

ПРОГРАММНЫЙ КОМПЛЕКС «КИБЕРСЕРДЦЕ-ДИАГНОСТИКА» ДЛЯ АВТОМАТИЧЕСКОГО АНАЛИЗА ЭЛЕКТРОКАРДИОГРАММ С ПРИМЕНЕНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

DOI: 10.17691/stm2019.11.2.12

УДК 616.12–073.7:615.47

Поступила 9.09.2018 г.

В.А. Москаленко, магистрант¹;А.В. Никольский, к.м.н., сердечно-сосудистый хирург²;Н.Ю. Золотых, д.ф.-м.н., доцент, профессор кафедры алгебры, геометрии и дискретной математики¹;А.А. Козлов, анестезиолог-реаниматолог³;К.А. Косоногов, к.м.н., сердечно-сосудистый хирург²;А.И. Калякулина, аспирант¹;И.И. Юсипов, аспирант¹;В.М. Леванов, д.м.н., доцент, профессор кафедры социальной медицины и организации здравоохранения⁴

¹Национальный исследовательский Нижегородский государственный университет им. Н.И. Лобачевского, пр. Гагарина, 23, Н. Новгород, 603950;

²Городская клиническая больница №5, ул. Нестерова, 34, Н. Новгород, 603005;

³Нижегородская областная клиническая больница им. Н.А. Семашко, ул. Родионова, 190, Н. Новгород, 603126;

⁴Приволжский исследовательский медицинский университет, пл. Минина и Пожарского, 10/1, Н. Новгород, 603005

Целью работы стало создание в составе программно-аппаратного комплекса «Киберсердце» системы автоматического анализа электрокардиограмм — программного модуля «Киберсердце–Диагностика» — и выбор методов машинного обучения для ее тестирования на основе сравнительного анализа их возможностей.

Материалы и методы. При разработке программного комплекса использовали известные методы машинного обучения, работа которых строится на большой выборке размеченных данных, т.е. на базе ЭКГ с известными заключениями: метод опорных векторов, дерево решений, искусственные нейронные сети, методы квадратичного и линейного дискриминантного анализа, метод случайных подпространств, AdaBoost, случайный лес, логистическая регрессия (модель нейрона Мак-Каллока–Питтса). Для сравнительного анализа и оценки точности полученных результатов программа «Киберсердце–Диагностика» была протестирована на открытых международных базах данных ЭКГ: Arrhythmia Data Set, PhysioNet PTBDB, PhysioNet Competition 2017, а также на материалах собственной базы данных, включающей 1652 записи стандартной 12-канальной ЭКГ покоя. Все ЭКГ были описаны врачами-экспертами с формированием структурированного врачебного заключения, которое принималось как эталонное.

Результаты. В различных классах признаков точность диагностики программы «Киберсердце–Диагностика» составила 83,8–94,5%, при сравнении с заключениями врачей-экспертов — 66,3–95,1%. Таким образом, разработанная программа по качеству анализа электрокардиограмм сравнима с мировыми аналогами.

Ключевые слова: электрокардиограмма; автоматический анализ; база данных ЭКГ; методы машинного обучения.

Как цитировать: Moskalenko V.A., Nikolskiy A.V., Zolotykh N.Yu., Kozlov A.A., Kosonogov K.A., Kalyakulina A.I., Yusipov I.I., Levanov V.M. Cyberheart-Diagnostics software package for automated electrocardiogram analysis based on machine learning techniques. *Sovremennye tehnologii v medicine* 2019; 11(2): 86–91, <https://doi.org/10.17691/stm2019.11.2.12>

English

Cyberheart-Diagnostics Software Package for Automated Electrocardiogram Analysis Based on Machine Learning Techniques

V.A. Moskalenko, Graduate Student¹;A.V. Nikolskiy, MD, PhD, Cardiovascular Surgeon²;N.Yu. Zolotykh, DSc, Associate Professor, Professor, Department of Algebra, Geometry and Discrete Mathematics¹;

Для контактов: Леванов Владимир Михайлович, e-mail: levanov53@rambler.ru

A.A. Kozlov, Anesthesiologist, Resuscitator³;
 K.A. Kosonogov, MD, PhD, Cardiovascular Surgeon²;
 A.I. Kalyakulina, PhD Student¹;
 I.I. Yusipov, PhD Student¹;
 V.M. Levanov, MD, DSc, Associate Professor, Professor, Department of Social Medicine and Health Care⁴

¹National Research Lobachevsky State University of Nizhny Novgorod, 23 Prospekt Gagarina, Nizhny Novgorod, 603950, Russia;

²City Clinical Hospital No.5, 34 Nesterova St., Nizhny Novgorod, 603005, Russia;

³Nizhny Novgorod Regional Clinical Hospital named after N.A. Semashko, 190 Rodionova St., Nizhny Novgorod, 603126, Russia;

⁴Privolzhsky Research Medical University, 10/1 Minin and Pozharsky Square, Nizhny Novgorod, 603005, Russia

The aim of the study was to develop the Cyberheart-Diagnostics software module, an automated electrocardiogram analysis system being part of the Cyberheart software and hardware complex, and to select machine learning techniques for testing the system based on the comparative analysis of their capabilities.

Materials and Methods. The software package was developed using various machine learning techniques working on a large sample of labeled data, i.e. ECG database with known diagnostic conclusions: support-vector machines, decision tree, artificial neural networks, linear and quadratic discriminant analysis, the random subspace method, AdaBoost, random forest, logistic regression (McCulloch–Pitts neuron model). For comparative analysis and evaluation of the obtained results, the Cyberheart-Diagnostics software was tested using open international ECG databases: Arrhythmia Data Set, PhysioNet PTBDB, PhysioNet Competition 2017 as well as our own database comprising 1652 records of a standard 12-lead resting ECG. The ECG records were interpreted by expert physicians who then formed structured medical conclusions considered as reference.

Results. In different classes of attributes, the diagnostic accuracy of the Cyberheart-Diagnostics software appeared to be 83.8 to 94.5% as compared to the conclusions of expert doctors — 66.3 to 95.1%. Thus, the developed software is comparable with the world analogues in quality of electrocardiogram analysis.

Key words: electrocardiogram; automated analysis; ECG database; machine learning techniques.

Введение

Развитие методов автоматизированной обработки данных в сочетании с прогрессом в области телемедицинских технологий и использованием портативной медицинской аппаратуры открывает новые возможности для совершенствования методов ранней диагностики болезней системы кровообращения и дистанционного контроля состояния здоровья пациентов [1, 2]. Наиболее распространенным методом инструментальной диагностики остается электрокардиография (ЭКГ) [3]. Одним из ее перспективных направлений является создание интеллектуального электрокардиографа, т.е. автоматизированной системы расшифровки сигналов электрокардиограммы с выдачей заключения, максимально приближенного к врачебному [2, 4]. Для достижения этой цели используются алгоритмы машинного обучения на основе репрезентативной выборки ЭКГ.

В настоящее время в разных странах появляются программные продукты для современных мобильных устройств, в которых используются автоматические методы анализа ЭКГ. В то же время степень доверия к автоматической диагностике ЭКГ без участия человека остается спорным вопросом на протяжении нескольких десятилетий. Поэтому именно алгоритм, обеспечивающий необходимую точность заключения, является определяющим фактором при выборе той или иной системы.

Сотрудниками Национального исследовательско-

го Нижегородского государственного университета им. Н.И. Лобачевского создан программно-аппаратный комплекс (ПАК) «Киберсердце» для сбора, хранения и автоматического анализа разнородных медицинских данных. ПАК состоит из медицинских приборов-датчиков, контролирующих показатели сердечно-сосудистой системы, и программного обеспечения — модуля «Киберсердце–Диагностика». Задача данного модуля — автоматический анализ ЭКГ различной продолжительности с формированием доврачебного диагностического заключения.

В целях повышения точности диагностики авторами был разработан и апробирован алгоритм, включающий обучение и тестирование модуля на открытых международных базах и на структурированных врачебных заключениях.

Целью исследования стало создание в составе программно-аппаратного комплекса «Киберсердце» системы автоматического анализа электрокардиограмм — программного модуля «Киберсердце–Диагностика» — и выбор методов машинного обучения для ее тестирования на основе сравнительного анализа их возможностей.

Материалы и методы

Разработан базовый вариант программы анализа ЭКГ «Киберсердце–Диагностика», позволяющий далее проводить ее обучение. Интерфейсная часть

программы написана на языке C#, математические методы — на языке Python с использованием библиотеки матричных вычислений NumPy (www.numpy.org), библиотеки вейвлет-анализа PyWavelets (github.com/PyWavelets) и библиотеки методов машинного обучения Scikit-learn (scikit-learn.org/stable).

Создана собственная база данных («Кардиобаза»), включающая 1652 записи стандартной 12-канальной

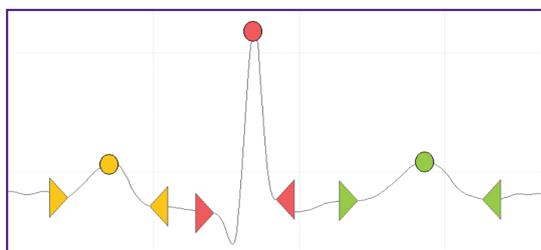


Рис. 1. Сегментация комплекса PQRST

ЭКГ покоя в цифровом формате EDF. ЭКГ были получены от взрослых пациентов в возрасте 17–80 лет, среди которых было 743 мужчины (45%) и 909 женщин (55%). ЭКГ регистрировали у пациентов, обращающихся в поликлиники Н. Новгорода за амбулаторной помощью к врачам-кардиологам, аритмологам, кардиохирургам, а также находившихся на стационарном лечении в кардиологических отделениях и сосудистых центрах.

Все 1652 записи ЭКГ были независимо описаны врачами-экспертами (кардиологами и врачами функциональной диагностики) с формированием структурированного врачебного заключения. Далее все записи ЭКГ были подвергнуты автоматическому анализу с использованием метода детектирования ключевых точек (ДКТ), сегментированы и автоматически описаны в том же формате доврачебного заключения разработанной авторами программой по классическим критериям анализа ЭКГ [5].

Алгоритм применения метода ДКТ включал следующие этапы:

предварительную обработку сигнала ЭКГ: фильтрация (подавление шума), выделение изолинии [1, 3];

ДКТ сигнала: детектирование начала, пика и конца комплекса QRS, P- и T-волн и определение их морфологии (рис. 1);

автоматическую генерацию заключения.

На основе этих данных рассчитывались общепринятые характеристики сигнала (см., например, [3]). Использовались стандартные функции для вычисления числовых характеристик (средняя продолжительность и высота комплексов сигнала ЭКГ, их стандартные отклонения и т.д.). В итоге для описания каждого отведения ЭКГ было получено 38 признаков.

С использованием 1242 из 1652 ЭКГ, имеющих в «Кардиобаза», с формализованными заключениями врачей было проведено обучение программы «Киберсердце–Диагностика». Для этого использовали наиболее часто применяемые методы машинного обучения: метод опорных векторов (SVM), дерево решений, методы квадратичного и линейного дискриминантного анализа [6], метод случайных подпространств [7], AdaBoost [8], случайный лес [9], логистическая регрессия (модель нейрона Мак-Каллока–Питтса) с предварительной предобработкой признаков с помощью слоя Batch Normalization [10].

В этих методах алгоритмы автоматически строятся по большой выборке размеченных данных, т.е. по базе ЭКГ с известными заключениями. При этом алгоритм постановки диагноза (решающая функция)

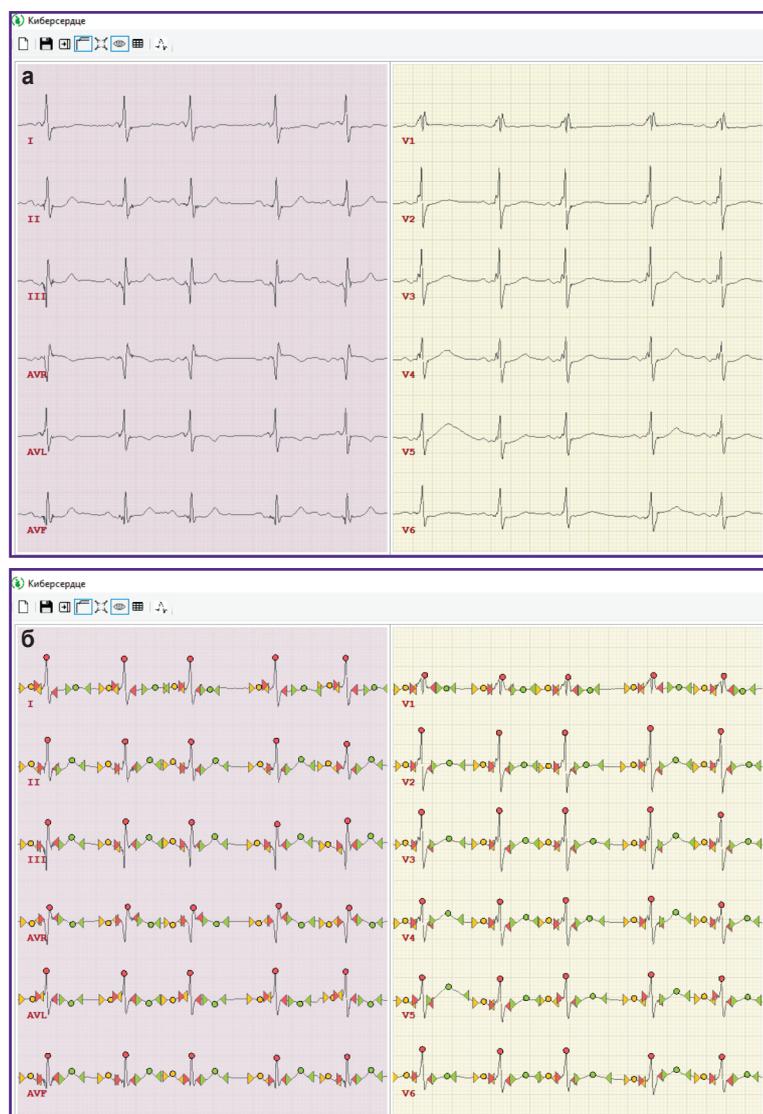


Рис. 2. ЭКГ (12 отведений) пациентки У., 69 лет: а — исходная; б — с сегментацией

Таблица 1

Структура «Кардиобазы» по классам заключений

Номер класса	Диагноз	Количество записей	
		абс. число	%
1	Абсолютная норма	340	21,2
2	Синусовая аритмия	287	17,9
3	Блокада правой ножки пучка Гиса	89	5,5
4	Двухпучковая блокада	48	3,0
5	Фибрилляция предсердий	170	10,6
6	Ишемические изменения	272	16,9
7	Гипертрофия левых отделов сердца	315	19,6
8	Имплантированный электрокардиостимулятор	65	4,0
9	Другое	21	1,3
Всего		1607*	100,0

* Часть ЭКГ от 1242 пациентов вошли в два и более классов.

не закладывается явным образом. Происходит «настройка» модели по данным обучающей выборки — набору характеристик и атрибутов ЭКГ пациента с известным заключением.

Программа автоматического анализа ЭКГ обучалась с применением методов машинного обучения на признаках, полученных с помощью ДКТ (рис. 2). Подробнее об алгоритме ДКТ см. в работе [5].

Для тестирования программы «Киберсердце-Диагностика» с помощью названных методов машинного обучения была проведена апробация анализа ЭКГ, которую выполняли с использованием наиболее крупных и обработанных с участием медицинских экспертов открытых баз данных ЭКГ: Arrhythmia Data Set (<http://archive.ics.uci.edu/ml/datasets/arrhythmia>), PhysioNet PTBDB (<https://www.physionet.org/physiobank/database/ptbdb>), PhysioNet Competition 2017 (<https://physionet.org/challenge/2017>). При анализе результатов учитывалась точность диагностики относительно основных признаков и классов ЭКГ.

База Arrhythmia Data Set представлена 410 записями 12-канальных ЭКГ. Каждая ЭКГ описывается 279 признаками и относится к одному из 16 классов признаков ЭКГ.

База PhysioNet PTBDB состоит из 549 записей ЭКГ от 290 пациентов. Каждый пациент относится к одному из девяти классов.

База PhysioNet Competition 2017 состоит из 8528 одноканальных пятиминутных записей ЭКГ, отнесенных к одному из четырех классов.

При разработке программного комплекса «Киберсердце-Диагностика» была создана собственная база данных («Кардиобаза»), которая представлена 1652 записями ЭКГ, разделенными на 9 классов, при этом для обучения были использованы ЭКГ, полученные от 1242 пациентов (табл. 1).

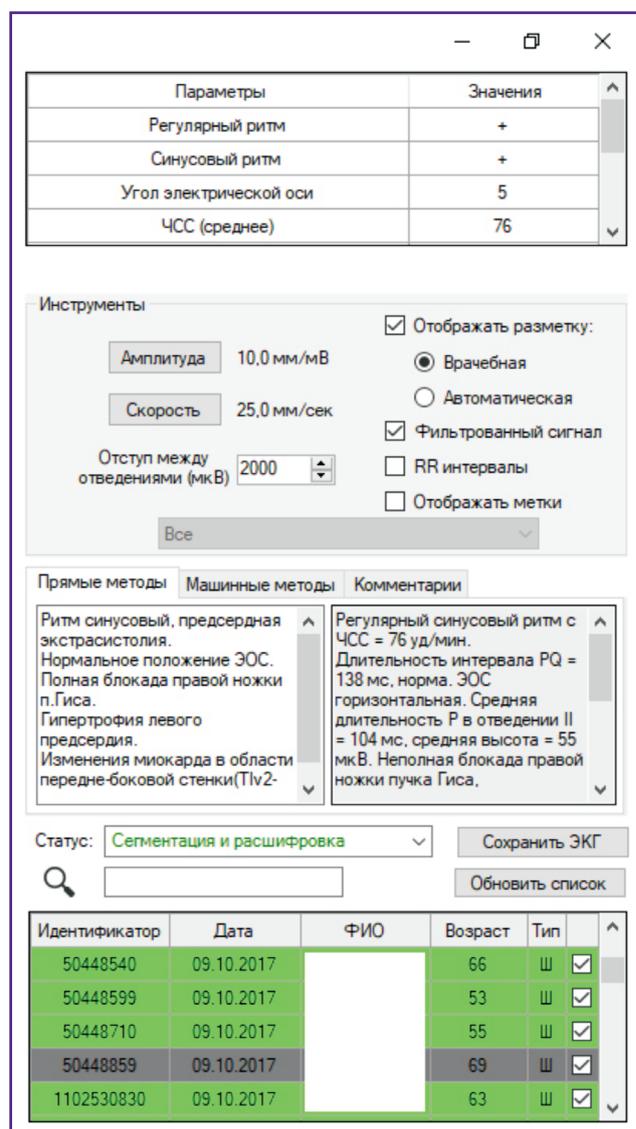


Рис. 3. Пример интерфейса заключения по ЭКГ

Классы «Кардиобазы» были разработаны исходя из классических клинко-электрофизиологических подходов к заключениям по ЭКГ (см. табл. 1). Наиболее часто представлены следующие группы заключений: нормальная ЭКГ, синусовая аритмия, гипертрофия левых отделов сердца, фибрилляция предсердий, ишемические изменения.

Данные автоматического анализа 410 ЭКГ из «Кардиобазы» были сравнены с результатами заключений врачей-экспертов, которые условно рассматривались как эталонные. Интерфейс заключения по ЭКГ представлен на рис. 3.

Проведена комплексная оценка полученных результатов по классам признаков. Оценка качества диагностики происходила с помощью пятикратного перекрестного контроля по метрике ROC-AUC [11, 12].

Результаты и обсуждение

В соответствии с задачами исследования проведено последовательное тестирование разработанной программы с помощью методов (алгоритмов) машинного обучения на доступных международных базах данных.

База Arrhythmia. Эксперименты по тестированию были проведены с выборкой, состоящей из объектов (наблюдений), относящихся к наиболее представительным классам: 1-му («Норма»), 2-му («Ишемические изменения») и 10-му («Блокада правой ножки пучка Гиса») (всего 339 записей). Было проведено тестирование программы с использованием методов опорных векторов, случайных подпространств, ближайших соседей, дерева решений, нейронных сетей, дискриминантного анализа. Оценка качества происходила с помощью пятикратного перекрестного контроля по метрике ROC-AUC. В табл. 2 представлены параметры алгоритмов, при которых получены наилучшие результаты.

Был также проведен эксперимент по трехклассовой классификации (классы 1, 2 и 10) без этапа предвари-

тельного отбора признаков. Использовались следующие методы машинного обучения: метод опорных векторов, логистическая регрессия, AdaBoost, случайный лес. Данные случайным образом разбивались на обучающую (70%) и тестовую (30%) выборки. Такое разделение проводилось 100 раз. Достигнутая точность алгоритмов отражена в табл. 3.

Тестирование на базе PhysioNet PTBDB. Рассматривалась задача бинарной классификации

Таблица 3

Точность трехклассовой классификации на обучающей выборке

Метод	Точность, %
Метод опорных векторов	86,1
Градиентный бустинг	85,3
Случайный лес	85,2
Логистическая регрессия	82,7

Таблица 4

Результаты экспериментов на базе PhysioNet Competition 2017

Классы базы PhysioNet Competition 2017		Точность, %
Первый	Второй	
N, A, O	~	94,7
N	A	87,2
N	A, O	79,5
O	A	78,0
N	O	77,4

Здесь: N — нормальный ритм; A — мерцательная аритмия; O — другой ритм; ~ — шум.

Таблица 2

Результаты эксперимента с предварительным отбором признаков, %

Метод	ROC-AUC (для класса «Ишемические изменения»)	ROC-AUC (для класса «Блокада правой ножки пучка Гиса»)
Метод опорных векторов	94,1	89,0
Метод случайных подпространств	94,5	87,2
Дискриминантный анализ	93,6	83,8

Таблица 5

Результаты тестирования программы «Киберсердце–диагностика» на собранной «Кардиобазе» (n=410)

Класс ЭКГ	Название класса	Число ЭКГ по данным экспертных заключений	Число истинно положительных заключений	Чувствительность	Число истинно отрицательных заключений	Специфичность	Точность
		P	TP	TPR=TP/P×100%	TN		
1	Абсолютная норма	156	120	76,9	234	92,1	86,3
2	Синусовая аритмия	105	74	70,5	302	99,0	91,7
3	Блокада правой ножки пучка Гиса	22	20	90,9	252	64,9	66,3
4	Двухпучковая блокада	6	4	66,7	307	76,0	75,9
5	Фибрилляция предсердий	33	31	93,9	271	71,9	73,7
6	Ишемические изменения	70	63	90,0	248	72,9	75,9
7	Гипертрофия левых отделов сердца	11	10	90,9	323	80,9	81,2
8	Имплантированный электрокардиостимулятор	5	5	100,0	385	95,1	95,1
9	Другое	3	2	66,7	256	62,9	62,9

между классами 1 («Инфаркт миокарда») и 9 («Здоровые»). Остальные классы малопредставительны, и поэтому в них было сложно выделить какие-либо закономерности, полезные для правильной диагностики. Лучший результат дала логистическая регрессия (модель нейрона Мак-Каллока–Питтса) с предварительной предобработкой признаков с помощью слоя Batch Normalization. На сбалансированной выборке достигнута точность 86,1%.

Тестирование на базе PhysioNet Competition 2017. Ставилась серия задач бинарной классификации, результаты экспериментов описаны ниже (табл. 4).

Значение F1-меры (среднего гармонического между чувствительностью и специфичностью) составило 0,81. Заметим, что лучшие показатели F1-меры в международном исследовании, по данным PhysioNet Competition 2017, были равны 0,83. Таким образом, результаты реализованных нами алгоритмов сравнимы по качеству диагностики с мировыми аналогами.

Тестирование на созданной «Кардиобазе». В результате тестирования программы на созданной «Кардиобазе» были получены результаты, представленные в табл. 5.

Чувствительность заключений, выполненных программой «Киберсердце–Диагностика», оказалась равной 66,7–100,0% по различным классам в сравнении с заключениями врачей-диагностов. Специфичность метода составила 62,9–99,0%, точность — 62,9–95,1%.

Заключение

Результаты использования основных методов машинного обучения для тестирования разработанной программы «Киберсердце–Диагностика» показали достаточно высокую точность заключений, достигаемую этой программой, в сравнении с условно «идеальными» заключениями врачей-диагностов.

Полученные авторами данные автоматической расшифровки ЭКГ с помощью представленной программы, выполненные на собственном материале «Кардиобазы», сравнивались с данными трех крупных баз ЭКГ, находящихся в открытом доступе. Несмотря на то, что эти базы данных имели отличия по продолжительности записи кардиосигнала, количеству отведений, набору классов и другим критериям, точность диагностики по разработанному авторами алгоритму в соответствующих классах признаков составила 62,9–95,1%.

Финансирование исследования. Работа выполнена при поддержке Министерства образования Российской Федерации (контракт №02.G25.31.0157 от 01.12.2015).

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Литература/References

1. Юровский А.Ю., Сухов С.С. Дистанционный анализ ЭКГ и компьютерная электрокардиография — современные альтернативы классическому «бумажному» решению. *Практическая медицина* 2017; 2: 14–17. Yurovskiy A.Yu., Sukhov S.S. Distant analysis of ECG and computerized electrocardiography — modern alternatives to classic “paper” solutions. *Prakticheskaya meditsina* 2017; 2: 14–17.
2. Струтынский А.В. Электрокардиограмма: анализ и интерпретация. М: МЕДпресс-информ; 2017; 224 с. Strutynskiy A.V. *Elektrokardiogramma: analiz i interpretatsiya* [Electrocardiogram: analysis and interpretation]. Moscow: MEDpress-inform; 2017; 224 p.
3. Воробьев Л.В. ЭКГ анализ сердечной деятельности здорового человека. *Международный журнал прикладных и фундаментальных исследований* 2016; 10: 549–553. Vorobiov L.V. ECG analysis of cardiac activity of a healthy person. *Mezhdunarodnyy zhurnal prikladnykh i fundamental'nykh issledovaniy* 2016; 10: 549–553.
4. Дроздов Д.В., Леванов В.М. Автоматический анализ ЭКГ: проблемы и перспективы. *Здравоохранение и медицинская техника* 2004; 1: 10. Drozdov D.V., Levanov V.M. Automatic ECG analysis: problems and prospects. *Zdravookhranenie i meditsinskaya tekhnika* 2004; 1: 10.
5. Калякулина А.И., Юсипов И.И., Москаленко В.А., Никольский А.В., Козлов А.А., Золотых Н.Ю., Иванченко М.В. Вейвлет-анализ для нахождения точек морфологий волн электрокардиографического сигнала. *Известия Вузов. Радиофизика* 2018; 61(8): 773–789. Kalyakulina A.I., Yusipov I.I., Moskalenko V.A., Nikolskiy A.V., Kozlov A.A., Zolotykh N.Yu., Ivanchenko M.V. Finding morphology points of electrocardiographic signal waves using wavelet analysis. *Izvestiya Vuzov. Radiofizika* 2018; 61(8): 773–789.
6. Duda R.O., Hart P.E., Stork D.G. *Pattern classification*. Wiley-Interscience; 2000.
7. Tin Kam Ho. The random subspace method for constructing decision forests. *IEEE Trans Pattern Anal Mach Intell* 1998; 20(8): 832–844, <https://doi.org/10.1109/34.709601>.
8. Freund Y., Schapire R.E. A decision-theoretic generalization of on-line learning and an application to boosting. *J Comput Syst Sci* 1997; 55(1): 119–139, <https://doi.org/10.1006/jcss.1997.1504>.
9. Breiman L. Random forests. *Machine Learning* 2001; 45(1): 5–32.
10. Ioffe S., Szegedy C. *Batch normalization: accelerating deep network training by reducing internal covariate shift*. 2015. URL: <https://arxiv.org/pdf/1502.03167.pdf>.
11. Brown C.D., Davis H.T. Receiver operating characteristics curves and related decision measures: a tutorial. *Chemometr Intell Lab Syst* 2006; 80(1): 24–38, <https://doi.org/10.1016/j.chemolab.2005.05.004>.
12. Petrov V., Lebedev S., Pirova A., Vasilyev E., Nikolskiy A., Turlapov V., Meyerov I., Osipov G. CardioModel — new software for cardiac electrophysiology simulation. In: Voevodin V., Sobolev S. (editors). *Supercomputing. RuSCDays 2018. Communications in computer and information science*. Vol. 965. Springer, Cham; 2018; p. 195–207, https://doi.org/10.1007/978-3-030-05807-4_17.