

# Проблемы внедрения алгоритмов машинного обучения в интеллектуальные носимые медицинские устройства мониторинга

Г. Х. Ирзаев

Дагестанский государственный технический университет

Проведена классификация носимых медицинских устройств для мониторинга состояния пациентов. Подчеркнуты особенности использования алгоритмов машинного обучения для носимых устройств в целях диагностики заболеваний, фиксации приступов, обнаружения аритмии, падений, стресса, распознавания физической и эмоциональной активности, назначения реабилитации. Рассмотрены методы машинного обучения в частном случае применения носимого устройства для наблюдения сердечной аритмии пациента. Проведен анализ исследований, в которых в качестве алгоритмов машинного обучения использовались метод опорных векторов и метод случайного леса для классификации аритмии. Рассмотрены работы, в которых используются подходы глубокого обучения для неструктурированных данных, в частности, архитектура сверточной нейронной сети для классификации аритмии и фибрилляции предсердий. Выявлены проблемы и ограничения использования машинного обучения в носимых устройствах. Предложены оптимальные решения проблем, связанных с надежностью и доступностью данных, выбором модели машинного обучения, безопасностью и конфиденциальностью данных пациентов, энергопотреблением и ограниченными объемами памяти носимых устройств

*Носимое медицинское устройство; машинное обучение; искусственный интеллект; мониторинг аритмии; электрокардиограмма; метод опорных векторов; сверточная нейронная сеть; метод случайного леса.*

## ВВЕДЕНИЕ

Для успешной диагностики и лечения пациентов, особенно с хроническими заболеваниями, современная медицина прибегает наряду с другими методами к непрерывному отслеживанию их состояния для эффективного последующего лечения. В этих случаях роль носимых устройств и вспомогательных гаджетов трудно переоценить. Носимые устройства диагностики и мониторинга, которые активно разрабатываются и модернизируются для медицинского применения, стали чаще использоваться как в стационарном, так и амбулаторном режимах наблюдения за больными.

К носимым устройствам относятся устройства, которые пациенты могут надеть или установить на части своего тела для того, чтобы в непрерывном режиме отслеживать различные физиологические параметры через систему датчиков. В устройства могут быть вмонтированы датчики температуры, давления, оптические датчики, акселерометры, биометрические датчики, сенсоры электрокардиограммы (ЭКГ), гироскопы, пульсоксиметры и др. Данные, которые собирают датчики, необходимо передавать и обрабатывать в непрерывном режиме в центрах накопления информации для принятия решений медицинским персоналом в интересах здоровья пациентов.

Искусственный интеллект (ИИ) привлек внимание исследователей биомедицинской отрасли благодаря своему перспективному потенциальному в обработке огромных объемов данных,

получении точных результатов и управлении процессами самыми оптимальными способами. Хотя вычислительная техника для принятия решений и прогнозирования последствий заболеваний использовались давно, в современных условиях развития медицины компьютеры и алгоритмы помогают надежно решать большинство повседневных задач и объяснять полученные результаты. Способность компьютера или робота копировать человеческий интеллект с помощью программного обеспечения и алгоритмов составляет суть ИИ, который способен выполнять интеллектуальные процессы, в числе которых визуализация, поиск лекарств, логические рассуждения, управляемая хирургия и обучение на основе знаний.

В исследовании обсуждается важность носимых устройств и данных, собранных с этих устройств, для диагностики различных заболеваний, а также эффективность использования методов машинного обучения (МО) для классификации, выявления аритмии с использованием данных ЭКГ. Цель работы – провести анализ последних исследований в области машинного обучения для носимых медицинских устройств с акцентом на решение проблем и ограничений, с которыми сталкиваются приложения МО. Это такие проблемы, как доступность, надежность и ограниченная размерность данных, выбор модели, безопасность и конфиденциальность, подключение, энергопотребление и хранение.

### **НОСИМЫЕ МЕДИЦИНСКИЕ УСТРОЙСТВА И АЛГОРИТМЫ МАШИННОГО ОБУЧЕНИЯ**

Показания стационарных приборов в медицинских учреждениях могут быть более точными, чем зафиксированные носимыми устройствами, но в зависимости от области применения и медицинских рекомендаций часто их точность считаются приемлемой для диагностирования и назначения персонализированного лечения. Например, для наблюдения сердечно-сосудистых аритмий ЭКГ служит основным диагностическим и лечебным инструментом. Однако обычные мониторы ЭКГ могут быть неудобны для пациентов, поскольку требуют использования гелиевых электродных кабелей и внешних электронных инструментов для получения сигналов. Более того, они обычно ограничены контролируемыми условиями лаборатории больницы или поликлиники, измеряют данные пациента в состоянии покоя. Значительная часть информации о работе сердца «вне медицинского учреждения» теряется, что делает стационарные мониторы ЭКГ непрактичными для непрерывного наблюдения, например, с учетом физических и эмоциональных нагрузок. Это представляет проблему для пациентов с сердечно-сосудистыми заболеваниями, которым необходим непрерывный анализ состояния их здоровья – они не могут позволить себе финансовые затраты и ежедневное посещение стационара. Такие же соображения относятся и к другим носимым гаджетам. Поэтому носимые устройства представляют собой более гибкое и удобное решение для непрерывного мониторинга. В табл. 1 систематизированы данные о современных носимых медицинских устройствах.

Носимые устройства относятся к категории Интернета медицинских вещей (IoMT), который включает стационарные, имплантируемые и периферийные устройства, используемые в медицинских учреждениях. Они обычно удаленно взаимодействуют с мобильными устройствами, а также могут подключаться к сети, как показано на рис. 1.

Машинное обучение – это широко используемый метод искусственного интеллекта для предсказания закономерностей. МО можно классифицировать в зависимости от структуры алгоритма и типа обучения как контролируемое, неконтролируемое обучение и обучение с подкреплением. В контролируемом обучении алгоритм более простой, точный и обучается на входных архивных данных, что позволяет прогнозировать будущие события. Методы неконтролируемого обучения могут выявлять закономерности в наборах данных, даже если данные неправильно классифицированы или помечены. Обучение с подкреплением относится к процессу, при котором агент взаимодействует с окружающей средой, приобретая знания об оптимальной политике посредством серии проб и ошибок для решения последовательных задач принятия решений.

Таблица 1

**Область применения и измеряемые параметры носимых медицинских устройств**

Наименование носимого устройства	Область применения	Измеряемые параметры человека	Наличие функции удаленного мониторинга
Умные часы, браслет	мониторинг основных параметров состояния человека, слежение за подвижностью, качеством сна, питания с высокой точностью	температура тела, пульс, артериальное давление, уровень холестерина, уровень мочевой кислоты, сатурация	да
Устройство комплексного медицинского наблюдения	мониторинг физиологических показателей человека, параметров активности и сна, симптомов заражения инфекцией	температура тела, пульс, сердечный ритм, частота дыхания, анализ активности, сна и походки; фиксация рвоты, чихания, кашля.	да
Одноразовый ЭКГ-пластырь	фиксация сердечного ритма при физической активности и отдыхе, реакции на препараты и нагрузку	сердечный ритм	да
Сенсорная система мониторинга сахарного диабета	измерение уровня глюкозы в крови для больных сахарным диабетом	уровень глюкозы	да
Умное кольцо	отслеживание основных параметров состояния здоровья	сердечный ритм, сатурация, параметры сна и физической активности	да
Монитор Холтера	мониторинг нарушений ритма и проводимости сердца, выявление аритмии, блокады, наличия импульсов в миокарде	сердечный ритм, частота сокращений, сердечные интервалы	нет
Смарт-очки дополненной и виртуальной реальности	применение при реабилитации после травм, лечения фобий, управления болью	для терапии	да
Умные текстильные изделия	отслеживание основных параметров пациента, падения пожилых людей.	пульс, частота дыхания, активность	да
Умная контактная линза	отслеживает внутриглазное давление при глаукоме	внутриглазное давление	да

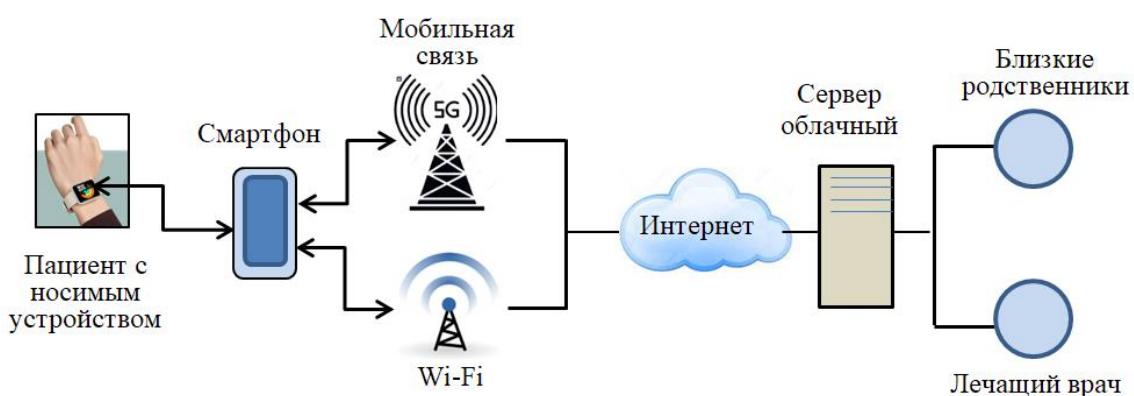


Рис. 1 Схема использования носимых медицинских устройств

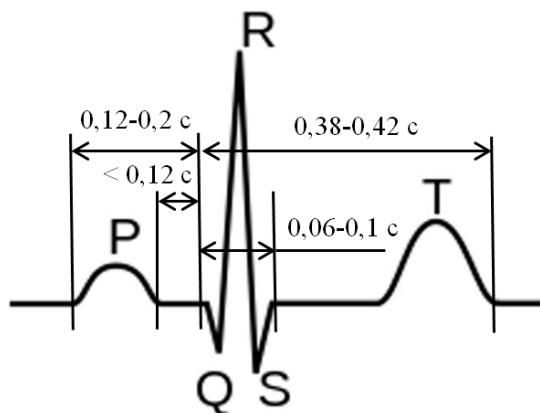
В здравоохранении крайне мало исследований, посвященных применению машинного обучения для носимых устройств. Однако, учитывая огромные массивы медицинских данных о пациентах, необходимость индивидуального анализа, сбора и ведения подробных записей о состоянии их здоровья, применение систем машинного обучения помогает автоматически выявлять закономерности и делать прогнозы на основе имеющихся данных. Благодаря использованию систем МО становится возможным эффективное управление большими объемами медицинских данных, улучшение процессов диагностирования и принятия решений о персонализированном лечении с более высоким уровнем точности.

Машинное обучение также позволяет носимым устройствам принимать автономные решения без необходимости явного программирования, разработанного для конкретного сценария, опираясь на знания, полученные из прошлого опыта. Многие приложения здравоохранения и ухода за пожилыми людьми используют алгоритмы МО, такие как диагностика заболеваний, обнаружение приступов, обнаружение аритмии, падений, стресса, распознавание физической и эмоциональной активности, назначение реабилитации. Применение приложений МО для носимых устройств только набирает силу на рынке, несмотря на множество научных исследований в области ИИ и телемедицины.

Датчики в носимых устройствах являются важным источником данных, и алгоритмы машинного обучения могут использоваться для извлечения признаков из этих данных с целью обнаружения и изучения полезных закономерностей. Несмотря на стремительный рост носимых устройств, в этой области по-прежнему необходимы дальнейшие исследования для повышения их точности и эффективного решения задачи приспособленности носимых медицинских приборов к строению человеческого тела и его параметрам.

### Машинное обучение на примере интеллектуального носимого устройства мониторинга аритмии

Рассмотрим использование методов МО в частном случае применения носимого устройства для наблюдения аритмии пациента. Сердечная аритмия – это нарушение ритма работы сердца. Электрокардиограмма нормального сердечного сокращения здорового человека имеет характерную форму, показанную на рис. 2. Зубец Р указывает на деполяризацию предсердий, за которым следует комплекс QRS, указывающий на деполяризацию желудочков, и зубец Т, указывающий на реполяризацию желудочков.



**Рис. 2** Электрокардиограмма здорового человека

Изменения в ЭКГ могут указывать на скрытые патофизиологические изменения. Наиболее распространенным типом нерегулярной аритмии, которую можно распознать по изменениям ЭКГ, является фибрилляция предсердий. Она характеризуется дезорганизованными электрическими импульсами предсердий и увеличивает риск инсульта до 17% ежегодно [Kac20]. Кроме того, фибрилляция предсердий с устойчивой частотой желудочковых сокращений

более 110 ударов в минуту может привести к кардиомиопатии, сердечной недостаточности и внезапной сердечной смерти при отсутствии адекватного лечения [Бык13]. Распространенность фибрилляции предсердий в мире оценивается в [Тур18] примерно в 46 миллионов человек ежегодно, причем до трети этих людей не имеют симптомов и, находясь в неведении, подвергаются повышенному риску инсульта.

Помимо фибрилляции предсердий, существуют и другие аритмии, о которых могут сигнализировать носимые устройства ЭКГ, включая преждевременное сокращение предсердий или желудочков, трепетание предсердий, атриовентрикулярную реципрокную тахикардию, атриовентрикулярную узловую реципрокную тахикардию и сердечную блокаду разных степеней. Несколько недавних работ продемонстрировали использование носимых технологий, способных идентифицировать преждевременные сокращения предсердий или правого желудочка сердца с точностью более 97% [Мен22, Юж21, Губ21]. Класс злокачественных аритмий, примерами которых являются желудочковая тахикардия и фибрилляция желудочков, имеет высокий риск прогрессирования до остановки сердца или даже смерти [Zip98].

Однако носимые устройства ограничены в своих возможностях обнаружения аритмий, отличных от фибрилляции предсердий, особенно желудочковой тахикардии или фибрилляции желудочков. В целом, существует ограниченное количество исследований, посвященных носимым устройствам с ИИ для мониторинга аритмии. В некоторых исследованиях для изучения применения ЭКГ с ИИ используются коммерчески доступные носимые устройства, например, Amazfit Band 1S (рис. 3, *а*) [Che20], биосенсоры HealthyPiV3 [Pan21] или пульсометр Polar H7 [Low20] (рис. 3, *б*). Распространены смарт-часы с одним каналом ЭКГ, которые, как доказано, обнаруживают фибрилляцию предсердий у пациентов [Per19]. Другое устройство, разработанное для мониторинга и обнаружения фибрилляции предсердий, включает в себя беспроводной одноканальный ЭКГ-пластырь, фиксируемый на груди (рис. 3, *в*), который обеспечивает мониторинг ЭКГ в реальном времени с использованием облачного анализа данных и обмена данными с медицинским учреждением [Sha20]. Индивидуальный носимый ЭКГ-регистратор на запястье [FuW21] при исследовании показал высокую точность 99,4% при наблюдении аритмии, хотя использовался небольшой набор данных от пациентов. Наконец, был описан нагрудный ремень для регистрации ЭКГ с одним каналом, который передает данные в облачный сервис для анализа. Анкетирование пользователей показало, что 77% участников предпочли нагрудный ремень стандартному монитору Холтера с тремя каналами. Чувствительность (вероятность получения положительного результата теста при болезни) и специфичность (вероятность получения отрицательного результата теста без болезни) составили 100% и 95,4% соответственно [San21].



**Рис. 3** Носимые устройства для мониторинга аритмии

*а* – ЭКГ-регистратор Amazfit Band 1S на запястье; *б* – беспроводной одноканальный ЭКГ-пластырь; *в* – нагрудной пульсометр Polar H7

Большинство исследований носимых устройств ЭКГ с ИИ проводилось с использованием общедоступных баз данных, таких как PhysioNet и МИТ-ВИН, но некоторые немногие исследовательские группы самостоятельно получали данные от пациентов. Анализируемые наборы данных включали аннотации врачей, которые служили справочной информацией для обучения алгоритма ИИ.

Машинное обучение и глубокое обучение (ГО) широко применяются к данным ЭКГ для выявления аритмий. Несмотря на относительно низкую производительность, МО используется для выявления аритмии из-за некоторых ограничений ГО, включая ресурсоемкие гиперпараметры для поиска оптимальной конфигурации сети и сложности в понимании правил, лежащих в основе обученных моделей прогнозирования. Тем не менее, ГО продемонстрировало незначительные улучшения для выявления аритмии. Различное разрешение выборки может представлять собой проблему для этих методов, но было показано, что можно точно выявлять аритмии, используя данные ЭКГ с пониженной дискретизацией [Ben22].

Подходы МО для носимых устройств часто включают в себя использование метода опорных векторов SVM для классификации аритмии [Baz20, Smi18]. Основная идея метода заключается в построении гиперплоскости, разделяющей объекты выборки оптимальным способом. Алгоритм работает в предположении, что чем больше расстояние (зазор) между разделяющей гиперплоскостью и объектами разделяемых классов, тем меньше будет средняя ошибка классификатора. Применяется также метод случайного леса [Sha20, Mei18], когда вместо одного решающего дерева создается множество деревьев. Для каждого отдельного дерева вводится обучающая выборка путем случайного извлечения с возвращением. При каждом разветвлении дерева выбирается случайное подмножество признаков, а не все признаки сразу. Прогноз вырабатывается агрегированием результатов всех деревьев и решение принимается большинством голосов.

Многоступенчатые и многоуровневые системы классификации выводят локальные характеристики активности предсердий и желудочков посредством комбинации методов SVM и деревьев решений, а также глобальных характеристик из необработанной записи ЭКГ, что, в конечном итоге, приводит к классификации через линейный метод SVM. Например, в работе [Tan20] предложен метод SVM с повернутым линейным ядром, в котором обучаются два классификатора – один на глобальном наборе данных, а другой – на наборе данных, зависящем от пациента. Получают две разные дискриминантные гиперплоскости, а окончательная гиперплоскость, полученная путем поворота первой гиперплоскости на определенную величину в направлении второй гиперплоскости, приводит к улучшенной чувствительности.

Аналогичным образом, этот метод МО использовался с классификатором декоррелированных диаграмм Лоренца межсердечных интервалов [Low20] и с другим классификатором, построенным на признаках, извлеченных с помощью методов предварительной обработки из диаграмм Пуанкаре плотностей, которые представляли сегменты ЭКГ [Bas21]. В качестве альтернативы было продемонстрировано использование SVM с помощью метода полуkontroliriuemogo обучения [Hua18], в то время как гибридная структура эффективно объединяла преимущества ансамблевого обучения и эволюционных вычислений для максимальной точности классификации аритмии [Pla20].

Что касается подходов глубокого обучения для неструктурированных данных, архитектура сверточной нейронной сети (CNN) была применена для классификации аритмии в работах [Kar22, Zha22] и фибрилляции предсердий в исследовании [Ram21]. Другие архитектуры, представляющие интерес для классификации фибрилляции предсердий, включают глубокую плотно связанную нейронную сеть на основе 12-канальной ЭКГ [Cai20], нейронную сеть прямого распространения на основе признаков, охватывающих интервалы RR между последовательными зубцами на кардиограмме [Che22]. Были также представлены гибридные конструкции, часто включающие архитектуру на основе расширенного метода SVM с прогнозами от CNN [MaC21]. В исследовании [Tan20] была предложена универсальная сверточная нейронная сеть (Generic CNN), подходящая для всех пациентов, и настроенная специализированная сверточная нейронная сеть, полученная путем точной настройки предыдущей модели относительно конкретного человека [LiY18]. Другим интересным подходом является использование глобальной гибридной CNN для улучшения извлечения признаков и классификации данных ЭКГ, описанный в научной статье [Zha21].

Предыдущие исследования также разрабатывали легкие модели глубокого обучения с использованием облачных приложений для эффективной классификации данных ЭКГ. Эти подходы используют слои объединенной рекуррентной нейронной сети (RNN) вместо стандартных слоев [Jeo20]. Применение методов сжатия [Lee22] и преобразования (Accu 99,60%) [Rib22] для уменьшения размера модели с точки зрения вычислительных параметров, привело к снижению потребления памяти и времени вывода. В качестве альтернативы данные ЭКГ могут быть сжаты для обеспечения классификации фибрилляции предсердий в реальном времени [Che20b, Zha20].

## ПРОБЛЕМЫ И ОГРАНИЧЕНИЯ ИСПОЛЬЗОВАНИЯ МАШИННОГО ОБУЧЕНИЯ В НОСИМЫХ МЕДИЦИНСКИХ УСТРОЙСТВАХ

### Доступность и надежность данных

Методы машинного обучения, особенно в здравоохранении, требуют наличия достаточного количества обучающих данных для получения точных результатов для новых наборов данных. Надежность данных имеет первостепенное значение для пациентов и врачей при принятии обоснованных медицинских решений, которые в некоторых ситуациях могут иметь опасные для жизни последствия. Чтобы гарантировать надежность данных, крайне важно проводить разнообразные клинические испытания и предоставлять четкую отчетность о результатах. Это необходимо для оценки различных технологий и определения перспектив будущих исследовательских проектов. Более того юридические аспекты сбора и использования информации должны быть строго определены и регламентированы.

Клиническая надёжность носимых устройств обусловлена тем, что они собирают меньше информации, чем их стационарные аналоги. Например, ЭКГ носимых устройств обычно регистрируется в одном-трёх каналах, в то время как стационарно используемые устройства имеют двенадцать каналов. Данные, собранные носимыми устройствами, зачастую являются дискретными или зашумленными. Кроме того, эффективность соответствующих алгоритмов ИИ в режиме реального времени может быть снижена из-за ограниченной емкости аккумулятора носимого устройства или из-за облачной обработки данных, ограничений для подключения к беспроводным сетям в сельской местности.

После записи с помощью носимых устройств данные обычно просматриваются врачами для лучшего понимания болезни пациента, однако диагнозы и прогнозы, предоставляемые алгоритмами ИИ, не так охотно принимаются врачами, поскольку для них алгоритмы представляют «черный ящик». То есть алгоритм ИИ может принять решение о конкретном медицинском состоянии, но отсутствие физиологического понимания делает надежность таких решений неопределенной по клиническим стандартам.

Необходимость предоставления физиологических данных связана с двумя ограничениями. Во-первых, определение суммарных признаков, учитывающих предметную область, для использования ИИ снижает размерность данных и может, таким образом, ограничивать потенциал прогнозирования за счёт более глубокого понимания физиологических процессов. Действительно, для проведения контролируемого обучения и, следовательно, соответствия клиническим стандартам понимания физиологических процессов, данные должны быть обработаны для получения транслируемых суммарных признаков. Например, для анализа ЭКГ такими характеристиками могут быть интервал R–R, ширина и амплитуда комплекса QRS, а также элевация (смещение сегмента ЭКГ вверх от изоэлектрической линии) или депрессия сегмента ST. Этот подход основан на знании, какие суммарные признаки необходимо определить. К сожалению, определение транслируемых характеристик основано на тех, которые уже известны традиционной медицине. Эти характеристики наиболее очевидны для интерпретации человеком, но подрывают главное преимущество использования ИИ – способность принимать решения, выходящие за рамки человеческого понимания. Во-вторых, возможно целесообразно выполнить такие этапы обработки, как усечение, фильтрация или понижение частоты дискретизации данных, чтобы сделать физиологические детали более очевидными

или оптимизировать входные данные перед запуском алгоритма ИИ. Однако эти этапы также потенциально удаляют ценную информацию, выходящую за рамки уровня человеческой интерпретации. Для достижения компромисса между более глубокими знаниями и пониманием физиологических особенностей можно использовать тепловые карты, выделяющие временной сегмент ЭКГ, наиболее важный для классификации [Lee21].

Другая проблема, с которой сталкивается врач при анализе диагнозов ИИ, заключается в отсутствии стандартов для определения того, какой уровень правильности достаточен для замены врача в качестве основного эксперта. Такой порог особенно важно учитывать в контексте обучения алгоритмов ИИ врачами-специалистами, поскольку в этом случае диагнозы ИИ соотносятся с наиболее лучшим клиническим стандартом, а не со средним значением. Кроме того, этот стандарт предполагает, что все пациенты имеют доступ к лучшему врачу-специалисту, с которым сравнивается алгоритм ИИ, хотя в обычных условиях не все пациенты имеют доступ к опытным врачам, тем более в режиме реального времени. Таким образом, носимые устройства в сочетании с алгоритмами ИИ обеспечивают гораздо более качественный мониторинг пациентов и имеют более высокий стандарт диагностической надежности.

Дополнительным ограничением современных методов ИИ является то, что обучение алгоритмов требует наличия качественных данных. В большинстве случаев такие наборы данных должны быть достаточно большими, чтобы их можно было разделить на обучающие и тестовые, а также следить, чтобы большинство полей были полными и очищенными от ошибочной информации. Однако разработчикам следует помнить, что каждая база данных имеет свои ограничения, которые сужают область ее использования. После принятия алгоритма необходима постоянная клиническая валидация и очистка после применения базы данных для поддержания точности и корректности предсказаний.

### Проблема выбора модели машинного обучения

При выборе модели МО для носимых устройств необходимо учитывать несколько факторов. Одним из основных критериев является минимизация меры ошибки, используемой для решения задач регрессии, или максимизация шкалы оценки, используемой для определения точности классификации. Часто наблюдается, что обучение комбинации различных моделей дает наилучшие результаты. Более того, ключевым фактором, который следует учитывать, является интерпретируемость или объяснимость модели, что имеет большое значение, особенно в приложениях здравоохранения. В таких ситуациях результат классификации, регрессии или кластеризации должен быть понятным и содержательным для пользователя, что делает его ключевым критерием. В этом контексте модели на основе деревьев часто считаются более интерпретируемыми, чем модели на основе нейронных сетей. Другим важным фактором является размер модели, который необходимо учитывать при адаптации модели к носимому устройству с ограниченной памятью. Кроме того, крайне важно учитывать вычислительные сложности как вывода, так и онлайн-обучения на устройстве для персонализации. Это особенно важно, учитывая ограниченные вычислительные возможности носимых устройств для мониторинга здоровья.

### Безопасность и конфиденциальность

Получение данных от пользователей через носимые устройства и последующая передача этих данных в сервисы машинного обучения на облачных платформах, как показано на рис. 1, представляет собой процесс, уязвимый для ряда угроз безопасности и конфиденциальности. Данные пользователей могут подвергнуться кибератакам. Большинство современных смартфонов оснащены модулями Bluetooth и Wi-Fi, необходимыми для подключения фитнес-трекеров к их приложениям, но остаются уязвимыми для различных нарушений безопасности, что увеличивает вероятность несанкционированной утечки личной информации пользователей.

Появление облачных архитектур Интернета вещей привело к появлению ряда фундаментальных требований к безопасности и конфиденциальности личности, местоположения и лич-

ных привычек, для защиты целостности данных. Для создания безопасной облачной инфраструктуры IoMT необходимо реализовать меры, обеспечивающие конфиденциальность входных, выходных данных и функциональности. Необходимо предпринять усилия для предотвращения доступа злоумышленников к личным данным и эффективного противодействия атакам перехвата пакетов.

Кроме того, обеспечение прямой и обратной безопасности критически важно, чтобы новые пользователи могли расшифровывать зашифрованные сообщения только при подключении к сети, в то время как отстраненные пользователи не должны иметь возможности расшифровывать после ухода. Поэтому крайне важно определить стратегии и протоколы безопасности IoMT, а также предоставить пользователям возможность каждый раз выбирать предпочтительный вариант.

Основная функция расширенного стандарта шифрования (AES) – гарантировать конфиденциальность, в то время как алгоритм RSA использовать для асимметричного шифрования, цифровых подписей и управления ключами. Стандарты безопасных хеш-функций (SHA) применяются вместе с алгоритмом Диффи–Хеллмана и криптографией на эллиптических кривых для обеспечения конфиденциальности с помощью асимметричной криптографии.

В последнее время разработчики программного обеспечения носимых устройств особенно интересуются механизмами безопасности комбинированного режима, поскольку он обеспечивает как шифрование, так и аутентификацию, которые необходимы для компактных, встраиваемых или портативных устройств. В настоящее время значительное внимание уделяется оптимизации шифров, и алгоритмы шифрования тщательно изучаются с учетом ресурсов, доступных на различных устройствах IoMT.

### **Интероперабельность**

Способность интегрировать данные и использовать их вместе с другими формами данных повышает интероперабельность, имеющую решающее значение для использования преимуществ новых и больших наборов данных, полученных с помощью носимых устройств. И наоборот, низкий уровень интероперабельности препятствует интеграции данных носимых устройств с другими данными, связанными со здоровьем, затрудняя сравнение и оценку результатов, полученных с различных устройств и датчиков альтернативными методами. Таким образом, обеспечение интероперабельности данных носимых устройств на программном и аппаратном уровнях может облегчить сравнение результатов, полученных альтернативными методами, и оценить потенциальные расхождения. Например, интеграция носимых устройств в медицинские услуги сопряжена с трудностями из-за необходимости привлечения и обучения дополнительного IT-персонала, поскольку конфигурации программного и аппаратного обеспечения различаются. Кроме того, стандарты совместимости играют жизненно важную роль в управлении данными, позволяя интегрировать носимые устройства в медицинские услуги. Например, данные. Полученные из носимых устройств мониторинга можно внедрить в электронные медицинские карты, устранив риски кибербезопасности, способствуя прозрачности и отчетности в информационных системах здравоохранения.

### **Ограничения по энергопотреблению, памяти и технологиям связи**

Основным ограничением носимых устройств является их энергопотребление, которое в основном обусловлено ограниченным временем автономной работы. Для облачных вычислений, в случае приложений МО, физиологические данные, собранные датчиками устройства, передаются в облако, что значительно влияет на энергопотребление. Для носимых устройств многие элементы, включая электронную плату, операционную систему и другое программное обеспечение, компоненты биосенсоров с различными частотами дискретизации, объем данных, передаваемых по каналу связи, скорость регистрации данных на устройстве и дисплее носимого устройства, отрицательно влияют на энергопотребление. В связи с этим предлагаются схемы, направленные на оптимизацию энергопотребления компонентами [Хар24, Ели23,

Max23]. Считается, что отправка и получение данных потребляют больше энергии, чем измерения и регистрация информации. Сокращение объема данных, хранящихся и отправляемых в облако, является потенциальной стратегией снижения энергопотребления. Текущая вычислительная мощность и время автономной работы носимых устройств могут ограничивать использование передовых алгоритмов МО.

Возможность внедрения приложения МО на носимом устройстве зависит от различных факторов, таких как сложность модели, которая включает количество параметров и слоев, размеры устройства, объем данных и используемый вид обработки (пакетная или обработка в реальном времени). Небольшие размеры и вес современных носимых устройств делают их также ограниченными по объему памяти. Из-за количества параметров и слоев в модели, высокоточная модель требует больше памяти, чем модель с низкой точностью. В носимых устройствах IoT для обеспечения короткого времени загрузки и устойчивого восстановления системы при внезапном отключении используется энергонезависимая память (например, F-RAM, MRAM, EEPROM и флэш-память). В зависимости от конкретного применения МО размер памяти некоторых моделей может превышать 100 МБ или даже гигабайт, особенно те, которые включают в себя входные данные изображений. Эти модели могут оказаться несовместимыми с носимыми устройствами из-за ограничений памяти, необходимой для выполнения вычислений.

В случае модели периферийных вычислений для связи между носимым устройством и периферийным устройством может использоваться один из стандартов UWB, NFC, RFID, Zigbee или Bluetooth. Облегченная технология Bluetooth обычно предпочтительна из-за ее более низкого энергопотребления, однако спецификация Bluetooth 5 допускает до семи подключений к устройству. При их одновременном подключении каналов производительность может снизиться, возникнут проблемы с сопряжением при установлении нескольких подключений к смартфону.

Выбор технологии связи зависит от различных факторов, таких как скорость передачи данных, необходимая для носимого устройства, максимальное расстояние между носимым устройством и устройством, а также требования к задержке сигнала.

## ЗАКЛЮЧЕНИЕ

Носимые медицинские устройства играют важную роль в получении высокоточных биосигналов, которые необходимы для реализации цифровой медицины. Для достижения цели успешного лечения пациентов решающее значение имеет использование носимых устройств, которые фиксируют непрерывный поток клинических показателей жизнедеятельности человека. Кроме того, ИИ должен быть реализован для распознавания тенденций и маркеров, которые могут указывать на изменения в базовой физиологии или на начало заболевания. В статье представлен анализ способов использования носимых устройств в здравоохранении и применения методов искусственного интеллекта для сбора и анализа поступающей на них информации.

Представлен углубленный анализ сильных и слабых сторон использования машинного обучения в здравоохранении. Методы, предложенные в исследованиях, сложно сравнивать из-за различных наборов данных и различных целей исследований. Тем не менее, наиболее перспективным алгоритмом для приложений ЭКГ является архитектура глубокого обучения CNN, однако широко используются также метод опорных векторов SVM и метод деревьев решений. Рассмотрены проблемы и ограничения использования МО в носимых медицинских устройствах, связанные с надежностью и доступностью данных, выбором модели машинного обучения, безопасностью и конфиденциальностью данных пациентов, ограничениями, связанными с энергопотреблением, объемами памяти и технологиями связи носимых устройств.

## СПИСОК ЛИТЕРАТУРЫ | REFERENCES

- [Bas21] Bashar S. K., Han D., Zieneddin F., Ding E., Fitzgibbons T. P., Walkey A. J., McManus D. D., Javidi B., Chon K. H. Novel Density Poincaré Plot Based Machine Learning Method to Detect Atrial Fibrillation from Premature Atrial/Ventricular Contractions // IEEE Trans. Biomed. Eng. 2021. Vol. 68. Pp. 448–460. DOI: [10.1109/TBME.2020.3004310](https://doi.org/10.1109/TBME.2020.3004310).
- [Baz20] Bazi Y., Al Rahhal M. M., AlHichri H., Ammour N., Alajlan N., Zuair M. Real-Time Mobile-Based Electrocardiogram System for Remote Monitoring of Patients with Cardiac Arrhythmias // Int. J. Pattern Recognit. Artif. Intell. 2020. Vol. 34. P. 2058013. DOI: [10.1142/S0218001420580136](https://doi.org/10.1142/S0218001420580136).
- [Ben22] Ben Itzhak S., Ricon S. S., Biton S., Behar J. A., Sobel J. A. Effect of temporal resolution on the detection of cardiac arrhythmias using HRV features and machine learning // Physiol. Meas. 2022. Vol. 43. P. 045002. DOI: [10.1088/1361-6579/ac6561](https://doi.org/10.1088/1361-6579/ac6561).
- [Cai20] Cai W., Chen Y., Guo J. et al. Accurate detection of atrial fibrillation from 12-lead ECG using deep neural network // Comput. Biol. Med. 2020. Vol. 116. Pp. 103378. DOI: [10.1016/j.combiomed.2019.103378](https://doi.org/10.1016/j.combiomed.2019.103378).
- [Che20] Chen E., Jiang J., Su R., Gao M., Zhu S., Zhou J., Huo Y. A new smart wristband equipped with an artificial intelligence algorithm to detect atrial fibrillation // Heart Rhythm. 2020. Vol. 17. Pp. 847–853. DOI: [10.1016/j.hrthm.2020.01.034](https://doi.org/10.1016/j.hrthm.2020.01.034).
- [Che20b] Cheng Y., Hu Y., Hou M., Pan T., He W., Ye Y. Atrial Fibrillation Detection Directly from Compressed ECG with the Prior of Measurement Matrix // Information. 2020. Vol. 11. P. 436. DOI: [10.3390/info11090436](https://doi.org/10.3390/info11090436).
- [Che22] Chen Y., Zhang C., Liu C., Wang Y., Wan X. Atrial Fibrillation Detection Using a Feedforward Neural Network // J. Med. Biol. Eng. 2022. Vol. 42. Pp. 63–73. DOI: [10.1007/s40846-022-00681-z](https://doi.org/10.1007/s40846-022-00681-z).
- [FuW21] Fu W., Li R. Diagnostic performance of a wearing dynamic ECG recorder for atrial fibrillation screening: The HUAMI heart study // BMC Cardiovasc. Disord. 2021. Vol. 21. P. 558.
- [Hua18] Hua J., Zhang H., Liu J., Xu Y., Guo F. Direct Arrhythmia Classification from Compressive ECG Signals in Wearable Health Monitoring System // J. Circuits Syst. Comput. 2018. Vol. 27. P. 1850088. DOI: [10.1142/S0218126618500883](https://doi.org/10.1142/S0218126618500883).
- [Jeo20] Jeon E., Oh K., Kwon S., Son H., Yun Y., Jung E.-S., Kim M.S. A Lightweight Deep Learning Model for Fast Electrocardiographic Beats Classification with a Wearable Cardiac Monitor: Development and Validation Study // JMIR Public Health Surveill. 2020. Vol. 8. P. e17037. DOI: [10.2196/17037](https://doi.org/10.2196/17037).
- [Kar22] Karthiga S., Abirami A. M. Deep Learning Convolutional Neural Network for ECG Signal Classification Aggregated Using IoT // Comput. Syst. Sci. Eng. 2022. Vol. 42. Pp. 851–866. DOI: [10.32604/csse.2022.021935](https://doi.org/10.32604/csse.2022.021935).
- [Lee21] Lee H., Shin M. Learning Explainable Time-Morphology Patterns for Automatic Arrhythmia Classification from Short Single-Lead ECGs // Sensors. 2021. Vol. 21. P. 4331. DOI: [10.3390/s21134331](https://doi.org/10.3390/s21134331).
- [Lee22] Lee K.-S., Park H.-J., Kim J. E., Kim H. J., Chon S., Kim S., Jang J., Kim J.-K., Jang S., Gil Y., et al. Compressed Deep Learning to Classify Arrhythmia in an Embedded Wearable Device // Sensors. 2022. Vol. 22. P. 1776. DOI: [10.3390/s22051776](https://doi.org/10.3390/s22051776).
- [LiY18] Li Y., Pang Y., Wang J., Li X. Patient-specific ECG classification by deeper CNN from generic to dedicated // Neurocomputing. 2018. Vol. 314. Pp. 336–346. DOI: [10.1016/j.neucom.2018.06.068](https://doi.org/10.1016/j.neucom.2018.06.068).
- [Low20] Lown M., Brown M., Brown C., Yue A. M., Shah B. N., Corbett S. J., Lewith G., Stuart B., Moore M., Little P. Machine learning detection of Atrial Fibrillation using wearable technology // PLoS ONE. 2020. Vol. 15/ Pp. e0227401. DOI: [10.1371/journal.pone.0227401](https://doi.org/10.1371/journal.pone.0227401).
- [MaC21] Ma C., Wei S., Chen T., Zhong J., Liu Z., Liu C. Integration of Results from Convolutional Neural Network in a Support Vector Machine for the Detection of Atrial Fibrillation // IEEE Trans. Instrum. Meas. 2021. Vol. 70. Pp. 215–220. DOI: [10.1109/TIM.2020.3044718](https://doi.org/10.1109/TIM.2020.3044718).
- [Mei18] Mei Z., Gu X., Chen H., Chen W. Automatic Atrial Fibrillation Detection Based on Heart Rate Variability and Spectral Features // IEEE Access. 2018. Vol. 6. Pp. 53566–53575.
- [Men22] Meng L., Tan W., Ma J., Wang R., Yin X., Zhang Y. Enhancing dynamic ECG heartbeat classification with lightweight transformer model // Artif. Intell. Med. 2022. Vol. 124. Pp. 102236. DOI: [10.1016/j.artmed.2022.102236](https://doi.org/10.1016/j.artmed.2022.102236).
- [Pan21] Panganiban E. B., Paglinawan A. C., Chung W. Y., Paa G. L. S. ECG diagnostic support system (EDSS): A deep learning neural network based classification system for detecting ECG abnormal rhythms from a low-powered wearable bio-sensors // Sens. Bio-Sens. Res. 2021. Vol. 31. Pp. 100398. DOI: [10.1016/j.sbsr.2021.100398](https://doi.org/10.1016/j.sbsr.2021.100398).
- [Per19] Perez M. V., Mahaffey K. W., Hedlin H., Rumsfeld J. S., Garcia A., Ferris T., Balasubramanian V., Russo A. M., Rajmane A., Cheung L., et al. Large-Scale Assessment of a Smartwatch to Identify Atrial Fibrillation // N. Engl. J. Med. 2019. Vol. 381. Pp. 1909–1917. DOI: [10.1056/NEJMoa1901183](https://doi.org/10.1056/NEJMoa1901183).
- [Pła20] Pławiak P., Acharya U. R. Novel deep genetic ensemble of classifiers for arrhythmia detection using ECG signals // Neural Comput. Appl. 2020. Vol. 32. Pp. 11137–11161. DOI: [10.1007/s00521-018-03980-2](https://doi.org/10.1007/s00521-018-03980-2).
- [Ram21] Ramesh J., Solatidehkordi Z., Aburukba R., Sagahyroon A. Atrial Fibrillation Classification with Smart Wearables Using Short-Term Heart Rate Variability and Deep Convolutional Neural Networks // Sensors. 2021. Vol. 21. P. 7233. DOI: [10.3390/s2117233](https://doi.org/10.3390/s2117233).
- [Rib22] Ribeiro H. D. M., Arnold A., Howard J. P., Shun-Shin M. J., Zhang Y., Francis D. P., Lim P. B., Whinnett Z., Zolgharni M. ECG-based real-time arrhythmia monitoring using quantized deep neural networks: A feasibility study // Comput. Biol. Med. 2022. Vol. 143/ Pp. 26093–26106. DOI: [10.1016/j.combiomed.2022.105249](https://doi.org/10.1016/j.combiomed.2022.105249).

- [San21] Santala O. E., Halonen J., Martikainen S. et al. Automatic Mobile Health Arrhythmia Monitoring for the Detection of Atrial Fibrillation: Prospective Feasibility, Accuracy, and User Experience Study // JMIR mHealth uHealth. 2021. Vol. 9. P. 29933. DOI: [10.2196/29933](https://doi.org/10.2196/29933).
- [Sha20] Shao M., Zhou Z., Bin G., Bai Y., Wu S. A Wearable Electrocardiogram Telemonitoring System for Atrial Fibrillation Detection // Sensors. 2020. Vol. 20. P. 606. DOI: [10.3390/s20030606](https://doi.org/10.3390/s20030606).
- [Smi18] Smisek R., Hejc J., Ronzhina M., Nemcova A., Marsanova L., Kolarova J., Smial L., Vitek M. Multi-stage SVM approach for cardiac arrhythmias detection in short single-lead ECG recorded by a wearable device // Physiol. Meas. 2018. Vol. 39. P. 094003. DOI: [10.1088/1361-6579/aad9e7](https://doi.org/10.1088/1361-6579/aad9e7).
- [Tan20] Tang X., Ma Z., Hu Q., Tang W. A Real-Time Arrhythmia Heartbeats Classification Algorithm Using Parallel Delta Modulations and Rotated Linear-Kernel Support Vector Machines // IEEE Trans. Biomed. Eng. 2020. Vol. 67. Pp. 978–986. DOI: [10.1109/TBME.2019.2926104](https://doi.org/10.1109/TBME.2019.2926104).
- [YuJ21] Yu J., Wang X., Chen X., Guo J. Automatic Premature Ventricular Contraction Detection Using Deep Metric Learning and KNN // Biosensors. 2021. Vol. 11. P. 69. DOI: [10.3390/bios11030069](https://doi.org/10.3390/bios11030069).
- [Zha20] Zhang H., Dong Z., Gao J., Lu P., Wang Z. Automatic screening method for atrial fibrillation based on lossy compression of the electrocardiogram signal // Physiol. Meas. 2020. Vol. 41. P. 075005. DOI: [10.1088/1361-6579/ab979f](https://doi.org/10.1088/1361-6579/ab979f).
- [Zha21] Zhang P., Ma C., Sun Y., Fan G., Song F., Feng Y., Zhang G. Global hybrid multi-scale convolutional network for accurate and robust detection of atrial fibrillation using single-lead ECG recordings // Comput. Biol. Med. 2021. Vol. 139. P. 104880. DOI: [10.1016/j.combiomed.2021.104880](https://doi.org/10.1016/j.combiomed.2021.104880).
- [Zha22] Zhang Y., Liu S., He Z., Zhang Y., Wang C. A CNN Model for Cardiac Arrhythmias Classification Based on Individual ECG Signals // Cardiovasc. Eng. Technol. 2022. Vol. 13. Pp. 548–557. DOI: [10.1007/s13239-021-00599-8](https://doi.org/10.1007/s13239-021-00599-8).
- [Zip98] Zipes D. P., Wellens H. J. J. Sudden Cardiac Death // Circulation. 1998. Vol. 98. Pp. 2334–2351.
- [Бык13] Быкова О. Н., Гузеева О. В. Факторы риска и профилактика ишемического инсульта // Вестник Российской военно-медицинской академии. 2013. № 4 (44). С. 46–48. EDN: [RPTIHN](#). [[Bykova O. N., Guzeva O. V. "Risk factors and prevention of ischemic stroke" // Bulletin of the Russian Military Medical Academy. 2013. No. 4 (44). Pp. 46–48. EDN: [RPTIHN](#). (In Russian).]]
- [Губ21] Губкин С.В., Лемешко Е.В., Васюкевич С.Н., Жогаль К.Н., Кохан С.Б., Рубахова В.М. Портативные медицинские устройства длительного мониторирования показателей состояния здоровья пациента // Новости медико-биологических наук. 2021. Т. 21. № 3. С. 188–196. EDN: [FQIXDG](#). [[Gubkin S.V., Lemeshko E.V., Vasyukovich S.N., Zhogal K.N., Kokhan S.B., Rubakhova V.M. "Portable medical devices for long-term monitoring of patient health indicators" // News of medical and biological sciences. 2021. Vol. 21. No. 3. Pp. 188–196. EDN: [FQIXDG](#). (In Russian).]]
- [Ели23] Елизарова А. В., Сайтова Г. А., Момзиков Н. В. Выбор архитектуры нейронной сети для прогнозирования состояния заряда аккумулятора // СИИТ. 2023. Т. 5, № 4(13). С. 123–131. DOI: [10.54708/2658-5014-SIT-2023-no4-p123](https://doi.org/10.54708/2658-5014-SIT-2023-no4-p123). EDN: [RXSDIA](#). [[Elizarova A. V., Saitova G. A., Momzikov N. V. Selecting a neural network architecture for predicting the battery charge state // SIIT. 2023. Vol. 5, No. 4(13). P. 123-131. (In Russian).]]
- [Кас20] Кастей Р. М., Дюсембеков Е. К., Зетов А. Ш. и др. Эпидемиологические аспекты и факторы развития острых нарушений мозгового кровообращения (литературный обзор) // Вестник Казахского национального медицинского университета. 2020. № 2-1. С. 591–596. EDN: [AAAPSO](#).
- [Max23] Махмутов А. Р., Вульфин А. М., Миронов К. В. Исследование возможностей автономной работы конечных устройств интернета вещей // СИИТ. 2023. Т. 5, № 1(10). С. 41–47. DOI: [10.54708/2658-5014-SIT-2023-no1-p41](https://doi.org/10.54708/2658-5014-SIT-2023-no1-p41). EDN: [DPEMFA](#). [[Makhmutov A. R., Vulfin A. M., Mironov K. V. Study of the capabilities of autonomous operation of end devices of the Internet of Things // SIIT. 2023. Vol. 5, No. 1(10). P. 41–47. (In Russian).]]
- [Тур18] Туровинина Е. Ф., Лебедев Д. И., Агафонова М. А., Барсукова Л. Л. Эпидемиологические аспекты и технологии вторичной профилактики у пациентов, перенесших ишемический инсульт // Медицинский альманах. 2018. № 4 (55). С. 119–122. DOI: [10.21145/2499-9954-2018-4-119-122](https://doi.org/10.21145/2499-9954-2018-4-119-122). EDN: [YLKQRN](#). [[Turovinina E. F., Lebedev D. I., Agafonova M. A., Barsukova L. L. "Epidemiological aspects and technologies of secondary prevention in patients who have suffered ischemic stroke" // Medical Almanac. 2018. No. 4 (55). P. 119–122. DOI: [10.21145/2499-9954-2018-4-119-122](https://doi.org/10.21145/2499-9954-2018-4-119-122). EDN: [YLKQRN](#). (In Russian).]]
- [Хар24] Харченко С. Б. Разработка энергоэффективных схем для носимых электронных устройств // Экономика и управление: проблемы, решения. 2024. Т. 9, № 11. С. 77–83. DOI: [10.36871/ek.up.p.r](https://doi.org/10.36871/ek.up.p.r). 2024.11.09.011. EDN: [LCDKJP](#). [[Kharchenko S. B. "Development of energy-efficient circuits for wearable electronic devices" // Economics and Management: Problems, Solutions. 2024. Vol. 9, No. 11. Pp. 77–83. DOI: [10.36871/ek.up.p.r](https://doi.org/10.36871/ek.up.p.r). 2024.11.09.011. EDN: [LCDKJP](#). (In Russian).]]

## ОБ АВТОРЕ | ABOUT THE AUTHOR

**ИРЗАЕВ Гамид Хайбулаевич**

Дагестанский государственный технический университет,  
Россия.

[irzaevgkh@dstu.ru](mailto:irzaevgkh@dstu.ru) ORCID: [0000-0001-5694-9504](https://orcid.org/0000-0001-5694-9504).

Канд. техн. наук (Моск. гос. авиац.-технол. ун-т, 1996), доц.  
Иссл. в обл. радиоэл. средств и интернета вещей.

**IRZAEV Gamid Khaibulaevich**

Dagestan State Technical University, Russia.

[irzaevgkh@dstu.ru](mailto:irzaevgkh@dstu.ru) ORCID: [0000-0001-5694-9504](https://orcid.org/0000-0001-5694-9504).

Cand. Techn. Sci. (Moscow State Aviat. Technol. Univ., 1996),  
Ass. Prof. Research in the field of radio-electronic equipment and  
the Internet of Things.

**МЕТАДАННЫЕ | METADATA**

**Заглавие:** Проблемы внедрения алгоритмов машинного обучения в интеллектуальные носимые медицинские устройства мониторинга.

**Авторы:** Ирзаев Г. Х.

**Аннотация:** Проведена классификация носимых медицинских устройств для мониторинга состояния пациентов. Подчеркнуты особенности использования алгоритмов машинного обучения для носимых устройств в целях диагностики заболеваний, фиксации приступов, обнаружения аритмии, падений, стресса, распознавания физической и эмоциональной активности, назначения реабилитации. Рассмотрены методы машинного обучения в частном случае применения носимого устройства для наблюдения сердечной аритмии пациента. Проведен анализ исследований, в которых в качестве алгоритмов машинного обучения использовались метод опорных векторов и метод случайного леса для классификации аритмии. Рассмотрены работы, в которых используются подходы глубокого обучения для неструктурированных данных, в частности, архитектура сверточной нейронной сети для классификации аритмии и фибрилляции предсердий. Выявлены проблемы и ограничения использования машинного обучения в носимых устройствах. Предложены оптимальные решения проблем, связанных с надежностью и доступностью данных, выбором модели машинного обучения, безопасностью и конфиденциальностью данных пациентов, энергопотреблением и ограниченными объемами памяти носимых устройств.

**Ключевые слова:** Носимое медицинское устройство; машинное обучение; искусственный интеллект; мониторинг аритмии; электрокардиограмма; метод опорных векторов; сверточная нейронная сеть; метод случайного леса.

**Язык:** Русский.

Статья поступила в редакцию 23 ноября 2025 г.

**Title:** Challenges of implementing machine learning algorithms in intelligent wearable medical monitoring devices.

**Authors:** Irzaev G. Kh.

**Abstract:** A classification of wearable medical devices for patient monitoring is presented. The article highlights the specific applications of machine learning algorithms for wearable devices for diagnosing diseases, recording seizures, detecting arrhythmia, falls, and stress, recognizing physical and emotional activity, and prescribing rehabilitation. Machine learning methods are considered in the specific case of using a wearable device to monitor a patient's cardiac arrhythmia. An analysis of studies using support vector machines and random forests for arrhythmia classification is conducted. Works that utilize deep learning approaches for unstructured data are considered, in particular, a convolutional neural network architecture for classifying arrhythmia and atrial fibrillation. The problems and limitations of using machine learning in wearable devices are identified. Optimal solutions are proposed for problems related to data reliability and availability, machine learning model selection, patient data security and privacy, power consumption, and limited memory capacity of wearable devices.

**Key words:** wearable medical device; machine learning; artificial intelligence; arrhythmia monitoring; electrocardiogram; support vector machine; convolutional neural network; random forest method.

**Language:** Russian.

The article was received by the editors on 23 November 2025.