

doi: 10.17586/2226-1494-2022-22-6-1166-1177

УДК 004.9 + 616.1/9

Автоматизированная оценка параметров электрокардиограмм в условиях пандемии COVID-19

Александра Сергеевна Ватьян¹, Наталия Федоровна Гусарова²✉,
Наталия Викторовна Добренко³, Данил Александрович Змиевский⁴,
Максим Васильевич Кабышев⁵, Татьяна Андреевна Полевая⁶,
Анна Андреевна Татаринова⁷, Иван Вячеславович Томилов⁸

^{1,2,3,4,5,6,8} Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

⁷ Национальный медицинский исследовательский центр им. В.А. Алмазова, Санкт-Петербург, 197341, Российская Федерация

¹ alexvatyan@gmail.com, <https://orcid.org/0000-0002-5483-716X>

² natfed@list.ru✉, <https://orcid.org/0000-0002-1361-6037>

³ graziokisa@yandex.ru, <https://orcid.org/0000-0001-6206-8033>

⁴ danil.zmievskiy@gmail.com, <https://orcid.org/0000-0002-0077-794X>

⁵ maxk6971@gmail.com, <https://orcid.org/0000-0002-1006-0408>

⁶ tanusha2406@gmail.com, <https://orcid.org/0000-0001-6131-0019>

⁷ antsvet.18@mail.ru, <https://orcid.org/0000-0002-9046-2457>

⁸ ivan-tomilov3@yandex.ru, <https://orcid.org/0000-0003-1886-2867>

Аннотация

Предмет исследования. Рассмотрены алгоритмы оперативной автоматизированной оценки параметров электрокардиограммы в условиях отсутствия специализированного оборудования и профильных специалистов.

Метод. Электрокардиограмма пациента записана на бумажную ленту, которая сфотографирована на мобильный телефон врача первичного звена и обработана специализированным приложением. С помощью приложения выполнена оцифровка фотографируемого изображения электрокардиограммы, оценка ее основных параметров, а также расчет критериев для дифференциальной диагностики отдельных заболеваний по приближенным формулам. Кроме того, оцифрованное изображение электрокардиограммы передается на сервер и обрабатывается с помощью системы машинного обучения. **Основные результаты.** Разработаны алгоритмы оцифровки и анализа электрокардиограммы, которые могут быть использованы для оценки ее элементов, важных для диагностики. Средняя ошибка определения положения наиболее сложных (сглаженных) пиков — зубцов Р и Т — составила не более 0,1 мм. Предложен алгоритм критериального анализа электрокардиограммы для поддержки дифференциальной диагностики острого инфаркта миокарда с подъемом сегмента ST и синдрома ранней реполяризации желудочков, который обеспечил значения точности 0,85 и F-меры 0,74. Представлен альтернативный алгоритм на основе глубокой нейронной сети, который обеспечивает лучшие значения точности и F-меры — 0,96 и 0,88, но требует больших затрат вычислительных ресурсов и выполнения расчетов на сервере.

Практическая значимость. Алгоритмы реализованы в виде набора библиотечных функций. Они могут быть использованы как самостоятельно, так и в составе полномасштабной системы поддержки принятия клинических решений для автоматизированной оценки параметров электрокардиограммы на основе клиент-серверной архитектуры. Все результаты расчетов совместно с фотографией исходной электрокардиограммы могут быть оперативно переданы квалифицированному кардиологу с целью дистанционного получения консультативного заключения.

Ключевые слова

COVID-19, система поддержки клинических решений, автоматизированная оценка параметров электрокардиограммы, поддержка дифференциальной диагностики

Благодарности

Работа поддержана грантом Президента Российской Федерации № МК-5723.2021.1.6.

Ссылка для цитирования: Ватян А.С., Гусарова Н.Ф., Добренко Н.В., Змиевский Д.А., Кабышев М.В., Полевая Т.А., Татаринова А.А., Томилов И.В. Автоматизированная оценка параметров электрокардиограмм в условиях пандемии COVID-19 // Научно-технический вестник информационных технологий, механики и оптики. 2022. Т. 22, № 6. С. 1166–1177. doi: 10.17586/2226-1494-2022-22-6-1166-1177

Automated evaluation of ECG parameters during the COVID-19 pandemic

Alexandra S. Vatian¹, Natalia F. Gusarova²✉, Natalia V. Dobrenko³,
Danil A. Zmievsky⁴, Maxim V. Kabyshev⁵, Tatiana A. Polevaya⁶,
Anna A. Tatarinova⁷, Ivan V. Tomilov⁸

^{1,2,3,4,5,6,8} ITMO University, Saint Petersburg, 197101, Russian Federation

⁷ Almazov National Medical Research Centre, Saint Petersburg, 197341, Russian Federation

¹ alexvatyan@gmail.com, <https://orcid.org/0000-0002-5483-716X>

² natfed@list.ru✉, <https://orcid.org/0000-0002-1361-6037>

³ graziokisa@yandex.ru, <https://orcid.org/0000-0001-6206-8033>

⁴ danil.zmievskiy@gmail.com, <https://orcid.org/0000-0002-0077-794X>

⁵ maxk6971@gmail.com, <https://orcid.org/0000-0002-1006-0408>

⁶ tanusha2406@gmail.com, <https://orcid.org/0000-0001-6131-0019>

⁷ antsvet.18@mail.ru, <https://orcid.org/0000-0002-9046-2457>

⁸ ivan-tomilov3@yandex.ru, <https://orcid.org/0000-0003-1886-2867>

Abstract

Algorithms for prompt automated evaluation of electrocardiogram parameters in the absence of specialized equipment and specialized specialists are considered. The patient's electrocardiogram is recorded on a paper tape, then it is photographed on the primary care doctor's mobile phone and processed by a specialized application. The application digitizes the photographed image of the electrocardiogram, evaluates its main parameters as well as calculates criteria for the differential diagnosis of certain diseases using approximate formulas. In addition, the digitized electrocardiogram image is transmitted to the server and processed using a machine learning system. Algorithms for digitizing and analyzing an electrocardiogram have been developed that make it possible to evaluate its elements that are important for diagnosis, and the average error in determining the position of the most complex (smoothed) peaks — P and T waves — was no more than 0.1 mm. An algorithm for the criteria analysis of an electrocardiogram is proposed to support the differential diagnosis of acute myocardial infarction with ST segment elevation and early ventricular repolarization syndrome which provides accuracy values of 0.85 and F-scores of 0.74. An alternative algorithm based on a deep neural network is proposed which provides the best values — 0.96 and 0.88, respectively, but requires large computing resources and is executed on the server. The algorithms are implemented as a set of library functions. They can be used both independently and as part of a full-scale clinical decision support system for automated evaluation of electrocardiogram parameters based on a client-server architecture. In addition, all calculation results, together with a photograph of the original electrocardiogram, can be promptly transferred to a qualified cardiologist in order to receive an advisory opinion remotely.

Keywords

COVID-19, clinical decision support system, automated evaluation of electrocardiogram parameters, support for differential diagnosis

Acknowledgements

The work was supported by the Grant of the President of the Russian Federation No. MK-5723.2021.1.6.

For citation: Vatian A.S., Gusarova N.F., Dobrenko N.V., Zmievsky D.A., Kabyshev M.V., Polevaya T.A., Tatarinova A.A., Tomilov I.V. Automated evaluation of ECG parameters during the COVID-19 pandemic. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2022, vol. 22, no. 6, pp. 1166–1177 (in Russian). doi: 10.17586/2226-1494-2022-22-6-1166-1177

Введение

Мировой опыт борьбы с пандемией COVID-19 показал, что наиболее тяжелое течение болезни и наиболее неблагоприятные прогнозы приходятся на больных, имеющих сопутствующие заболевания. Среди сопутствующих заболеваний ведущее место занимают сердечно-сосудистые заболевания (ССЗ). Согласно оценкам [1], наличие ССЗ в 3,4 раза увеличивает тяжесть течения COVID-19 и более чем в 23 раза — смертность.

В отличие от медленно развивающихся заболеваний, таких как онкология, ССЗ часто проявляют себя как катастрофы, требующие принятия немедленного

и обоснованного решения на уровне звена скорой и неотложной медицинской помощи. В условиях пандемии COVID-19 в этом звене наблюдалась нехватка специалистов, которую системы здравоохранения во всем мире компенсируют, в первую очередь, за счет привлечения врачей непрофильных специальностей или интернов [2, 3], которым сложно принять квалифицированное решение относительно ССЗ. Кроме того, перепрофилирование медицинских учреждений под нужды пандемии привело к сокращению числа специализированных ССЗ-коек и осуществлению мер против такой ранее широко практиковавшейся тактики, как гипердиагностика острых ССЗ с последующим уточнением диагноза в стационаре [4].

Основное средство диагностики ССЗ на уровне скорой и неотложной медицинской помощи — электрокардиограмма (ЭКГ) (рис. 1). Однако точность интерпретации ЭКГ существенно отличается в зависимости от квалификации интерпретатора. Например, согласно исследованию в работе [5], точность расшифровки ЭКГ составляет: у кардиологов 63,2–86,7 %, у практикующих врачей 57,6–79,5 %, а у медиков низшего звена и непрофильной квалификации (доля которых при пандемии возрастает) 48,1–63,6 %.

Постановка задачи

Таким образом, в условиях пандемии COVID-19 особую актуальность приобрели системы поддержки принятия клинических решений (СПКР) по ССЗ, причем важно предотвратить как ошибки первого рода (избыточно тяжелый диагноз и госпитализация без острой необходимости), так и ошибки второго рода (недооценка серьезности состояния больного). Перспективным подходом здесь признаны системы автоматизированной диагностики ССЗ [6, 7], в первую очередь, на основе автоматизированного определения параметров ЭКГ [8]. Отметим, что несмотря на впечатляющие успехи, в данной области остается еще много нерешенных проблем [9], среди которых в аспекте пандемии COVID-19 важно выделить следующие.

Недостаточная точность оценки параметров ЭКГ. Диагностика ССЗ по ЭКГ основана на результатах измерений временных параметров всех зубцов и интервалов, которые существенно различаются по степени выраженности и вариабельности (рис. 1, а). Например, автоматизированная оценка отклонений синусового ритма (т. е. RR-интервала) может быть выполнена с точностью до 99 % [10]. При этом интервалы PQ, PR и QT измерить гораздо сложнее из-за сглаженной формы зубцов Р и Т; в результате при нахождении связанных с ними признаков на ЭКГ точность падает до 79,2 % и ниже [8]. В связи с этим, как показывает анализ научных работ последних лет [11, 12], фокус исследований все больше сдвигается с повышения точности оценки ЭКГ в целом на поддержку диагностики отдельных заболеваний, связанных с анализом конкретных фрагментов ЭКГ.

Необходимость специализированного оборудования. Практически все представленные в современных научных работах и на коммерческом уровне системы автоматизированного анализа ЭКГ предполагают использование цифрового электрокардиографа, оснащенного соответствующей компьютерной системой [13]. В звене первичной медико-санитарной помощи в отдельных регионах России, а также в развивающихся странах наблюдается дефицит такого оборудования, проявившийся в большей степени в условиях пандемии COVID-19. Многие бригады скорой помощи имеют в своем распоряжении только электрокардиограф с записью ЭКГ на бумажной ленте (рис. 1, б) и мобильный телефон в качестве компьютерной системы. Систем автоматизированного анализа ЭКГ для такого комплекта оборудования в доступной авторам научной литературе не найдено.

Необходимость оперативного получения квалифицированной консультации. Любые СПКР принципиально являются консультативными, т. е. не снимают необходимости оценки ЭКГ квалифицированным специалистом-кардиологом. Известно, что организовать такую оценку посредством личного контакта узкого специалиста и пациента (на дому или в стационаре) в условиях пандемии COVID-19 проблематично. Для этого необходимо использовать дистанционные формы взаимодействия, в том числе посредством мобильного телефона как наиболее доступного в этой ситуации средства передачи изображения.

Перспективный путь преодоления указанных проблем — построение СПКР для автоматизированной оценки параметров ЭКГ на основе клиент-серверной архитектуры. При этом клиентская часть реализована в виде мобильного приложения, установленного на телефон врача первичного звена. Врач снимает ЭКГ пациента на бумажную ленту кардиографа и фотографирует ее на мобильный телефон. Приложение выполняет оцифровку изображения и автоматизированную оценку основных параметров ЭКГ, которые отображаются на экране телефона, а также производит расчет критериев для дифференциальной диагностики отдельных заболеваний по приближенным формулам. Для уточнения диагноза оцифрованное изображение ЭКГ может передаваться на сервер, где обрабатывается




Рис. 1. Характерные интервалы (а) и фрагмент электрокардиограммы в записи на бумаге (б).

P, R, Q, S, T, U — зубцы; PR, ST — сегменты; QRS, RR, PR, QT, TP — интервалы

Fig. 1. Typical ECG intervals (a); fragment of an ECG recorded on paper (b)

с помощью системы машинного обучения. Все результаты расчетов совместно с фотографией исходной ЭКГ могут быть переданы квалифицированному кардиологу с целью дистанционного получения консультативного заключения.

Алгоритм обработки ЭКГ с использованием мобильного телефона был представлен авторами на международной конференции [14]. Цель настоящей работы — развитие идеи в направлении создания полномасштабной СПКР. Рассмотрены ключевые аспекты создания СПКР: оцифровка исходной ЭКГ на бумажной ленте, автоматизированная оценка основных параметров ЭКГ и повышение робастности оценки. Определены возможности поддержки дифференциальной диагностики при остром коронарном синдроме на основе критериальной оценки и машинного обучения. Рассмотрен пример клинически значимой задачи выявления признаков для поддержки дифференциальной диагностики острого инфаркта миокарда с подъемом сегмента ST и синдрома ранней реполяризации желудочков.

Автоматизированная оценка основных параметров ЭКГ

В аналоговых электрокардиографах ЭКГ регистрируется на специальной тепловой бумаге с нанесенной миллиметровой сеткой красного оттенка, которая используется для визуальной оценки параметров ЭКГ (амплитудного и временного масштаба сигналов). Таким образом, для оцифровки фотографии бумажной ЭКГ необходимо разделить изображения сигнала и регистрационной сетки. С этой целью выполнена сравнительная оценка трех подходов:

- 1) спектральной фильтрации посредством маскирования в цветовой модели HSV;
- 2) пороговой фильтрации канала grayscale в полутоновом изображении [13];
- 3) адаптивной бинаризации (автоматическое определение порога для отдельных зон изображения) [15].

Отметим, что подход 3 показал наилучшие результаты. Как показали результаты экспериментов, во избежание возможных шумовых эффектов к отделенному изображению сигнала целесообразно применять фильтр Гаусса и медианный фильтр.

Разработанный алгоритм оцифровки фотографии ЭКГ состоит из следующих шагов: адаптивная бинаризация изображения ЭКГ; фильтрация полученного сигнала ЭКГ; расчет масштаба сетки по ее отделенному изображению. Результатом оцифровки является одномерный массив амплитудных значений сигнала ЭКГ, автоматически приведенный к одному из стандартизованных временных масштабов. Пример визуализации оцифрованного сигнала ЭКГ представлен на рис. 2.

Как показывает практика, медианные значения (изолинии) ЭКГ могут претерпевать низкочастотные изменения как за счет нарушения режима питания электрокардиографа, так и за счет физиологических проявлений пациента. Для устранения этого эффекта в процессе предобработки сигнала использован фильтр Баттерворта (рис. 3).




Рис. 2. Оцифрованный сигнал электрокардиограммы

Fig. 2. Digitized ECG signal




Рис. 3. Устранение смещения изолинии: зеленый — сигнал со смещением изолинии, желтый — сигнал с устраненным смещением изолинии

Fig. 3. Elimination of iseline shift: green — signal with iseline shift, yellow — signal with corrected iseline shift

В работах [16, 17] показано, что для оценки временного положения отдельных зубцов ЭКГ предпочтительны методы на основе вейвлет-преобразований, реализованные, в частности, в широко распространенном пакете NeuroKit¹. Выполненные эксперименты в настоящей работе подтвердили эффективность такого подхода для поиска пиков зубцов ЭКГ (рис. 4, а). Между тем при определении границ зубцов, особенно таких «мягких», как Р и Т, подход показал недостаточную устойчивость (наблюдается смещение и переналожение граничных точек — рис. 4, б). Статистическая обработка полученных значений по методу [18] также оказалась недостаточно эффективной. В связи с этим границы зубцов вычислены на основе предложенного в клинических рекомендациях [19, 20] метода [21]. Метод состоит в поиске максимального или минимального градиента на одной из условных половин оцениваемого зубца ЭКГ и построении касательной, проходящей через точку градиента (рис. 5). Проекция точки пересечения касательной и изолинии непосредственно на сам сигнал принимается за границу зубца.

¹ NeuroKit's documentation [Электронный ресурс]. Режим доступа: <https://rpanderson-neurokit2.readthedocs.io/en/latest/index.html> (дата обращения: 20.11.2022).




Рис. 4. Определения: пиков (пакет NeuroKit, функция delineate, метод peak) (a) и границ (пакет NeuroKit, функция delineate, метод dwt) (b) зубцов электрокардиограммы

Fig. 4. a — determination of ECG wave peaks (NeuroKit package, delineate function, peak method); b — determination of ECG wave boundaries (NeuroKit package, delineate function, dwt method)

Для оценки разработанных алгоритмов использован публично доступный датасет [22], состоящий из записей ЭКГ, на которых врачами-кардиологами вручную размечены точки пиков R, P, T зубцов. В результате экспериментов средняя ошибка определения положения пиков ЭКГ составила не более 0,1 мм для зубцов P и T




Рис. 5. Схема определения границ зубцов электрокардиограммы по методу касательных

Fig. 5. Scheme for determining the boundaries of ECG teeth using the tangent method

и 0,6 мм для R. Выборочное визуальное обследование использованного датасета выявило наличие выбросов (неверно размеченных положений пиков) именно для зубца R.

Разработанные алгоритмы оцифровки и анализа ЭКГ реализованы на языке Python в виде набора библиотечных функций. При этом на входе функции находится фотографическое изображение ЭКГ в формате .jpg, а на выходе — набор значений элементов ЭКГ: амплитуды зубцов R, P, T, длительность интервалов RR и QT, а также сегментов ST и PR.

Выявление признаков для поддержки дифференциальной диагностики инфаркта миокарда с подъемом сегмента ST и синдрома ранней реполяризации желудочков на основе автоматизированной оценки параметров ЭКГ

В качестве одной из клинически значимых задач рассмотрим дифференциальную диагностику таких состояний, как острый инфаркт миокарда (ОИМ) с подъемом (элевацией) сегмента ST (ST-ОИМ) и синдром ранней реполяризации желудочков (СРРЖ/ЕР), который также проявляется на ЭКГ в виде подъема сегмента ST (рис. 6). Если ST-ОИМ — жизнеугрожающее состояние, которое требует немедленной госпитализации, то СРРЖ/ЕР рассматривается как фенотипический вариант нормы, хотя и ассоциируется с повышением риска внезапной сердечной смерти. В условиях пандемии COVID-19 дифференциальная диагностика состояний ST-ОИМ и СРРЖ/ЕР непосредственно на месте, на основе анализа только ЭКГ, т. е. без госпитализации и дополнительных обследований, приобретает особую важность и одновременно вызывает особые затруднения у медиков звена скорой и неотложной медицинской помощи.

Отметим, что в научной литературе представлен ряд работ, в которых задача дифференциальной диа-




Рис. 6. Элевация сегмента ST на электрокардиограмме во II отведении

Fig. 6. Elevation of the ST segment on the electrocardiogram in lead II

гностики состояний ST-ОИМ и СРРЖ/ЕР решается как двухклассовая классификация на наборе признаков, извлекаемых из ЭКГ. Как показал сравнительный анализ литературы, наилучшая эффективность установлена в работе [22], где на основе многомерной линейной регрессии построен критерий разделения следующего вида:

$$(1,196 \times STE60 \text{ V3}) + (0,059 \times QTc) - (0,326 \times RA \text{ V4}) > Q, \quad (1)$$

где $STE60 \text{ V3}$ — значение ST-элевации в отведении V3, мм; QTc — значение скорректированного интервала QT, мс; $RA \text{ V4}$ — значение амплитуды пика R в отведении V4, мм (приведение к безразмерным единицам учтено в нормировочных коэффициентах). При пороговом значении $Q > 23,4$ принимается решение о наличии ST-ОИМ, при $Q < 23,4$ — о СРРЖ/ЕР.

В [23] для вывода регрессионной формулы (1) использован датасет, содержащий только случаи ОИМ передней локализации. В настоящей работе, исходя из результатов работы [23], проведено уточнение регрессионных коэффициентов на основе открытого датасета [24], содержащего ЭКГ с инфарктами различных типов. Для этого использован фрагмент набора данных [24], содержащий 159 записей ЭКГ, принадлежащих к состояниям ST-ОИМ (49 записей) и СРРЖ/ЕР (110 записей). Применение формулы (1) на этом датасете дало значительно более низкие показатели эффективности разбивания, чем в [23] (табл. 1).

Для решения проблемы эффективности выполнена модификация формулы (1): оптимизация порогового значения Q без изменения остальных коэффициентов и ограничение максимальной амплитуды пика R. В результате формула (1) преобразована к виду

$$(1,0 \times STE60 \text{ V3}) + (0,06 \times QTc) - (0,5 \times \min(RA \text{ V4}, 10,5)) > 27,1. \quad (2)$$

Для снижения вероятности переобучения произведено дополнительное дообучение модели на датасете [24] при помощи логистической регрессии с кросс-валидацией на трех разбиениях обучающей выборки. Тогда полученная модификация исходной формулы (1) имеет вид

$$(2,9 \times STE60 \text{ V3}) + (0,3 \times QTc) - (1,7 \times \min(RA \text{ V4}, 19)) \geq 126,9. \quad (3)$$

Из анализа табл. 1 видно, что модификация критерия (1) к форме (2) позволила получить практически исходно заявленные значения точности при существенном увеличении робастности. При необходимости дальнейшего увеличения робастности критериального метода (формула (3)) приходится идти на некоторое снижение точности и F1-меры. Важно подчеркнуть, что разработанные алгоритмы оценки критерия (2) и (3) нетребовательны к вычислительным ресурсам и могут быть легко размещены в виде автономного приложения на большинстве моделей мобильных телефонов, распространенных в России.

Отметим, что вопрос влияния конкретной локализации очага нарушения кровоснабжения, как и других предикторов, представляет самостоятельный интерес и выходит за рамки данной работы, цель которой — показать возможности инструментальной поддержки дифференциальной диагностики острых состояний сердечно-сосудистой системы на примере конкретной пары состояний.

Альтернативный подход к поддержке дифференциальной диагностики состояний ST-ОИМ и СРРЖ/ЕР — подход на основе глубоких нейронных сетей [25, 26]. Для эксперимента использована сеть с архитектурой ConvNet [27], которая включает в себя четыре группы сверточных слоев и слой линейной трансформации.

Результаты настройки сети СРРЖ/ЕР и ST-ОИМ, соответственно, иллюстрируются на графиках f1-меры (рис. 7, а, b и рис. 8, а, b), потерь (рис. 7, c, d и рис. 8, c, d), точности (рис. 7, e, f и рис. 8, e, f), полноты (рис. 7, g, h и рис. 8, g, h), специфичности (рис. 7, i, j и рис. 8, i, j). Графики демонстрируют достижение необходимых показателей нейронной сети при сравнительно небольшом количестве итераций обучения, что можно считать достоинством используемой архитектуры. Кроме того, следует подчеркнуть, что эти результаты достигнуты на достаточно малом количестве обучающих примеров, что является очень ценным для поддержки дифференциальной диагностики сравнительно редко встречающихся заболеваний, для которых количество клинических случаев в популяции принципиально невелико (даже в таком объемном датасете, как [22], таких случаев всего 220).

Количественные оценки эффективности разработанного алгоритма поддержки дифференциальной диагностики состояний ST-ОИМ и СРРЖ/ЕР на основе глубокого обучения представлены в табл. 2.

Несмотря на то, что конкретная реализация алгоритма (в виде обученной нейронной сети) может быть

Таблица 1. Сравнительная оценка эффективности различных модификаций критерия

Table 1. Comparative evaluation of the effectiveness of various criterion modifications

Датасет	Вид критерия	Метрики			
		Точность (accuracy)	Точность (precision)	Полнота	F1-мера
[23]	(1)	0,88	0,84	0,86	0,85
[24]	(1)	0,64	0,44	0,78	0,56
	(2)	0,85	0,76	0,71	0,74
	(3)	0,79	0,63	0,69	0,66




Рис. 7. Графики результатов настройки модели при определении состояния СРРЖ: F1-меры (f1-score) (a, b), потери (loss) (c, d), точности (precision) (e, f), полноты (recall) (g, h), специфичности (specificity) (i, j). По горизонтали — число итераций
 Fig. 7. Results of model tuning when determining the EVRS: graphs of the F1-score (a, b), loss (c, d), precision (e, f), recall (g, h), specificity (i, j). Horizontal — number of iterations




Рис. 8. Графики результатов настройки модели при определении состояния острого инфаркта миокарда: графики F1-меры (f1-score) (*a, b*), потери (loss) (*c, d*), точности (precision) (*e, f*), полноты (recall) (*g, h*), специфичности (specificity) (*i, j*). По горизонтали — число итераций

Fig. 8. Results of model tuning when determining the AMI: graphs of the f1-score (*a, b*), loss (*c, d*), precision (*e, f*), recall (*g, h*), specificity (*i, j*). Horizontal — number of iterations

Таблица 2. Оценка эффективности алгоритмов на основе глубокого обучения

Table 2. Evaluation of the effectiveness of algorithms based on deep learning

Датасет	Состояние	Точность (accuracy)	Точность (precision)	Полнота	F1-мера
[24]	ST-ОИМ	0,96	0,85	0,86	0,88
	СРРЖ/ER	0,91	0,85	0,92	0,88

реализована в виде автономного приложения для мобильного телефона, с точки зрения возможностей модификации и дообучения на вновь поступающие клинические данные целесообразно размещение приложения на сервере и обращение к нему через сеть Интернет. Отметим, что алгоритм реализован на языке Python в виде набора библиотечных функций, входом которого является сигнал ЭКГ в цифровом виде, а выходом — булево значение признака заболевания с маркированной вероятностью.

Сравнительная оценка эффективности различных модификаций критериального подхода (табл. 1) и подхода на основе глубокого обучения (табл. 2) позволила сделать следующие выводы:

- эффективность автоматизированной дифференциальной диагностики состояний ST-ОИМ и СРРЖ/ER может сильно зависеть от данных, на которых проводится обучение метода;
- несмотря на то, что критерий вида (2) показал наилучшие показатели эффективности, с точки зрения робастности к данным целесообразно использовать модель (3);
- подход на основе глубокого обучения показывает лучшую эффективность, но требует дополнительной оценки робастности на альтернативных датасетах, что является предметом дальнейших исследований.

Заключение

В условиях пандемии COVID-19 скорая кардиологическая помощь во всем мире испытывает трудности, связанные с нехваткой профильных специалистов и специализированного оборудования. В связи с этим особую значимость приобретает построение систем поддержки принятия клинических решений для автоматизированной оценки параметров электрокардиограммы на основе клиент-серверной архитектуры. Рассмотрены ключевые аспекты создания системы поддержки принятия клинических решений: оцифровка исходной бумажной электрокардиограммы и автомати-

зированная оценка основных ее параметров с помощью приложения, устанавливаемого на мобильный телефон врача первичного звена, а также поддержка дифференциальной диагностики заболеваний на основах критериальной оценки и машинного обучения. В качестве примера приведена клинически значимая задача дифференциальной диагностики инфаркта миокарда с подъемом (элевацией) сегмента ST (ST-ОИМ) и синдрома ранней реполяризации желудочков (СРРЖ/ER).

Разработанные алгоритмы оцифровки и анализа электрокардиограммы позволили в автоматическом режиме и без подключения к сети Интернет оценить наиболее значимые элементы электрокардиограммы (амплитуды зубцов R, P, T, длительность интервалов RR и QT, а также сегментов ST и PR). При этом средняя ошибка определения положения наиболее сложных (сглаженных) пиков электрокардиограммы (зубцов R и T) — не более 0,1 мм.

Разработан алгоритм для поддержки дифференциальной диагностики состояний ST-ОИМ и СРРЖ/ER на основе критериального анализа электрокардиограммы. Предложенный алгоритм работает без подключения к сети Интернет и обеспечивает значения точности 0,85 и F-меры 0,74. Разработан альтернативный алгоритм на основе глубокой нейронной сети, который обеспечивает лучшие значения — 0,96 и 0,88 соответственно, но требует подключения к сети Интернет.

Все алгоритмы реализованы на языке Python в виде набора библиотечных функций и входят в состав создаваемой в Университете ИТМО библиотеки ECG Recognition Library, размещенной в открытом доступе¹. Они могут быть использованы как самостоятельно, так и в составе полномасштабной системы поддержки принятия клинических решений для автоматизированной оценки параметров электрокардиограммы на основе клиент-серверной архитектуры, которая является предметом дальнейшей работы авторов.

¹ [Электронный ресурс]. Режим доступа: <https://github.com/Med-AI-Lab/ECG-Recognition-Library> (дата обращения: 20.11.2022).

Литература

1. Yu J.-N., Wu B.-B., Yang J., Lei X.-L., Shen W.-Q. Cardio-cerebrovascular disease is associated with severity and mortality of COVID-19: A systematic review and meta-analysis // *Biological Research for Nursing*. 2021. V. 23. N 2. P. 258–269. <https://doi.org/10.1177/1099800420951984>
2. Abir M., Nelson Ch., Chan E.W., Al-Ibrahim H., Cutter Ch., Patel K., Bogar A. *Critical care surge response strategies for the 2020 COVID-19 outbreak in the United States*. Santa Monica, CA: RAND Corporation, 2020 [Электронный ресурс]. URL: https://www.rand.org/pubs/research_reports/RRA164-1.html (accessed: 09.09.2021).

References

1. Yu J.-N., Wu B.-B., Yang J., Lei X.-L., Shen W.-Q. Cardio-cerebrovascular disease is associated with severity and mortality of COVID-19: A systematic review and meta-analysis. *Biological Research for Nursing*, 2021, vol. 23, no. 2, pp. 258–269. <https://doi.org/10.1177/1099800420951984>
2. Abir M., Nelson Ch., Chan E.W., Al-Ibrahim H., Cutter Ch., Patel K., Bogar A. *Critical care surge response strategies for the 2020 COVID-19 outbreak in the United States*. Santa Monica, CA: RAND Corporation, 2020. Available at: https://www.rand.org/pubs/research_reports/RRA164-1.html (accessed: 09.09.2021).

- org/pubs/research_reports/RRA164-1.html (дата обращения: 09.09.2021).
3. Health systems resilience during COVID-19: Lessons for building back better / ed. by A. Sagan, E. Webb, I. de la Mata, J. Figueras, M. McKee, N. Azzopardi-Muscat. WHO Regional Office for Europe, 2021.
4. Wang N.C., Jain S.K., Estes N.A.M., Barrington W.W., Bazaz R., Bhonsale A., Kancharla K., Shalaby A.A., Voigt A.H., Saba S. Priority plan for invasive cardiac electrophysiology procedures during the coronavirus disease 2019 (COVID-19) pandemic // *Journal of Cardiovascular Electrophysiology*. 2020. V. 31. N 6. P. 1255–1258. <https://doi.org/10.1111/jce.14478>
5. Cook D.A., Oh S., Pusic M.V. Accuracy of physicians' electrocardiogram interpretations: A systematic review and meta-analysis // *JAMA Internal Medicine*. 2020. V. 180. N 11. P. 1461–1471. <https://doi.org/10.1001/jamainternmed.2020.3989>
6. Javed A., Khan S.U., Ali L., Ali S., Imrana Y., Rahman A. Machine learning-based automated diagnostic systems developed for heart failure prediction using different types of data modalities: A systematic review and future directions // *Computational and Mathematical Methods in Medicine*. 2022. V. 2022. P. 9288452. <https://doi.org/10.1155/2022/9288452>
7. Martin-Isla C., Campello V.M., Izquierdo C., Raisi-Estabragh Z., Baeßler B., Petersen S.E., Lekadir K. Image-based cardiac diagnosis with machine learning: A review // *Frontiers in Cardiovascular Medicine*. 2020. V. 7. P. 1. <https://doi.org/10.3389/fcvm.2020.00001>
8. Attia Z.I., Noseworthy P.A., Lopez-Jimenez F., Asirvatham S.J., Deshmukh A.J., Gersh B.J., Carter R.E., Yao X., Rabinstein A.A., Erickson B.J., Kapa S., Friedman P.A. An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: A retrospective analysis of outcome prediction // *Lancet*. 2019. V. 394. P. 861–867. [https://doi.org/10.1016/S0140-6736\(19\)31721-0](https://doi.org/10.1016/S0140-6736(19)31721-0)
9. Katoh T., Yashima M., Takahashi N., Watanabe E., Ikeda T., Kasamaki Y., Sumitomo N., Ueda N., Morita H., Hiraoka M. Expert consensus document on automated diagnosis of the electrocardiogram: The task force on automated diagnosis of the electrocardiogram in Japan. Part 2: Current status of inappropriate automated diagnosis is widely used electrocardiographs in Japan // *Journal of Arrhythmia*. 2021. V. 37. N 6. P. 1427–1433. <https://doi.org/10.1002/joa3.12646>
10. Sangaiah A., Arumugam M., Bian G. An intelligent learning approach for improving ECG signal classification and arrhythmia analysis // *Artificial Intelligence in Medicine*. 2020. V. 103. P. 101788. <https://doi.org/10.1016/j.artmed.2019.101788>
11. Tse G., Lee S., Li A., Chang D., Li G., Zhou J., Liu T., Zhang Q. Automated electrocardiogram analysis identifies novel predictors of ventricular arrhythmias in brugada syndrome // *Frontiers in Cardiovascular Medicine*. 2021. V. 7. P. 618254. <https://doi.org/10.3389/fcvm.2020.618254>
12. Rueda C., Fernández I., Larriba Y., Rodríguez-Collado A., Canedo C. Compelling new electrocardiographic markers for automatic diagnosis // *Computer Methods and Programs in Biomedicine*. 2022. V. 221. P. 106807. <https://doi.org/10.1016/j.cmpb.2022.106807>
13. Fortune J.D., Coppa N.E., Haq K.T., Patel H., Tereshchenko L.G. Digitizing ECG image: new fully automated method. 2021 [Электронный ресурс]. URL: <https://www.medrxiv.org/content/10.1101/2021.07.13.21260461v1.full.pdf> (дата обращения: 25.04.2022)
14. Vatian A., Peredreev D., Rodiontsev K., Murzina A., Klevtsova E., Tatarinova A., Treshkur T., Shalyto A., Gusarova N. Helping paramedics in assessing a patient's condition based on ECG by means of mobile phone // *Proc. of the International Conferences ICT, Society, and Human Beings 2021; Web Based Communities and Social Media 2021; and e-Health 2021*. 2021. P. 144–151. https://doi.org/10.33965/eh2021_2021061018
15. Agrawal S. *Image Processing in Python – The Computer Vision Techniques*. 2021 [Электронный ресурс]. <https://www.analyticsvidhya.com/blog/2021/08/image-processing-in-python-the-computer-vision-techniques/> (дата обращения: 25.04.2022)
16. Park J.-S., Lee S.-W., Park U. R Peak detection method using wavelet transform and modified shannon energy envelope // *Journal of Healthcare Engineering*. 2017. V. 2017. P. 4901017. <https://doi.org/10.1155/2017/4901017>
17. Nouira I., Abdallah A.B., Bedoui M.H., Dogui M. A robust R peak detection algorithm using wavelet transform for heart rate variability studies // *International Journal on Electrical Engineering and Informatics*. 2013, vol. 5, no. 3, pp. 270–284. <https://doi.org/10.15676/ijeei.2013.5.3.3>
3. *Health systems resilience during COVID-19: Lessons for building back better*. Ed. by A. Sagan, E. Webb, I. de la Mata, J. Figueras, M. McKee, N. Azzopardi-Muscat. WHO Regional Office for Europe, 2021.
4. Wang N.C., Jain S.K., Estes N.A.M., Barrington W.W., Bazaz R., Bhonsale A., Kancharla K., Shalaby A.A., Voigt A.H., Saba S., Priority plan for invasive cardiac electrophysiology procedures during the coronavirus disease 2019 (COVID-19) pandemic. *Journal of Cardiovascular Electrophysiology*, 2020, vol. 31, no. 6, pp. 1255–1258. <https://doi.org/10.1111/jce.14478>
5. Cook D.A., Oh S., Pusic M.V. Accuracy of physicians' electrocardiogram interpretations: A systematic review and meta-analysis. *JAMA Internal Medicine*, 2020, vol. 180, no. 11, pp. 1461–1471. <https://doi.org/10.1001/jamainternmed.2020.3989>
6. Javed A., Khan S.U., Ali L., Ali S., Imrana Y., Rahman A. Machine learning-based automated diagnostic systems developed for heart failure prediction using different types of data modalities: A systematic review and future directions. *Computational and Mathematical Methods in Medicine*, 2022, vol. 2022, pp. 9288452. <https://doi.org/10.1155/2022/9288452>
7. Martin-Isla C., Campello V.M., Izquierdo C., Raisi-Estabragh Z., Baeßler B., Petersen S.E., Lekadir K. Image-based cardiac diagnosis with machine learning: A review. *Frontiers in Cardiovascular Medicine*, 2020, vol. 7, pp. 1. <https://doi.org/10.3389/fcvm.2020.00001>
8. Attia Z.I., Noseworthy P.A., Lopez-Jimenez F., Asirvatham S.J., Deshmukh A.J., Gersh B.J., Carter R.E., Yao X., Rabinstein A.A., Erickson B.J., Kapa S., Friedman P.A. An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: A retrospective analysis of outcome prediction. *Lancet*, 2019, vol. 394, pp. 861–867. [https://doi.org/10.1016/S0140-6736\(19\)31721-0](https://doi.org/10.1016/S0140-6736(19)31721-0)
9. Katoh T., Yashima M., Takahashi N., Watanabe E., Ikeda T., Kasamaki Y., Sumitomo N., Ueda N., Morita H., Hiraoka M. Expert consensus document on automated diagnosis of the electrocardiogram: The task force on automated diagnosis of the electrocardiogram in Japan. Part 2: Current status of inappropriate automated diagnosis is widely used electrocardiographs in Japan. *Journal of Arrhythmia*, 2021, vol. 37, no. 6, pp. 1427–1433. <https://doi.org/10.1002/joa3.12646>
10. Sangaiah A., Arumugam M., Bian G. An intelligent learning approach for improving ECG signal classification and arrhythmia analysis. *Artificial Intelligence in Medicine*, 2020, vol. 103, pp. 101788. <https://doi.org/10.1016/j.artmed.2019.101788>
11. Tse G., Lee S., Li A., Chang D., Li G., Zhou J., Liu T., Zhang Q. Automated electrocardiogram analysis identifies novel predictors of ventricular arrhythmias in brugada syndrome. *Frontiers in Cardiovascular Medicine*, 2021, vol. 7, pp. 618254. <https://doi.org/10.3389/fcvm.2020.618254>
12. Rueda C., Fernández I., Larriba Y., Rodríguez-Collado A., Canedo C. Compelling new electrocardiographic markers for automatic diagnosis. *Computer Methods and Programs in Biomedicine*, 2022, vol. 221, pp. 106807. <https://doi.org/10.1016/j.cmpb.2022.106807>
13. Fortune J.D., Coppa N.E., Haq K.T., Patel H., Tereshchenko L.G. *Digitizing ECG image: new fully automated method*. 2021. Available at: <https://www.medrxiv.org/content/10.1101/2021.07.13.21260461v1.full.pdf> (accessed: 25.04.2022)
14. Vatian A., Peredreev D., Rodiontsev K., Murzina A., Klevtsova E., Tatarinova A., Treshkur T., Shalyto A., Gusarova N. Helping paramedics in assessing a patient's condition based on ECG by means of mobile phone. *Proc. of the International Conferences ICT, Society, and Human Beings 2021; Web Based Communities and Social Media 2021; and e-Health 2021*, 2021, pp. 144–151. https://doi.org/10.33965/eh2021_2021061018
15. Agrawal S. *Image Processing in Python – The Computer Vision Techniques*. 2021. Available at: <https://www.analyticsvidhya.com/blog/2021/08/image-processing-in-python-the-computer-vision-techniques/> (accessed: 25.04.2022)
16. Park J.-S., Lee S.-W., Park U. R Peak detection method using wavelet transform and modified shannon energy envelope. *Journal of Healthcare Engineering*, 2017, vol. 2017, pp. 4901017. <https://doi.org/10.1155/2017/4901017>
17. Nouira I., Abdallah A.B., Bedoui M.H., Dogui M. A robust R peak detection algorithm using wavelet transform for heart rate variability studies. *International Journal on Electrical Engineering and Informatics*, 2013, vol. 5, no. 3, pp. 270–284. <https://doi.org/10.15676/ijeei.2013.5.3.3>

- Informatics. 2013. V. 5. N 3. P. 270–284. <https://doi.org/10.15676/ijeei.2013.5.3.3>
18. Bae T.W., Kwon K.K. ECG PQRST complex detector and heart rate variability analysis using temporal characteristics of fiducial points // *Biomedical Signal Processing and Control*. 2021. V. 66. P. 102291. <https://doi.org/10.1016/j.bspc.2020.102291>
 19. Camm A.J., Malik M., Yap Y.G. *Acquired Long QT Syndrome*. Blackwell Futura, 2004. 208 p.
 20. Национальные российские рекомендации по применению методики холтеровского мониторирования в клинической практике (проект) [Электронный ресурс]. URL: <https://scardio.ru/content/images/recommendation/HM.pdf>. (дата обращения: 20.09.2022).
 21. Goldenberg I., Moss A.J., Zareba W. QT interval: how to measure it and what is “normal” // *Journal of Cardiovascular Electrophysiology*. 2006. V. 17. N 3. P. 333–336. <https://doi.org/10.1111/j.1540-8167.2006.00408.x>
 22. Kalyakulina A., Yusipov I., Moskalenko V., Nikolskiy A., Kosonogov K., Zolotykh N., Ivanchenko M. *Lobachevsky University Electrocardiography Database* [Электронный ресурс]. URL: <https://physionet.org/content/ludb/1.0.1/> (дата обращения: 20.09.2022).
 23. Smith S.W., Khalil A., Henry T.D., Rosas M., Chang R.J., Heller K., Scharrer E., Ghorashi M., Pearce L.A. Electrocardiographic differentiation of early repolarization from subtle anterior ST-segment elevation myocardial infarction // *Annals of Emergency Medicine*. 2012. V. 60. N 1. P. 45–56.e2. <https://doi.org/10.1016/j.annemergmed.2012.02.015>
 24. Liu F.F., Liu C., Zhao L., Zhang X., Wu X., Xu X., Liu Y., Ma C., Wei S., He Z., Li J., Yin K., Eddie N. An open access database for evaluating the algorithms of electrocardiogram rhythm and morphology abnormality detection // *Journal of Medical Imaging and Health Informatics*. 2018. V. 8. N 7. P. 1368–1373. <https://doi.org/10.1166/jmih.2018.2442>
 25. Choi H.Y., Kim W., Kang G.H., Jang Y.S., Lee Y., Kim J.G., Lee N., Shin D.G., Bae W., Song Y. Diagnostic accuracy of the deep learning model for the detection of ST elevation myocardial infarction on electrocardiogram // *Journal of Personalized Medicine*. 2022. V. 12. N 3. P. 336. <https://doi.org/10.3390/jpm12030336>
 26. Chang K.-C., Hsieh P.-H., Wu M.-Y., Wang Y.-C., Wei J.-T., Shih E.S.-C., Hwang M.-J., Lin W.-Y., Lin W.-T., Lee K.-J., Wang T.-H. Usefulness of multi-labelling artificial intelligence in detecting rhythm disorders and acute ST-elevation myocardial infarction on 12-lead electrocardiogram // *European Heart Journal - Digital Health*. 2021. V. 2. N 2. P. 299–310. <https://doi.org/10.1093/ehjdh/ztab029>
 27. Liu Z., Mao H., Wu C.-Y., Feichtenhofer C., Darrell T., Xie S. A ConvNet for the 2020s // *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, CVPR*. 2022. P. 11966–11976. <https://doi.org/10.1109/CVPR52688.2022.01167>
 28. Bae T.W., Kwon K.K. ECG PQRST complex detector and heart rate variability analysis using temporal characteristics of fiducial points. *Biomedical Signal Processing and Control*, 2021, vol. 66, pp. 102291. <https://doi.org/10.1016/j.bspc.2020.102291>
 29. Camm A.J., Malik M., Yap Y.G. *Acquired Long QT Syndrome*. Blackwell Futura, 2004, 208 p.
 30. *National Russian recommendations for the use of Holter monitoring in clinical practice (draft)*. Available at: <https://scardio.ru/content/images/recommendation/HM.pdf>. (accessed: 20.09.2022). (in Russian)
 31. Goldenberg I., Moss A.J., Zareba W. QT interval: how to measure it and what is “normal”. *Journal of Cardiovascular Electrophysiology*, 2006, vol. 17, no. 3, pp. 333–336. <https://doi.org/10.1111/j.1540-8167.2006.00408.x>
 32. Kalyakulina A., Yusipov I., Moskalenko V., Nikolskiy A., Kosonogov K., Zolotykh N., Ivanchenko M. *Lobachevsky University Electrocardiography Database*. Available at: <https://physionet.org/content/ludb/1.0.1/> (accessed: 20.09.2022).
 33. Smith S.W., Khalil A., Henry T.D., Rosas M., Chang R.J., Heller K., Scharrer E., Ghorashi M., Pearce L.A. Electrocardiographic differentiation of early repolarization from subtle anterior ST-segment elevation myocardial infarction. *Annals of Emergency Medicine*, 2012, vol. 60, no. 1, pp. 45–56.e2. <https://doi.org/10.1016/j.annemergmed.2012.02.015>
 34. Liu F.F., Liu C., Zhao L., Zhang X., Wu X., Xu X., Liu Y., Ma C., Wei S., He Z., Li J., Yin K., Eddie N. An open access database for evaluating the algorithms of electrocardiogram rhythm and morphology abnormality detection. *Journal of Medical Imaging and Health Informatics*, 2018, vol. 8, no. 7, pp. 1368–1373. <https://doi.org/10.1166/jmih.2018.2442>
 35. Choi H.Y., Kim W., Kang G.H., Jang Y.S., Lee Y., Kim J.G., Lee N., Shin D.G., Bae W., Song Y. Diagnostic accuracy of the deep learning model for the detection of ST elevation myocardial infarction on electrocardiogram. *Journal of Personalized Medicine*, 2022, vol. 12, no. 3, pp. 336. <https://doi.org/10.3390/jpm12030336>
 36. Chang K.-C., Hsieh P.-H., Wu M.-Y., Wang Y.-C., Wei J.-T., Shih E.S.-C., Hwang M.-J., Lin W.-Y., Lin W.-T., Lee K.-J., Wang T.-H. Usefulness of multi-labelling artificial intelligence in detecting rhythm disorders and acute ST-elevation myocardial infarction on 12-lead electrocardiogram. *European Heart Journal — Digital Health*, 2021, vol. 2, no. 2, pp. 299–310. <https://doi.org/10.1093/ehjdh/ztab029>
 37. Liu Z., Mao H., Wu C.-Y., Feichtenhofer C., Darrell T., Xie S. A ConvNet for the 2020s. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, CVPR*, 2022, pp. 11966–11976. <https://doi.org/10.1109/CVPR52688.2022.01167>

Авторы

Ватьян Александра Сергеевна — кандидат технических наук, доцент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0002-5483-716X>, alexvatyan@gmail.com

Гусарова Наталья Федоровна — кандидат технических наук, старший научный сотрудник, доцент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0002-1361-6037>, natfed@list.ru

Добренко Наталья Викторовна — кандидат технических наук, доцент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0001-6206-8033>, graziokisa@yandex.ru

Змиевский Данил Александрович — студент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0002-0077-794X>, daniel.zmievskiy@gmail.com

Кабышев Максим Васильевич — аспирант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0002-1006-0408>, maxk6971@gmail.com

Полевая Татьяна Андреевна — программист, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0001-6131-0019>, tanusha2406@gmail.com

Татарникова Анна Андреевна — кандидат медицинских наук, старший научный сотрудник, старший научный сотрудник, Национальный медицинский исследовательский центр им. В.А. Алмазова, Санкт-

Authors

Alexandra S. Vatian — PhD, Associate Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0002-5483-716X>, alexvatyan@gmail.com

Natalia F. Gusarova — PhD, Senior Researcher, Associate Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0002-1361-6037>, natfed@list.ru

Natalia V. Dobrenko — PhD, Associate Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0001-6206-8033>, graziokisa@yandex.ru

Danil A. Zmievisky — Student, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0002-0077-794X>, daniel.zmieviskiy@gmail.com

Maxim A. Kabyshev — PhD Student, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0002-1006-0408>, maxk6971@gmail.com

Tatiana A. Polevaya — Software Developer, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0001-6131-0019>, tanusha2406@gmail.com

Anna A. Tatarinova — PhD (Medicine), Senior Researcher, Senior Researcher, Almazov National Medical Research Centre, Saint Petersburg,

Петербург, 197341, Российская Федерация,  6603195545, <https://orcid.org/0000-0002-9046-2457>, antsvet.18@mail.ru

Томилов Иван Вячеславович — старший лаборант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0003-1886-2867>, ivan-tomilov3@yandex.ru

197341, Russian Federation,  6603195545, <https://orcid.org/0000-0002-9046-2457>, antsvet.18@mail.ru

Ivan V. Tomilov — Senior Laboratory Assistant, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0003-1886-2867>, ivan-tomilov3@yandex.ru

Статья поступила в редакцию 15.08.2022

Одобрена после рецензирования 28.10.2022

Принята к печати 29.11.2022

Received 15.08.2022

Approved after reviewing 28.10.2022

Accepted 29.11.2022



Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»