

КОМПЬЮТЕРНЫЕ СИСТЕМЫ И ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ COMPUTER SCIENCE

doi: 10.17586/2226-1494-2025-25-5-833-843

УДК 004.89

Классификация двигательной активности человека на основе анализа мультисенсорных данных

Артём Дмитриевич Обухов✉

Тамбовский государственный технический университет, Тамбов, 392000, Российская Федерация
obuhov.art@gmail.com✉, <https://orcid.org/0000-0002-3450-5213>

Аннотация

Введение. Выполнен анализ мультисенсорных данных, полученных от электромиографа, инерциальных измерительных устройств, системы компьютерного зрения и трекеров виртуальной реальности, для решения задачи классификации двигательной активности человека. Актуальность решения данной задачи обусловлена необходимостью анализа и распознавания двигательной активности человека при использовании различных программно-аппаратных комплексов, например, реабилитационных и тренажерных систем. Для оптимального решения задачи распознавания типа движений рук с наибольшей точностью оценивается вклад каждого источника сигналов, а также выполняется сравнение различных моделей машинного обучения. **Метод.** Подход к обработке мультисенсорных данных включает синхронизированный сбор потоков от различных источников, разметку исходных данных, фильтрацию сигналов; двойное выравнивание временных рядов по частоте и длительности с аппроксимацией до общей константы, формирование общего набора данных, обучение и выбор модели машинного обучения для распознавания двигательной активности рук. Рассматриваются девять моделей машинного обучения: логистическая регрессия, k -ближайших соседей, наивный байесовский классификатор, дерево решений и ансамбли на их основе (случайный лес, AdaBoost, Extreme Gradient Boosting, Voting и Stacking Classifier). Разработанный подход синхронизации, фильтрации и двойного выравнивания потоков данных позволяет сформировать унифицированный набор данных мультисенсорных данных для обучения моделей. **Основные результаты.** Проведен эксперимент по классификации девяти категорий движений рук на основе анализа мультисенсорных данных (собрано 629 записей от 15 участников). Обучение выполнялось на 80 % собранных данных с пятикратной перекрестной проверкой. Показано, что ансамбль AdaBoost обеспечивает точность классификации 98,8 % на наборе данных из объединенных от четырех различных источников информации. В ходе абляционного анализа для сравнения источников данных, наибольшее влияние на итоговую точность классификации оказывает информация от трекеров виртуальной реальности (до $98,73 \pm 1,78$ % точности на модели AdaBoost), данные о мышечной активности от электромиографа являются наименее информативными. Определено, что высокая точность классификации двигательной активности может быть получена с использованием инерциальных измерительных устройств. **Обсуждение.** Исследование формализует воспроизводимый подход к обработке мультисенсорных данных и позволяет объективно сравнить вклад различных источников информации и моделей машинного обучения при решении задачи классификации двигательной активности рук пользователя в рамках реабилитационных и виртуальных тренажерных систем. Показано, что при ограничениях по ресурсам возможно отказаться от части источников данных без существенной потери точности классификации, упростив аппаратную конфигурацию систем отслеживания, перейти от закрытых коммерческих систем (трекеров виртуальной реальности) к более доступным и компактным инерциальным измерительным устройствам.

Ключевые слова

классификация движений человека, двигательная активность, машинное обучение, анализ мультисенсорных данных

Благодарности

Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации в рамках проекта «Разработка иммерсивной системы взаимодействия с виртуальной реальностью для профессиональной подготовки на основе всенаправленной платформы» (124102100628-3).

Ссылка для цитирования: Обухов А.Д. Классификация двигательной активности человека на основе анализа мультисенсорных данных // Научно-технический вестник информационных технологий, механики и оптики. 2025. Т. 25, № 5. С. 833–843. doi: 10.17586/2226-1494-2025-25-5-833-843

Classification of human motor activity based on multisensory data analysis

Artem D. Obukhov✉

Tambov State Technical University, Tambov, 392000, Russian Federation

obuhov.art@gmail.com✉, <https://orcid.org/0000-0002-3450-5213>

Abstract

An analysis of multisensor data obtained from an electromyograph, inertial measurement devices, a computer-vision system, and virtual-reality trackers was performed in order to solve the problem of classifying human motor activity. The relevance of solving this problem is determined by the necessity of analyzing and recognizing human motor activity when using various hardware and software complexes, for example, rehabilitation and training systems. For the optimal solution of the task of recognizing the type of hand movements with the highest accuracy, the contribution of each signal source is evaluated, and a comparison of various machine-learning models is performed. The approach to processing multisensor data includes: synchronized acquisition of streams from different sources; labeling of the initial data; signal filtering; dual alignment of time series by frequency and duration with approximation to a common constant; formation of a common dataset; training and selection of a machine-learning model for recognizing motor activity of the hands. Nine machine-learning models are considered: logistic regression, k -nearest neighbors, naïve Bayes classifier, decision tree, and ensembles based on them (Random Forest, AdaBoost, Extreme Gradient Boosting, Voting, and Stacking Classifier). The developed approach of synchronization, filtering, and dual alignment of data streams makes it possible to form a unified dataset of multisensor data for model training. An experiment was carried out on the classification of nine categories of hand movements based on the analysis of multisensor data (629 recordings collected from 15 participants). Training was performed on 80 % of the collected data with five-fold cross-validation. The AdaBoost ensemble provides a classification accuracy of 98.8 % on the dataset composed of the combined information from four different sources. In the course of ablation analysis for comparing the data sources, the greatest influence on the final classification accuracy is exerted by information from virtual-reality trackers (up to 98.73 % $\pm$ 1.78 % accuracy on the AdaBoost model), while data on muscle activity from the electromyograph turned out to be the least informative. It was determined that high classification accuracy of motor activity can be obtained using inertial measurement devices. The considered study formalizes a reproducible approach to processing multisensor data and makes it possible to objectively compare the contribution of different sources of information and machine-learning models in solving the problem of classifying the motor activity of the user's hands within rehabilitation and virtual training systems. It is shown that under resource limitations it is possible to refuse part of the data sources without significant loss of classification accuracy, simplifying the hardware configuration of tracking systems and making it possible to move from closed commercial systems (virtual-reality trackers) to more accessible and compact inertial measurement devices.

Keywords

classification of human movements, motor activity, machine learning, multisensory data analysis

Acknowledgements

The work was carried out with the financial support of the Ministry of Science and Higher Education of the Russian Federation within the framework of the project “Development of an immersive virtual reality interaction system for vocational training based on an omnidirectional platform” (124102100628-3).

For citation: Obukhov A.D. Classification of human motor activity based on multisensory data analysis. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2025, vol. 25, no. 5, pp. 833–843 (in Russian). doi: 10.17586/2226-1494-2025-25-5-833-843

Введение

Создание передовых реабилитационных и тренажерных комплексов, объединяющих технологии виртуальной реальности и дополнительное имитационное или нагрузочное оборудование, невозможно без комплексного анализа данных о процессе двигательной активности пользователя. Это, с одной стороны, может использоваться для анализа паттернов его поведения и качества выполнения упражнений [1], с другой стороны применяться для последующего формирования его цифровой копии (аватара) с высокой степенью реалистичности [2].

Для осуществления комплексного анализа двигательной активности пользователя подобного рода программно-аппаратных комплексов необходимо ориентироваться на мультисенсорный подход, т. е. объединять

данные от нескольких независимых источников. Среди основных типов систем отслеживания двигательной активности стоит выделить электромиографические (Electromyography, EMG) датчики, системы инерциальной навигации (Inertial Measurement Unit, IMU) и системы компьютерного зрения (Computer Vision, CV) [3]. Необходимость комплексного подхода обусловлена тем, что каждая из систем отслеживания имеет свои сильные и слабые стороны, а также ограничения [1].

Специализированные трекеры для виртуальной реальности (Virtual Reality, VR) для абсолютного позиционирования требуют дополнительного оборудования в виде базовых станций. С другой стороны, IMU, к которым относятся различные устройства на основе акселерометров и гироскопов, включая коммерческие (Kat Loco S), позволяют осуществлять относительное позиционирование и поворот в пространстве [4]. IMU

также достаточно легко реализуются на базе широко распространенных датчиков, например, MPU-9250 [5]. Их интеграция в ESP32 позволяет создавать легкие, беспроводные носимые устройства без ограничений по количеству датчиков, их расположению, а также с возможностью самостоятельно реализовывать программную логику обработки данных [6]. Ключевой проблемой данного типа систем отслеживания является накопление ошибки интегрирования при расчете скорости движения акселерометра и, тем более, перемещения датчика. Тем не менее, IMU могут достаточно точно определять углы поворотов и направление движения, что может быть использовано при анализе двигательной активности человека.

При анализе двигательной активности большое значение имеет информация о состоянии мышечной системы человека, что можно получить путем обработки данных от датчиков EMG. EMG — широко используемый метод измерения мышечной активности путем обнаружения электрических сигналов, генерируемых мышечными сокращениями [7]. Датчики EMG могут быть прикреплены к поверхности кожи или внедрены в мышечную ткань. Поверхностные датчики EMG неинвазивны и просты в использовании, что делает их популярным выбором для отслеживания мышечной активности в различных областях применения. При использовании EMG необходимо учитывать, что данный тип датчиков очень чувствителен и подвержен помехам, в том числе, при значительной двигательной активности.

С развитием технологий CV значительное внимание уделяется методам Human Pose Estimation, позволяющим с высокой точностью определять положение ключевых точек скелета человека [8]. Современные решения, такие как MediaPipe Pose, YOLO, Movenet, OpenPose и другие, используют глубокие нейронные сети для построения скелетных моделей, что обеспечивает возможность построения трехмерных цифровых копий тела для взаимодействия с виртуальным пространством. Однако эффективность данных методов существенно зависит от качества изображений, разрешения камеры и условий освещения, что ограничивает их применение в сценариях с интенсивной динамикой или при слабом освещении. Кроме того, нужно учитывать, что активное перемещение или повороты могут сделать часть сегментов тела недоступными для камеры, что приводит к искажениям при реконструкции модели тела. Наконец, CV испытывает проблемы при определении дальности до объектов (координата Z), что частично решается стереокамерами и камерами с датчиками глубины, но точность и стоимость данных решений далеки от оптимальных.

Учитывая перечисленные проблемы, для отслеживания двигательной активности человека и ее последующего анализа (например, с использованием алгоритмов машинного обучения) необходимо объединение и обработка больших объемов данных от различных систем отслеживания. Интеграция различных методов отслеживания и мониторинга физиологических параметров позволит получить комплексный набор информации о движениях пользователя.

Эффективность применения технологий машинного обучения для решения задачи анализа и классификации двигательной активности подтверждается многочисленными исследованиями [9]. Технологии машинного обучения позволяют достаточно точно распознавать различные паттерны движений, например, при анализе походки человека на основе датчиков IMU [10], классификации различных движений [11], в том числе, при комбинации EMG и IMU [12]. В работе [13] рассмотрена задача классификации движений рук для определения статических и динамических жестов, в качестве исходных данных также выступают IMU и EMG. Итоговые результаты по точности классификации варьировались от 93 до 99 %, точность распознавания жеста от 56–70 % (для IMU) до 88–90 % (для EMG). Результаты, полученные в [13], подтвердили высокие перспективы использования машинного обучения в задачах классификации движений рук и оправданность мультисенсорного подхода для решения подобных задач. Проведенный анализ показывает возможность решения задачи классификации двигательной активности человека с использованием технологий машинного обучения. В настоящей работе, кроме анализа данных EMG и IMU, выполнено исследование эффективности мультисенсорного подхода и добавлена в качестве дополнительного источника система CV и трекары виртуальной реальности для расширения исходного набора данных.

Предмет исследования

В представленной работе решается задача автоматической классификации двигательной активности человека на основе совмещенного анализа мультисенсорных данных. Цель исследования — разработать методику распознавания типов движений рук с использованием совокупности разнородных сигналов (EMG, IMU, CV и VR-трекары) и оценить вклад каждого из этих источников в точность классификации. Для достижения этой цели будет сформирован набор данных, включающий синхронизированные записи от выбранных четырех типов сенсоров, собранные при выполнении пользователями различных движений верхних конечностей. Проведено обучение и сравнение нескольких моделей машинного обучения (как базовых алгоритмов, так и ансамблевых методов) по распознаванию девяти типовых движений рук на данном объединенном наборе данных. Основными задачами работы являются: количественно оценить эффективность каждого типа системы отслеживания в составе мультисенсорных данных (т. е. определить информативность сигналов EMG, IMU, CV и VR для решения задачи классификации); выявить модель машинного обучения, обеспечивающую наибольшую точность распознавания движений.

Первые предложен и применен оригинального подход к предварительной обработке и анализу мультисенсорных временных рядов для классификации движений, где данные различных источников имеют разную частоту дискретизации и размерность. Выполнено двойное выравнивание временных рядов по частоте

дискретизации и по длительности сигналов, что обеспечивает точную синхронизацию разнородных потоков данных без потери информативности. Кроме того, впервые комплексно объединены данные сразу четырех различных типов датчиков (IMU, ЭМГ, CV и VR-трекеры) для решения задачи распознавания движений. Проведен абляционный анализ влияния каждого из каналов сигналов на качество классификации, что позволяет оценить наиболее значимые источники данных для распознавания двигательной активности.

Подход к обработке мультисенсорных данных для решения задачи классификации двигательной активности

Рассмотрим основные этапы обработки мультисенсорных данных (рисунок).

Этап 1. Процедуры по теоретической подготовке (формализация процессов обработки данных, разработка архитектур моделей машинного обучения, выбор метрик оценки моделей).

Этап 2. Эксперименты, направленные на сравнение моделей машинного обучения и достижение поставленной цели в виде решения задачи классификации двигательной активности на основе обработанных мультисенсорных данных.

На этапе 1 осуществляется формализация процесса сбора мультисенсорных данных. К объектам относятся компоненты мультисенсорной системы, отслеживающей состояние человека: EMG, IMU, система CV и VR. В совокупности они формируют входные и выходные данные для последующего обучения моделей машинного обучения. Однако перед формированием набора данных должна быть выполнена предваритель-

ная подготовка данных, которая включает следующие процедуры.

Процедура 1. Синхронизация потоков данных из различных источников в единое множество с учетом временных меток.

Процедура 2. Разделение множества информации на временные отрезки (диапазоны) путем автоматической или ручной разметки (посредством анализа собранных видеоданных о выполняемых действиях и выбором интервала, где выполняется определенное действие).

Процедура 3. Предобработка данных с использованием соответствующих фильтров.

Этап 1 наиболее актуален для данных от IMU, где выполняются дополнительные преобразования для удаления высокочастотного шума и дрейфа базовой линии.

После завершения этапа 1 формируется итоговое множество входных и выходных данных. Предполагается, что в качестве входных данных выступают мультисенсорные данные от IMU, EMG, CV и VR-трекеров. Выходными данными являются типы (категории) движений пользователя.

Далее осуществляется решение задачи классификации двигательной активности рук пользователя по нескольким категориям на основе анализа входных данных. Наибольший интерес представляет исследование влияния выбранных источников на точность классификации движений.

На этапе 2 выполняется проведение экспериментальных исследований. Для их успешного завершения необходима разработка нескольких альтернативных архитектур моделей машинного обучения, что позволит осуществить объективное сравнение различных подходов и их эффективность в контексте решаемых задач.



Рисунок. Структура обработки мультисенсорных данных
Figure. Multisensory data processing framework

В результате, после необходимой подготовки, осуществляется сбор данных, его подготовка в соответствии с процедурами 1–3, формирование набора данных, обучение и сравнение моделей. Модели с наилучшими показателями будут использованы в различных программно-аппаратных комплексах для мониторинга и классификации двигательной активности пользователя.

В соответствии с предложенным подходом проведем формализацию процесса сбора и обработки мультисенсорных данных.

Пусть исходные данные поступают от некоторой мультисенсорной системы сбора информации, объединяющей совокупность сенсоров:

$$S = \{s_{EMG}, s_{IMU}, s_{CV}, s_{VR}\},$$

где s_{EMG} — поверхностные EMG-датчики для регистрации электрической активности мышц; s_{IMU} — инерциальные датчики (акселерометры и гироскопы) для измерения ускорений и угловых скоростей; s_{CV} — метод CV для регистрации положения пальцев и ладони; s_{VR} — VR-трекеры для высокоточного отслеживания положения руки.

Пусть P — множество пользователей, где $p \in P$ — конкретный пользователь. Данные от всех сенсоров обозначим как B . Между множествами S и B задано соответствие, так, что есть $s \in S$, соответствующий определенному $b \in B$.

Зададим некоторую функцию $\phi: P \times S \rightarrow B$, которая описывает процесс сбора данных от пользователя с помощью сенсоров. Для каждого $p \in P$ и набора датчиков S сбор данных будет иметь вид: $B_p = \{b_{p,i} = \phi(p, s_i)\}$, $\forall s_i \in S$. После формирования сигнал $b_{p,i}(t)$ передается датчиком s_i в модуль обработки для получения исходных («сырых») данных: $r_{p,i} = \phi(b_{p,i}, s_i)$. Функция передачи данных ϕ осуществляет следующее отображение $\phi: B \times S \rightarrow R$, где R — множество «сырых» данных в модуле обработки.

Выполним обработку полученных данных R . Обозначим через $\gamma: R \times A \rightarrow E$ функцию, осуществляющую преобразование исходных данных R в обработанные E с использованием множества алгоритмов A . Для конкретных данных получим: $e_{p,i} = \gamma(r_{p,i}, a)$. Форма функции γ и используемый алгоритм $a \in A$ зависят от характеристик исходного сигнала и, следовательно, источника данных (сенсора).

В процессе обработки выполняется несколько важных процедур.

Процедура 4. Синхронизация данных для устранения $\tau_i (\forall s_i \in S)$ для всех сенсоров путем синхронизации начальных временных меток в выборках от разных сенсоров в рамках каждой сессии записи (перед началом сессии проводится калибровка положения датчиков и фиксация единого времени отсчета).

Процедура 5. Применение фильтров для снижения шумов (для IMU используется комбинация из фильтра Калмана и ориентационного фильтра Маджевика, показавшего свою высокую эффективность, для остальных источников фильтры или процедуры преобразования применяются при необходимости).

В результате произведенных преобразований получим множество обработанных данных E , среди которых заданы соответствующие выбранным сенсорам подмножества: $E = \{E_{EMG}, E_{IMU}, E_{CV}, E_{VR}\}$.

Для каждого источника данных задана постоянная частота записи, которую можно обозначить через множество $FPS = \{v_{EMG} = 250, v_{IMU} = 80, v_{CV} = 30, v_{VR} = 65\}$ (Frames Per Second, FPS), где каждый элемент принимает целые значения в герцах.

Выполним несколько преобразований для подготовки исходных данных для обучения моделей. Необходимо сохранить исходные данные после их разметки по категориям действий. Очевидно, что количество записей в каждом замере в каждом источнике значительно варьируется и напрямую зависит от частоты записи данных и длины размеченного интервала. Все это может затруднить подготовку и обучение моделей машинного обучения. Для решения данной проблемы предлагается выравнивание размерности входных данных под единую длину с учетом наибольшей частоты среди всех источников путем аппроксимации. Данный подход приведет к тому, что все данные будут представлены в виде матриц с одинаковой частотой v_{all} (эта частота будет соответствовать наибольшей и равна v_{EMG}). Недостаток данного подхода заключается в том, что объем данных будет значительно увеличен (например, для CV — до 8,3 раз). С другой стороны имеются следующие преимущества подхода: все данные синхронизированы между собой, что позволяет сравнивать равные по индексам замеры полученные от разных источников (это может использоваться в решении задачи прогнозирования уточненных значений); все данные текущего замера могут быть объединены в единую матрицу размерностью $N_{all,j} \times M_{all}$, где количество записей $N_{all,j}$ соответствует наибольшему количеству записей от источника в текущем замере, а количество столбцов M_{all} — суммарному количеству признаков от всех источников S .

Однако выполнение выравнивания в рамках замера недостаточно, так как каждый замер имеет свое значение $N_{all,j}$, которое может значительно отличаться. Данный аспект затруднит использование таких временных рядов различной длины при обучении модели, поэтому предлагается дополнительно осуществить общее выравнивание всех данных по следующей процедуре. Введем константу времени T_{all} , одинаковую для оценки всех действий. Предлагается руководствоваться правилом, что значение T_{all} превышает 95 % времени всех замеренных упражнений. Тогда осуществим выравнивание всех замеров к данной константе: $T_j \rightarrow T_{all}$, что приведет к изменению длины замера от $N_{all,j}$ к $N_{all} = v_{all} T_{all}$, которое будет одинаковым для всех замеров. Соответствующие данные будут аппроксимированы в сторону растяжения или сжатия длины временного ряда.

Таким образом, входные данные для обучения моделей получены на основе исходных массивов данных от каждого источника $E = \{E_{EMG}, E_{IMU}, E_{CV}, E_{VR}\}$ и представляют собой массив объединенных данных X от всех источников после второго выравнивающего преобразования (в рамках всего набора данных).

В качестве выходных данных выступают $Y = \{Y_{Kj} \in \mathbb{N}\}_{j=1 \dots J}$ — идентификаторы категории действий пользователя, заданные для каждого замера.

Тогда для решения поставленной задачи необходимо найти такую модель Machine Learning (ML), обеспечивающую наибольшую точность классификации:

$$ML: X \rightarrow Y.$$

Выбор моделей машинного обучения для решения задачи классификации

С учетом проведенного обзора существующих исследований в области применения различных моделей машинного обучения для классификации двигательной активности, а также опыта коллектива в применении различных моделей при решении задач классификации был выполнен отбор набора моделей [14, 15]. Выбор гиперпараметров моделей производился путем либо аналитически на основе предыдущего опыта, либо с использованием метода GridSearchCV для поиска оптимальной глубины деревьев (для тех моделей, где они используются). Для линейных и прочих моделей использовались параметры по умолчанию, если не указано иного. Получен следующий перечень моделей машинного обучения.

1. Logistic Regression. Линейная модель, использующая логистическую функцию для расчета вероятности принадлежности объекта к заданному классу. Используется с параметрами по умолчанию.
2. Nearest Neighbors Classification. Метод классификации, основанный на поиске ближайших соседей в пространстве признаков. В качестве количества соседей выбрано значение 5.
3. Decision Tree Classifier. Дерево решений, используемое для классификации. В качестве параметра глубины дерева выбрано значение 10.
4. Random Forest Classifier. Ансамбль деревьев решений с ограниченной глубиной деревьев (модель 3) и количеством деревьев равным 10. Объединяя прогнозы нескольких слабых моделей, метод снижает дисперсию и повышает устойчивость к шуму.
5. AdaBoost Classifier. Метод бустинга, который итеративно обучает 50 слабых классификаторов с использованием алгоритма SAMME. Каждый новый классификатор фокусируется на ошибках предыдущих, а итоговое решение получается посредством взвешенного голосования.
6. Gaussian Naïve Bayes. Наивный байесовский классификатор, предполагающий независимость признаков и использующий нормальное распределение для оценки вероятностей. Используются параметры по умолчанию.
7. XGBClassifier. Градиентный бустинг, применяемый для классификации. В качестве основных параметров выбраны $n_estimators=50$ и $max_depth=5$.
8. Stacking Classifier. Ансамблевая модель, объединяющая прогнозы нескольких базовых классификаторов (Logistic Regression, ближайших соседей, двух вариантов Decision Tree с глубиной 5 и 10). Финальный мета-классификатор (Logistic Regression) объединя-

ет прогнозы классификаторов для получения итогового решения.

9. Voting Classifier. Ансамблевая модель, которая объединяет прогнозы базовых моделей посредством «soft voting». Итоговая вероятность для каждого класса вычисляется как средневзвешенное значение вероятностей, предсказанных базовыми моделями. Используется перечень моделей, аналогичный представленному в п. 8.

Процесс распознавания типа движения является задачей многоклассовой классификации на конечном множестве движений. Определим множество классов возможных движений как C , $\{Y_{Kj} \in C\}_{j=1 \dots J}$. Мерой качества решения задачи многоклассовой классификации могут выступать следующие оценки [16, 17]:

- кроссэнтропийная потеря, используемая в качестве функции потерь при обучении нейронных сетей:

$$H(y, \hat{y}) = - \sum_{i=1}^N \sum_{j=1}^C y_{ij} \ln(\hat{y}_{ij}),$$

где N — количество примеров в тестовой выборке; C — количество классов; y_{ij} — истинная метка класса j для примера i ; $\hat{y}_{ij}$ — предсказанная вероятность принадлежности примера i к классу j ;

- точность классификации (доля правильно предсказанных классов):

$$\text{Accuracy} = \frac{\sum_{i=1}^N 1(\hat{y}_i = y_i)}{N},$$

где $1(\hat{y}_i = y_i)$ — индикаторная функция (равна 1, если предсказание совпадает с истинным классом, иначе 0);

- средняя Precision:

$$\text{Precision} = \frac{1}{C} \sum_{k=1}^C \text{Precision}_k,$$

$$\text{Precision}_k = \frac{\text{TP}_k}{\text{TP}_k + \text{FP}_k},$$

где TP_k (True Positives) — число объектов, правильно определенных в класс k ; FP_k (False Positives) — число объектов, ошибочно отнесенных к классу k ;

- средняя Recall:

$$\text{Recall} = \frac{1}{C} \sum_{k=1}^C \text{Recall}_k,$$

$$\text{Recall}_k = \frac{\text{TP}_k}{\text{TP}_k + \text{FN}_k},$$

где FN_k (False Negatives) — число объектов класса k , ошибочно отнесенных к другим классам;

- F1-score (гармоническое среднее Precision и Recall):

$$F1 = \frac{1}{C} \sum_{k=1}^C F1_k,$$

$$F1_k = \frac{2 \text{Precision}_k \text{Recall}_k}{\text{Precision}_k + \text{Recall}_k}.$$

Соответственно, в качестве элементов тестовых выборок будут выступать элементы множества Y , не

участвовавшие в процессе обучения моделей. Также в ходе оценки моделей машинного обучения при решении задачи классификации большой интерес имеет важность признаков с целью выявления наиболее информативных составляющих мультисенсорных данных. Это может быть реализовано в процессе абляционного анализа: модели сравниваются на наборах данных с отдельными видами сенсоров (EMG, IMU, CV, VR). Такой анализ позволит количественно оценить, насколько наличие каждого типа сигнала влияет на итоговую точность классификации.

Результаты экспериментальных исследований

В рамках эксперимента были собраны данные о двигательной активности рук с использованием мультисенсорной системы, включающей EMG-датчики, IMU, VR-трекеры, систему CV. Эксперимент состоял из следующих этапов.

Этап 1. Подготовка программного обеспечения для синхронной записи данных.

Этап 2. Подготовка оборудования и калибровка датчиков.

Этап 3. Сбор данных. Участники выполняли набор заданных движений, представленный в табл. 1, включающий сгибание/разгибание локтя, круговые движения кисти, а также перемещения вдоль различных осей. Каждое движение повторялось несколько раз для получения достаточного объема данных.

Этап 4. Разметка данных. Для разметки данных использовалось разработанное программное обеспечение, которое позволяет создавать сессии для записи отдельных упражнений, визуально отслеживать по видео записанные движения и записывать время начала и окончания движения для последующего извлечения данных. При разметке осуществляется синхронное извлечение данных ото всех источников с учетом времени начала и окончания, выбранного сотрудником, отвечающим за разметку. Каждый фрагмент сохраняется отдельным файлом в формате csv.

Этап 5. Обработка сигналов. Проводится необходимая фильтрация шумов с применением полосовых фильтров, после чего формируется единая, синхронизированная выборка из источников, приходящих с разной частотой и в разных форматах. Этап 5 включает совмещение всех данных на единой временной шкале, которая затем растягивается до фиксированного времени в 5 с (наиболее распространенная длина движения), что позволяет получить единообразную размерность для всех записей в 1200 строк, которые затем поступают на вход моделей.

Этап 6. Обучение моделей. На основе выделенных признаков и синхронизированных данных были обучены девять моделей для решения задачи классификации. Этап 6 включает исследование абляции моделей классификации с целью выделения влияния отдельных источников данных на точность решения задачи.

В результате проведенного эксперимента с привлечением 15 участников собрано 629 записей, распределение упражнений представлено в табл. 1, размерность каждой записи составляет 1200 строк с 78 значениями. Каждой записи соответствует размеченная категория. Обучение моделей машинного обучения проводилось на 80 % полученных данных, оставшиеся 20 % использовались для перекрестной пятикратной проверки.

На этапе 1 проведено обучение моделей на полном наборе данных. Результаты обучения представлены в табл. 2. Сравнение моделей проведено по метрикам точности (Accuracy), Precision, Recall, F1-score по результатам перекрестной пятикратной проверки, также отражено время одного прогноза моделью. Результаты упорядочены по убыванию средней точности.

Выполнено исследование влияния используемого источника на точность классификации. Полученные результаты представлены в табл. 3. Лучшие результаты по каждому источнику выделены полужирным. Значения Accuracy получены по результатам перекрестной пятикратной проверки.

Таблица 1. Описание категорий упражнений

Table 1. Description of exercise categories

Описание упражнения		Количество собранных записей
Сгибание и разгибание руки в локте		70
Сгибание и разгибание запястья		70
Протягивание руки перед собой		70
Разведение руки вбок и приведение обратно к груди		67
Круговые движения рукой вдоль тела		71
Движение ладони перед телом вдоль оси	<i>X</i>	64
	<i>Y</i>	79
	<i>Z</i>	75
Имитация захвата предмета вытянутой рукой и перемещение к груди		63

Таблица 2. Сравнение моделей при классификации, %

Table 2. Comparison of models in classification

Модель	Accuracy EMG	Precision	Recall	F1-score	Время, мс
AdaBoost	98,89 ± 0,39	99,01 ± 0,33	98,86 ± 0,37	98,89 ± 0,37	4,4
XGBClassifier	97,94 ± 0,81	98,06 ± 0,76	97,93 ± 0,77	97,93 ± 0,79	26,7
Voting Classifier	97,14 ± 1,29	97,36 ± 1,29	97,15 ± 1,23	97,11 ± 1,31	48,6
Stacking Classifier	96,98 ± 1,84	97,34 ± 1,60	96,99 ± 1,81	97,00 ± 1,83	48,4
Decision Tree	94,12 ± 1,28	94,54 ± 1,22	94,12 ± 1,25	94,07 ± 1,24	0,1
Gaussian Naive Bayes	89,98 ± 1,96	91,48 ± 1,18	90,04 ± 1,89	90,06 ± 1,97	4,4
Nearest Neighbors	89,83 ± 3,26	91,38 ± 2,39	90,00 ± 3,19	89,90 ± 3,33	49,1
Logistic Regression	89,04 ± 3,06	89,75 ± 2,69	89,20 ± 3,06	89,03 ± 2,97	0,1
Random Forest	79,02 ± 7,23	77,99 ± 8,06	79,10 ± 7,18	75,70 ± 8,32	15,9

Таблица 3. Исследование абляции при классификации, %

Table 3. The study of ablation in classification

Модель	EMG	IMU	CV	VR
Logistic Regression	60,89 ± 1,35	88,72 ± 3,59	93,80 ± 1,83	96,98 ± 1,27
Nearest Neighbors	83,47 ± 4,04	89,83 ± 3,26	94,92 ± 2,33	96,03 ± 2,19
Decision Tree	50,71 ± 3,96	89,83 ± 2,85	88,40 ± 4,20	92,69 ± 1,15
Random Forest	44,99 ± 1,90	67,42 ± 6,00	76,65 ± 8,65	77,75 ± 4,28
AdaBoost	72,49 ± 3,58	97,14 ± 0,39	96,19 ± 1,62	98,73 ± 1,78
Gaussian Naive Bayes	51,04 ± 4,80	76,93 ± 6,69	83,62 ± 2,10	80,76 ± 4,41
XGBClassifier	72,33 ± 3,66	96,66 ± 1,29	93,48 ± 2,26	97,14 ± 0,81
Stacking Classifier	83,15 ± 2,72	92,37 ± 2,22	95,71 ± 2,22	97,62 ± 2,07
Voting Classifier	71,54 ± 1,70	94,60 ± 2,53	95,23 ± 1,94	96,67 ± 1,69

По результатам, полученным в табл. 2 и 3, можно сделать следующие выводы. Проведенный анализ всех данных показал, что наилучшую точность демонстрирует метод AdaBoost со значением более 98,8 %. Близкие результаты показали модели XGBClassifier и Voting Classifier, однако имели более низкую производительность и точность. При исследовании абляции моделей выявлены следующие закономерности: VR-трекеры являются наиболее информативным и содержательным источником данных (за счет объединения значений абсолютных координат и поворотов), что, в итоге, позволяет получить точность до 100 % для модели AdaBoost на некоторых выборках (в среднем $98,73 \pm 1,78$ %). Учитывая специфичность данного типа источника данных (современные шлемы переходят на системы CV и отказываются от использования базовых станций), стоит обратить внимание на остальные составляющие мультисенсорного сигнала. CV и IMU показывают достаточно высокие результаты, приемлемые для многих сценариев использования. Результаты EMG в данной ситуации являются самым ненадежным и сложным источником данных, неприменимым для большинства моделей.

В результате проведенного исследования необходимо отметить, что для решения поставленной задачи классификации двигательной активности можно использовать как всю совокупность мультисенсорных

данных, так и отдельные ее составляющие (за исключением EMG). В ходе сравнения моделей предпочтение отдается ансамблям, наилучшие показатели имели такие модели как AdaBoost, XGBClassifier, Voting Classifier и Stacking Classifier. Подчеркнем, что для EMG модель Nearest Neighbors показывала высокие результаты.

Дополнительно был выполнен анализ полученных результатов с существующими исследованиями в данной области, чтобы оценить такие факторы, как используемая архитектура и источник данных. Полученные результаты сравнения представлены в табл. 4.

Проведенное сравнение показывает, что нейросетевые модели на базе LSTM, GRU, Transformer и нейросетевых архитектур могут обеспечивать высокую точность, превышающую 99 %, благодаря эффективному извлечению пространственно-временных признаков. С другой стороны, такие модели, судя по существующему опыту и работе [18], не обладают хорошей производительностью и не могут использоваться в режиме реального времени или с большой частотой вызова. Небольшое увеличение точности полностью не компенсирует значительного снижения быстродействия.

Также по сравнению с существующими исследованиями в рамках данной работы рассмотрены не два или один источник данных, а четыре, проведен абля-

Таблица 4. Сравнение точности классификации со сторонними исследованиями

Table 4. Comparison of classification accuracy with third-party studies

Источник	Источник данных	Тип модели	Точность классификации, %	Время расчета, мс
[18]	EMG + IMU	LSTM-Res	99,67	3220
[18]	EMG + IMU	GRU-Res	99,49	2820
[18]	EMG + IMU	Transformer-CNN	98,96	2450
[13]	EMG + IMU	DQN (глубокая Q-сеть)	$97,50 \pm 1,13$	33
[19]	CV (MediaPipe)	Swin Transformer	99,7	Нет данных
[20]	VR-трекеры	CNN-Transformer	100	Нет данных
Настоящая работа	EMG + IMU + CV(MediaPipe) + VR-трекеры	AdaBoost	$98,89 \pm 0,39$	4,4

ционный анализ их вклада в итоговую точность классификации. Тем не менее, рассмотренное сравнение показывает перспективность дальнейших исследований по реализации нейросетевых архитектур для решения данной задачи с учетом необходимости оптимизации данных архитектур для их высокой производительности без ущерба для точности.

Заключение

Специализированные трекеры для виртуальной реальности (Virtual Reality, VR) для абсолютного позиционирования требуют дополнительного оборудования в виде базовых

Рассмотрена задача комплексного анализа двигательной активности человека для реабилитационных и тренировочных VR-комплексов на основе мультисенсорных данных (Inertial Measurement Unit (IMU), Electromyography (EMG), компьютерное зрение и VR-трекеры). Предложен подход к обработке мультисенсорных данных, включающий двойное выравнивание временных рядов для синхронизации разнородных потоков и формирования унифицированного набора данных без потери информативности.

Эксперимент с 15 участниками и 629 размеченными записями подтвердил эффективность применения ансамблевых моделей машинного обучения. Метод AdaBoost продемонстрировал наибольшую точность и стабильность ($98,89 \pm 0,39$ %) при полном наборе сенсоров. В ходе исследования абляции наибольший вклад внесли VR-трекеры (до $98,73 \pm 1,78$ % точности при использовании AdaBoost). IMU и система компьютерного зрения обеспечили достаточную точность

(96–97 %), EMG-канал показал самую низкую информативность (83 %).

Полученные результаты количественно доказали преимущества мультисенсорного подхода, так как собранные данные в дальнейшем могут быть обработаны для получения наибольшей точности. Однако необходимо учитывать, что некоторые источники данных могут снижать общую точность (как в случае информации о мышечной активности, полученной в ходе EMG). Практическая значимость работы заключается в том, что для массовых и ресурсо-ограниченных решений достаточно комбинации IMU и компьютерного зрения, так как в ряде случаев добавление VR-трекеров невозможно. Использование только одного EMG целесообразно в узкоспециализированных сценариях, ориентированных только на оценку мышечной активности.

Таким образом, разработанный подход и обученные модели могут быть использованы в рамках реабилитационных и профессиональных виртуальных тренажеров и комплексов для распознавания типов двигательной активности пользователя, а в дальнейшем и оценки качества выполнения действий. Более того, результаты абляционного анализа позволяют оптимизировать конфигурацию датчиков под конкретные приложения и требования предметной области. В частности показано, что для массовых решений достаточно комбинации IMU и/или компьютерного зрения, тогда как добавление VR-трекеров может быть опциональным. Направлением дальнейших исследований является исследование применимости более сложных архитектур, например, сверточных нейронных сетей, Transformer-ов или их сочетаний для решения задачи классификации.

Литература

- Obukhov A., Volkov A., Pchelintsev A., Nazarova A., Teselkin D., Surkova E., Fedorchuk I. Examination of the accuracy of movement tracking systems for monitoring exercise for musculoskeletal rehabilitation // *Sensors*. 2023. V. 23. N 19. P. 8058. <https://doi.org/10.3390/s23198058>
- Obukhov A., Dedov D., Volkov A., Teselkin D. Modeling of nonlinear dynamic processes of human movement in virtual reality based on digital shadows // *Computation*. 2023. V. 11. N 5. P. 85. <https://doi.org/10.3390/computation11050085>

References

- Obukhov A., Volkov A., Pchelintsev A., Nazarova A., Teselkin D., Surkova E., Fedorchuk I. Examination of the accuracy of movement tracking systems for monitoring exercise for musculoskeletal rehabilitation. *Sensors*, 2023, vol. 23, no. 19, pp. 8058. <https://doi.org/10.3390/s23198058>
- Obukhov A., Dedov D., Volkov A., Teselkin D. Modeling of nonlinear dynamic processes of human movement in virtual reality based on digital shadows. *Computation*, 2023, vol. 11, no. 5, pp. 85. <https://doi.org/10.3390/computation11050085>

3. Islam M.M., Nooruddin S., Karray F., Muhammad G. Human activity recognition using tools of convolutional neural networks: a state of the art review, data sets, challenges, and future prospects // *Computers in Biology and Medicine*. 2022. V. 149. P. 106060. <https://doi.org/10.1016/j.combiomed.2022.106060>
4. Ergun B.G., Şahiner R. Embodiment in virtual reality and augmented reality games: an investigation on user interface haptic controllers // *Journal of Soft Computing and Artificial Intelligence*. 2023. V. 4. N 2. P. 80–92. <https://doi.org/10.55195/jsc.ai.1409156>
5. Franček P., Jambrosic K., Horvat M., Planinec V. The performance of inertial measurement unit sensors on various hardware platforms for binaural head-tracking applications // *Sensors*. 2023. V. 23. N 2. P. 872. <https://doi.org/10.3390/s23020872>
6. Ghorbani F., Ahmadi A., Kia M., Rahman Q., Delrobaei M. A decision-aware ambient assisted living system with IoT embedded device for in-home monitoring of older adults // *Sensors*. 2023. V. 23. N 5. P. 2673. <https://doi.org/10.3390/s23052673>
7. Eliseichev E.A., Mikhailov V.V., Borovitskiy I.V., Zhilin R.M., Senatorova E.O. A review of devices for detection of muscle activity by surface electromyography // *Biomedical Engineering*. 2022. V. 56. N 1. P. 69–74. <https://doi.org/10.1007/s10527-022-10169-4>
8. Chung J.L., Ong L.Y., Leow M.C. Comparative analysis of skeleton-based human pose estimation // *Future Internet*. 2022. V. 14. N 12. P. 380. <https://doi.org/10.3390/fi14120380>
9. Zhang S., Li Y., Zhang S., Shahabi F., Xia S., Deng Y., Alshurafa N. Deep learning in human activity recognition with wearable sensors: a review on advances // *Sensors*. 2022. V. 22. N 4. P. 1476. <https://doi.org/10.3390/s22041476>
10. Lin J.J., Hsu C.K., Hsu W.L., Tsao T.C., Wang F.C., Yen J.Y. Machine learning for human motion intention detection // *Sensors*. 2023. V. 23. N 16. P. 7203. <https://doi.org/10.3390/s23167203>
11. Mazon D.M., Groefsema M., Schomaker L.R.B., Carloni R. IMU-based classification of locomotion modes, transitions, and gait phases with convolutional recurrent neural networks // *Sensors*. 2022. V. 22. N 22. P. 8871. <https://doi.org/10.3390/s22228871>
12. Gonzales-Huisa O.A., Oshiro G., Abarca V.E., Chavez-Echajaya J.G., Elias D.A. EMG and IMU data fusion for locomotion mode classification in transtibial amputees // *Prosthesis*. 2023. V. 5. N 4. P. 1232–1256. <https://doi.org/10.3390/prosthesis5040085>
13. Vásconez J.P., López L.I.B., Caraguay A.L.V., Benalcázar M.E. Hand gesture recognition using EMG-IMU signals and deep q-networks // *Sensors*. 2022. V. 22. N 24. P. 9613. <https://doi.org/10.3390/s22249613>
14. Sulla-Torres J., Gamboa A.C., Llanque C.A., Osorio J.A., Carnero M.Z. Classification of motor competence in schoolchildren using wearable technology and machine learning with hyperparameter optimization // *Applied Sciences*. 2024. V. 14. N 2. P. 707. <https://doi.org/10.3390/app14020707>
15. Stančić I., Music J., Grujić T., Vasic M.K., Bonkovic M. Comparison and evaluation of machine learning-based classification of hand gestures captured by inertial sensors // *Computation*. 2022. V. 10. N 9. P. 159. <https://doi.org/10.3390/computation10090159>
16. Ogundokun R.O., Maskeliunas R., Misra S., Damasevicius R. Hybrid inceptionv3-svm-based approach for human posture detection in health monitoring systems // *Algorithms*. 2022. V. 15. N 11. P. 410. <https://doi.org/10.3390/a15110410>
17. Farhadpour S., Warner T.A., Maxwell A.E. Selecting and interpreting multiclass loss and accuracy assessment metrics for classifications with class imbalance: Guidance and best practices // *Remote Sensing*. 2024. V. 16. N 3. P. 533. <https://doi.org/10.3390/rs16030533>
18. Jiang Y., Song L., Zhang J., Song Y., Yan M. Multi-category gesture recognition modeling based on sEMG and IMU signals // *Sensors*. 2022. V. 22. N 15. P. 5855. <https://doi.org/10.3390/s22155855>
19. Lin W.C., Tu Y.C., Lin H.Y., Tseng M.H. A comparison of deep learning techniques for pose recognition in Up-and-Go pole walking exercises using skeleton images and feature data // *Electronics*. 2025. V. 14. N 6. P. 1075. <https://doi.org/10.3390/electronics14061075>
20. Mohammadzadeh A.K., Alinezhad E., Masoud S. Neural-Network-Driven intention recognition for enhanced Human–Robot Interaction: a Virtual-Reality-Driven approach // *Machines*. 2025. V. 13. N 5. P. 414. <https://doi.org/10.3390/machines13050414>
3. Islam M.M., Nooruddin S., Karray F., Muhammad G. Human activity recognition using tools of convolutional neural networks: a state of the art review, data sets, challenges, and future prospects. *Computers in Biology and Medicine*, 2022, vol. 149, pp. 106060. <https://doi.org/10.1016/j.combiomed.2022.106060>
4. Ergun B.G., Şahiner R. Embodiment in virtual reality and augmented reality games: an investigation on user interface haptic controllers. *Journal of Soft Computing and Artificial Intelligence*, 2023, vol. 4, no. 2, pp. 80–92. <https://doi.org/10.55195/jsc.ai.1409156>
5. Franček P., Jambrosic K., Horvat M., Planinec V. The performance of inertial measurement unit sensors on various hardware platforms for binaural head-tracking applications. *Sensors*, 2023, vol. 23, no. 2, pp. 872. <https://doi.org/10.3390/s23020872>
6. Ghorbani F., Ahmadi A., Kia M., Rahman Q., Delrobaei M. A decision-aware ambient assisted living system with IoT embedded device for in-home monitoring of older adults. *Sensors*, 2023, vol. 23, no. 5, pp. 2673. <https://doi.org/10.3390/s23052673>
7. Eliseichev E.A., Mikhailov V.V., Borovitskiy I.V., Zhilin R.M., Senatorova E.O. A review of devices for detection of muscle activity by surface electromyography. *Biomedical Engineering*, 2022, vol. 56, no. 1, pp. 69–74. <https://doi.org/10.1007/s10527-022-10169-4>
8. Chung J.L., Ong L.Y., Leow M.C. Comparative analysis of skeleton-based human pose estimation. *Future Internet*, 2022, vol. 14, no. 12, pp. 380. <https://doi.org/10.3390/fi14120380>
9. Zhang S., Li Y., Zhang S., Shahabi F., Xia S., Deng Y., Alshurafa N. Deep learning in human activity recognition with wearable sensors: a review on advances. *Sensors*, 2022, vol. 22, no. 4, pp. 1476. <https://doi.org/10.3390/s22041476>
10. Lin J.J., Hsu C.K., Hsu W.L., Tsao T.C., Wang F.C., Yen J.Y. Machine learning for human motion intention detection. *Sensors*, 2023, vol. 23, no. 16, pp. 7203. <https://doi.org/10.3390/s23167203>
11. Mazon D.M., Groefsema M., Schomaker L.R.B., Carloni R. IMU-based classification of locomotion modes, transitions, and gait phases with convolutional recurrent neural networks. *Sensors*, 2022, vol. 22, no. 22, pp. 8871. <https://doi.org/10.3390/s22228871>
12. Gonzales-Huisa O.A., Oshiro G., Abarca V.E., Chavez-Echajaya J.G., Elias D.A. EMG and IMU data fusion for locomotion mode classification in transtibial amputees. *Prosthesis*, 2023, vol. 5, no. 4, pp. 1232–1256. <https://doi.org/10.3390/prosthesis5040085>
13. Vásconez J.P., López L.I.B., Caraguay A.L.V., Benalcázar M.E. Hand gesture recognition using EMG-IMU signals and deep q-networks. *Sensors*, 2022, vol. 22, no. 24, pp. 9613. <https://doi.org/10.3390/s22249613>
14. Sulla-Torres J., Gamboa A.C., Llanque C.A., Osorio J.A., Carnero M.Z. Classification of motor competence in schoolchildren using wearable technology and machine learning with hyperparameter optimization. *Applied Sciences*, 2024, vol. 14, no. 2, pp. 707. <https://doi.org/10.3390/app14020707>
15. Stančić I., Music J., Grujić T., Vasic M.K., Bonkovic M. Comparison and evaluation of machine learning-based classification of hand gestures captured by inertial sensors. *Computation*, 2022, vol. 10, no. 9, pp. 159. <https://doi.org/10.3390/computation10090159>
16. Ogundokun R.O., Maskeliunas R., Misra S., Damasevicius R. Hybrid inceptionv3-svm-based approach for human posture detection in health monitoring systems. *Algorithms*, 2022, vol. 15, no. 11, pp. 410. <https://doi.org/10.3390/a15110410>
17. Farhadpour S., Warner T.A., Maxwell A.E. Selecting and interpreting multiclass loss and accuracy assessment metrics for classifications with class imbalance: Guidance and best practices. *Remote Sensing*, 2024, vol. 16, no. 3, pp. 533. <https://doi.org/10.3390/rs16030533>
18. Jiang Y., Song L., Zhang J., Song Y., Yan M. Multi-category gesture recognition modeling based on sEMG and IMU signals. *Sensors*, 2022, vol. 22, no. 15, pp. 5855. <https://doi.org/10.3390/s22155855>
19. Lin W.C., Tu Y.C., Lin H.Y., Tseng M.H. A comparison of deep learning techniques for pose recognition in Up-and-Go pole walking exercises using skeleton images and feature data. *Electronics*, 2025, vol. 14, no. 6, pp. 1075. <https://doi.org/10.3390/electronics14061075>
20. Mohammadzadeh A.K., Alinezhad E., Masoud S. Neural-Network-Driven intention recognition for enhanced Human–Robot Interaction: a Virtual-Reality-Driven approach. *Machines*, 2025, vol. 13, no. 5, pp. 414. <https://doi.org/10.3390/machines13050414>

Автор

Обухов Артём Дмитриевич — доктор технических наук, профессор, ведущий научный сотрудник, Тамбовский государственный технический университет, Тамбов, 392000, Российская Федерация,  56104232400, <https://orcid.org/0000-0002-3450-5213>, obuhov.art@gmail.com

Author

Artem D. Obukhov — D.Sc., Professor, Leading Researcher, Tambov State Technical University, Tambov, 392000, Russian Federation,  56104232400, <https://orcid.org/0000-0002-3450-5213>, obuhov.art@gmail.com

Статья поступила в редакцию 21.05.2025
Одобрена после рецензирования 24.08.2025
Принята к печати 21.09.2025

Received 21.05.2025
Approved after reviewing 24.08.2025
Accepted 21.09.2025



Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»