Sudarshan V.K., Koh J.E., Tan J.H., Chua C.K., Tan R.S., Ng E.Y.K. Shockable versus nonshockable life-threatening ventricular arrhythmias using dwt and nonlinear features of ECG signals. *Journal of Mechanics in Medicine and Biology*. 2017;17(7):1740004. DOI: 10.1142/S0219519417400048

20. Sharma M., Tan R.-S., Acharya U.R. Detection of shockable ventricular arrhythmia using optimal orthogonal wavelet filters. *Neural Computing and Applications*. 2020;32(20):15869–15884. DOI: 10.1007/s00521-019-04061-8

21. Sharma M., Singh S., Kumar A., San Tan R., Acharya U.R. Automated detection of shockable and non-shockable arrhythmia using novel wavelet-based ECG features. *Computers in Biology and Medicine*. 2019;115:103446. DOI: 10.1016/j.compbiomed.2019.103446

22. Pan J., Tompkins W.J. A real-time QRS detection algorithm. *IEEE Transactions on Biomedical Engineering*. 1985;BME-32(3):230–236. DOI: 10.1109/TBME.1985.325532

23. Thakor N.V., Zhu Y.S., Pan K.Y. Ventricular Tachycardia and fibrillation detection by a sequential hypothesis testing algorithm. *IEEE Transactions on Biomedical Engineering*. 1990;37(9):837–843. DOI: 10.1109/10.58594

24. Arafat M.A., Chowdhury A.W., Hasan M.K. A simple time domain algorithm for the detection of ventricular fibrillation in electrocardiogram. *Signal, Image and Video Processing*. 2011;5(1):1–10. DOI: 10.1007/s11760-009-0136-1

25. Anas E., Lee S.Y., Hasan M.K. Sequential algorithm for life threatening cardiac pathologies detection based on mean signal strength and EMD functions. *BioMedical Engineering OnLine*. 2010;9(1):43. DOI: 10.1186/1475-925X-9-43

26. Amann A., Tratnig R., Unterkofler K. Reliability of old and new ventricular fibrillation detection algorithms for automated external defibrillators. *BioMedical Engineering OnLine*. 2005;4:60. DOI: 10.1186/1475-925X-4-60

27. Jekova I., Krasteva V. Real time detection of ventricular fibrillation and tachycardia. *Physiological Measurement*. 2004;25(5):1167–1178. DOI: 10.1088/0967-3334/25/5/007

28. Irusta U., Ruiz J., Aramendi E., Ruiz de Gauna S., Ayala U., Alonso E. A high-temporal resolution algorithm to discriminate shockable from nonshockable rhythms in adults and children. *Resuscitation*. 2012;83(9):1090–1097. DOI: 10.1016/j.resuscitation.2012.01.032

29. Ayala U., Irusta U., Ruiz J., Eftestøl T., Kramer-Johansen J., Alonso-Atienza F., Alonso E., González-Otero D. A reliable method for rhythm analysis during cardiopulmonary resuscitation. *BioMed Research International*. 2014:872470. DOI: 10.1155/2014/872470

30. Kuo S., Dillman R. Computer detection of ventricular fibrillation. *IEEE Computers in Cardiology*. 1978:347–349.
31. Barro S., Ruiz R., Cabello D., Mira J. Algorithmic sequential decision-making in the frequency domain for life threatening ventricular arrhythmias and imitative artefacts: a diagnostic system. *Journal of Biomedical Engineering*. 1989;11(4):320–328. DOI: 10.1016/0141-5425(89)90067-8
32. Dzwonczyk R., Brown C.G., Werman H.A. The median frequency of the ECG during ventricular fibrillation: its use in an algorithm for estimating the duration of cardiac arrest. *IEEE Transactions on Biomedical Engineering*. 1990;37(6):640–646. DOI: 10.1109/10.55668
33. Zhdanov A.E. et al. OculusGraphy: Literature Review on Electrophysiological Research Methods in Ophthalmology and Electroretinograms Processing Using Wavelet Transform. In: *2020 International Conference on e-Health and Bioengineering (EHB), Iasi, Romania, 29–30 Oct. 2020*. IEEE; 2020, pp. 1–6. DOI: 10.1109/EHB50910.2020.9280221
34. 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. *Physiological Measurement*. 2008;29(1):15–32. DOI: 10.1088/0967-3334/29/1/002
35. Li Y., Bisera J., Weil M.H., Tang W. An algorithm used for ventricular fibrillation detection without interrupting chest compression. *IEEE Transactions on Biomedical Engineering*. 2012;59(1):78–86. DOI: 10.1109/TBME.2011.2118755
36. Amann A., Tratnig R., Unterkofler K. Detecting ventricular fibrillation by time-delay methods. *IEEE Transactions on Biomedical Engineering*. 2007;54(1):174–177. DOI: 10.1109/TBME.2006.880909
37. Zhang X.S., Zhu Y.S., Thakor N.V., Wang Z.Z. Detecting ventricular tachycardia and fibrillation by complexity measure. *IEEE Transactions on Biomedical Engineering*. 1999;46(5):548–555. DOI: 10.1109/10.759055
38. Singh V., Gupta A., Sohal J.S., Singh A. A unified non-linear approach based on recurrence quantification analysis and approximate entropy: application to the classification of heart rate variability of age-stratified subjects. *Medical & Biological Engineering & Computing*. 2019;57(3):741–755. DOI: 10.1007/s11517-018-1914-0
39. Singh R.S., Saini B.S., Sunkaria R.K. Arrhythmia detection based on time-frequency features of heart rate variability and back-propagation neural network. *Iran Journal of Computer Science*. 2019;2(4):245–257. DOI: 10.1007/s42044-019-00042-1
40. Lake D.E., Richman J.S., Griffin M.P., Moorman J.R. Sample entropy analysis of neonatal heart rate variability. *American Journal of Physiology-Regulatory, Integrative and Comparative Physiology*. 2002;283(3):R789–R797. DOI: 10.1152/ajpregu.00069.2002
41. Yin J., Xiao P., Li J., Liu Y., Yan C., Zhang Y. Parameters analysis of sample entropy, permutation entropy and permutation ratio entropy

for RR interval time series. *Information Processing & Management*. 2020;57(5):102283. DOI: 10.1016/j.ipm.2020.102283

42. Sinha N., Das A. Automatic diagnosis of cardiac arrhythmias based on three stage feature fusion and classification model using DWT. *Biomedical Signal Processing and Control*. 2020;62:102066. DOI: 10.1016/j.bspc.2020.102066

43. Acharya U. R., Hagiwara Y., Deshpande S. N., Suren S., Koh J. E. W., Oh S. L., Arunkumar N., Ciaccio E. J., Lim C. M. Characterization of focal EEG signals: a review. *Future Generation Computer Systems*. 2019;91:290–299. DOI: 10.1016/j.future.2018.08.044

44. Nikias C. L., Mendel J. M. Signal processing with higher-order spectra. *IEEE Signal Processing Magazine*. 1993;10(3):10–37. DOI: 10.1109/79.221324

45. Oppenheim A. V., Verghese G. C. Signals, Systems and Inference, complete notes. Class Notes for 6.011: Introduction to Communication, Control and Signal Processing Spring 2010. Available at: https://mitocw.ups.edu.ec/courses/electrical-engineering-and-computer-science/6-011-introduction-to-communication-control-and-signal-processing-spring-2010/readings/MIT6_011S10_notes.pdf (accessed November 29, 2021).

46. Zbilut J. P., Webber C. L. Embeddings and delays as derived from quantification of recurrence plots. *Physics Letters A*. 1992;171(3-4):199–203. DOI: 10.1016/0375-9601(92)90426-M

47. Eckmann J.-P., Kamphorst S. O., Ruelle D. Recurrence plots of dynamical systems. *Europhysics Letters*. 1987;4(9):973–977. DOI: 10.1209/0295-5075/4/9/004

48. Marwan N. A historical review of recurrence plots. *The European Physical Journal Special Topics*. 2008;164(1):3–12. DOI: 10.1140/epjst/e2008-00829-1

49. Blum A. L., Langley P. Selection of relevant features and examples in machine learning. *Artificial Intelligence*. 1997;97(1-2):245–271. DOI: 10.1016/S0004-3702(97)00063-5

50. Granitto P. M., Furlanello C., Biasioli F., Gasperi F. Recursive feature elimination with random forest for PTR-MS analysis of agroindustrial products. *Chemometrics and Intelligent Laboratory Systems*. 2006;83(2):83–90. DOI: 10.1016/j.chemolab.2006.01.007

51. Ververidis D., Kotropoulos C. Fast and accurate sequential floating forward feature selection with the Bayes classifier applied to speech emotion recognition. *Signal Processing*. 2008;88(12):2956–2970. DOI: 10.1016/j.sigpro.2008.07.001

52. Pławiak P. Novel genetic ensembles of classifiers applied to myocardium dysfunction recognition based on ECG signals. *Swarm and Evolutionary Computation*. 2018;39:192–208. DOI: 10.1016/j.swevo.2017.10.002

53. Lehmann E. L., Romano J. P. *Testing Statistical Hypotheses*. 3rd ed. Springer, n.d. (accessed November 29, 2020).

54. Fisher R. A. Statistical methods for research workers. In: Kotz S., Johnson N. L. (eds) *Breakthroughs in Statistics*. Springer; 1992, pp. 66–70. DOI: 10.1007/978-1-4612-4380-9_6
55. Kira K., Rendell L. A. The Feature Selection Problem: Traditional Methods and a New Algorithm. In: *AAAI-92 Proceedings*. 1992, pp. 129–134. Available at: <https://aaai.org/Papers/AAAI/1992/AAAI92-020.pdf> (accessed November 29, 2020).
56. Park M. Y., Hastie T. *L_1 Regularization Path Algorithm for Generalized Linear Models*. 2006. Available at: <https://hastie.su.domains/Papers/glmppath.jrssb.pdf>
57. Raghavendra U., Rajendra Acharya U., Fujita H., Gudigar A., Tan J. H., Chokkadi S. Application of Gabor wavelet and Locality Sensitive Discriminant Analysis for automated identification of breast cancer using digitized mammogram images. *Applied Soft Computing*. 2016;46:151–161. DOI: 10.1016/j.asoc.2016.04.036
58. Miotto R., Wang F., Wang S., Jiang X., Dudley J. T. Deep learning for healthcare: Review, opportunities and challenges. *Briefings in Bioinformatics*. 2018;19(6):1236–1246. DOI: 10.1093/bib/bbx044
59. Esteva A., Robicquet A., Ramsundar B., Kuleshov V., DePristo M., Chou K., Cui C., Corrado G., Thrun S., Dean J. A guide to deep learning in healthcare. *Nature Medicine*. 2019;25(1):24–29. DOI: 10.1038/s41591-018-0316-z
60. Zhang W. Shift-invariant pattern recognition neural network and its optical architecture. In: *Proceedings of Annual Conference of the Japan Society of Applied Physics*. 1988.
61. Lawrence S., Giles C. L., Ah Chung Tsoi, Back A. D. Face recognition: a convolutional neural-network approach. *IEEE Transactions on Neural Networks*. 1997;8(1):98–113. DOI: 10.1109/72.554195
62. Graves A., Mohamed A., Hinton G. Speech recognition with deep recurrent neural networks. In: *2013 IEEE International Conference on Acoustics, Speech and Signal Processing, Vancouver, 26–31 May 2013*. IEEE; 2013, pp. 6645–6649. DOI: 10.1109/ICASSP.2013.6638947.
63. IEC 60601-2-4:2002, Medical electrical equipment – Part 2-4: General requirements for safety– Particular requirements for the safety of cardiac defibrillators.
64. Kong D., Zhu J., Wu S., Duan C., Lu L., Chen D. A novel IRBF-RVM model for diagnosis of atrial fibrillation. *Computer Methods and Programs in Biomedicine*. 2019;177:183–192. DOI: 10.1016/j.cmpb.2019.05.028
65. Buscema P. M., Grossi E., Massini G., Breda M., Della F. Torre, Computer Aided Diagnosis for atrial fibrillation based on new artificial adaptive systems. *Computer Methods and Programs in Biomedicine*. 2020;191:105401. DOI: 10.1016/j.cmpb.2020.105401
66. Kumar M., Pachori R. B., Rajendra Acharya U., Acharya U. R. Automated diagnosis of atrial fibrillation ECG signals using entropy features extracted from flexible analytic wavelet transform. *Biocybernetics*

and *Biomedical Engineering*. 2018;38(3):564–573. DOI: 10.1016/j.bbe.2018.04.004

67. Islam M.S., Ammour N., Alajlan N., Aboalsamh H., Rhythm-based heartbeat duration normalization for atrial fibrillation detection. *Computers in Biology and Medicine*. 2016;72:160–169. DOI: 10.1016/j.compbimed.2016.03.015

68. Baalman S.W.E.E., Schroevers F.E., Oakley A.J., Brouwer T.F., van der Stuijt W., Bleijendaal H., Ramos L.A., Lopes R.R., Marquering H.A., Knops R.E., de Groot J.R. A morphology based deep learning model for atrial fibrillation detection using single cycle electrocardiographic samples. *International Journal of Cardiology*. 2020;316:130–136. DOI: 10.1016/j.ijcard.2020.04.046

69. Panda R., Jain S., Tripathy R.K., Acharya U.R. Detection of shockable ventricular cardiac arrhythmias from ECG signals using FFREWT filter-bank and deep convolutional neural network. *Computers in Biology and Medicine*. 2020;124:103939. DOI: 10.1016/j.compbimed.2020.103939

70. Acharya U.R., Fujita H., Oh S.L., Raghavendra U., Tan J.H., Adam M., Gertych A., Hagiwara Y. Automated identification of shockable and non-shockable life-threatening ventricular arrhythmias using convolutional neural network. *Future Generation Computer Systems*. 2018;79(3):952–959. DOI: 10.1016/j.future.2017.08.039

71. Dang H., Sun M., Zhang G., Qi X., Zhou X., Chang Q. A novel deep arrhythmia-diagnosis network for atrial fibrillation classification using electrocardiogram signals. *IEEE Access*. 2019;7:75577–75590. DOI: 10.1109/ACCESS.2019.2918792

72. Li Z., Feng X., Wu Z., Yang C., Bai B., Yang Q. Classification of atrial fibrillation recurrence based on a convolution neural network with SVM architecture. *IEEE Access*. 2019;7:77849–77856. DOI: 10.1109/ACCESS.2019.2920900

73. Wang J. A deep learning approach for atrial fibrillation signals classification based on convolutional and modified Elman neural network. *Future Generation Computer Systems*. 2020;102:670–679. DOI: 10.1016/j.future.2019.09.012

Информация об авторах

Липчак Дарья Александровна, ведущий инженер-программист конструкторского бюро медицинских изделий АО «Производственное объединение “Уральский оптико-механический завод” имени Э. С. Яламова» (Екатеринбург, Россия), магистр по специальности «Электроника и телекоммуникации» (выдан Ляонинским политехническим университетом (Цзиньчжоу, КНР)).

Чупов Алексей Александрович, аспирант департамента радиоэлектроники и связи, Уральский федеральный университет им. первого Президента России Б. Н. Ельцина (Екатеринбург, Россия), главный конструктор конструкторского бюро медицинских изделий АО «Производственное объединение “Уральский оптико-механический завод” имени Э. С. Яламова» (Екатеринбург, Россия).

Information about the authors

Daria Lipchak, Senior Software Engineer, Medical Devices Research and Development Bureau, Joint Stock Company “Production Association Urals Optical & Mechanical Plant” named after Mr. E. S. Yalamov” (Ekaterinburg, Russia); Master in Electronics and Telecommunications, Liaoning University of Science and Technology (China).

Alexey A. Chupov, postgraduate student, Engineering School of Information Technologies, Telecommunications and Control Systems, Ural Federal University named after the first President of Russia B. N. Yeltsin, Russia; Chief Designer, Medical Devices Research and Development Bureau, Joint Stock Company “Production Association “Urals Optical & Mechanical Plant” named after Mr. E. S. Yalamov” (Ekaterinburg, Russia).

Поступила / Received: 19.12.2021

Принята в печать / Accepted: 18.01.2022