

УДК 004.89

DOI: [10.26102/2310-6018/2025.51.4.003](https://doi.org/10.26102/2310-6018/2025.51.4.003)

Исследование размера окна сегментации для задач классификации типа физического упражнения на основе данных с акселерометра и гироскопа смартфона

В.В. Носкин¹, А.Р. Донская^{1,2}, Д.Р. Черкашин¹, С.Г. Грошев¹

¹Волгоградский государственный технический университет, Волгоград,
Российская Федерация

²Волгоградский государственный медицинский университет, Волгоград,
Российская Федерация

Резюме. В статье проведен анализ влияния размера окна сегментации на качество классификации типа физического упражнения на основе данных с акселерометра и гироскопа смартфона. Дается понятие и описание задачи HAR (Human Activity Recognition) и ее уточнение для классификации конкретных видов физических упражнений: приседания, отжимания, прыжки, пресс, выпады. Проведен обзор существующих наборов данных и подходов к решению задач этого класса. Выбрана методика сбора данных для эксперимента, определено место крепления устройства с датчиками. Разработан инструмент (мобильное приложение) для сбора данных с датчиков смартфона, таких как акселерометр и гироскоп. С помощью разработанного инструмента был собран собственный набор данных в контролируемых условиях. Полученные данные были обработаны на основе общих рекомендаций для класса задач HAR (данные приведены к единой частоте, очищены от шумов и разбиты на сегменты). На основе полученных наборов данных были обучены несколько моделей как классического машинного обучения, так и глубоких нейронных сетей с различными параметрами размера окна сегментации данных. Как результат исследования были определены наилучший размер окна сегментации данных, а также модели классического машинного обучения и глубокого, которые лучше всего справились с задачей.

Ключевые слова: анализ активности человека, машинное обучение, глубокие нейронные сети, методы предобработки данных, сбор набора данных, гироскоп, акселерометр.

Для цитирования: Носкин В.В., Донская А.Р., Черкашин Д.Р., Грошев С.Г. Исследование размера окна сегментации для задач классификации типа физического упражнения на основе данных с акселерометра и гироскопа смартфона. *Моделирование, оптимизация и информационные технологии*. 2025;13(4). URL: <https://moitvvt.ru/ru/journal/pdf?id=1973> DOI: 10.26102/2310-6018/2025.51.4.003

Investigation of the segmentation window size for tasks of classifying the type of physical exercise based on data from the accelerometer and gyroscope of a smartphone

V.V. Noskin¹, A.R. Donskaya^{1,2}, D.R. Cherkashin¹, S.G. Groshev¹

¹Volgograd State Technical University, Volgograd, the Russian Federation

²Volgograd State Medical University, Volgograd, the Russian Federation

Abstract. This article analyzes the effect of the size of the segmentation window on the quality of classification of the type of physical exercise based on data from the accelerometer and gyroscope of a smartphone. The article gives the concept and description of the HAR (Human Activity Recognition) task and its refinement for classifying specific types of physical exercises: squats, push-ups, jumps, abs, lunges. The review of existing data sets and approaches to solving problems of this class is carried out.

The method of data collection for the experiment was chosen, and the attachment point of the device with sensors was determined. A tool (mobile application) has been developed to collect data from smartphone sensors such as accelerometer and gyroscope. Using the developed tool, a proprietary data set was collected under controlled conditions. The data obtained was processed based on general recommendations for the HAR class of tasks (data are reduced to a single frequency, noise-free, and segmented). Based on the obtained data sets, several models of both classical machine learning and deep neural networks with different parameters of the data segmentation window size were trained. As a result of the research, the best size of the data segmentation window was determined, as well as the classical machine learning and deep learning models that best performed the task.

Keywords: human activity analysis, machine learning, deep neural networks, data preprocessing methods, data collection, gyroscope, accelerometer.

For citation: Noskin V.V., Donskaya A.R., Cherkashin D.R., Groshev S.G. Investigation of the segmentation window size for tasks of classifying the type of physical exercise based on data from the accelerometer and gyroscope of a smartphone. *Modeling, Optimization and Information Technology*. 2025;13(4). (In Russ.). URL: <https://moitvvt.ru/ru/journal/pdf?id=1973> DOI: 10.26102/2310-6018/2025.51.4.003

Введение

По данным всемирной организации здравоохранения каждый четвертый человек на сегодняшний день имеет недостаточный уровень физической активности в течение своей повседневной деятельности. Исследования в сфере применения носимых устройств для исследования двигательной активности человека, являются достаточно актуальными на сегодняшний день. Этому способствуют различные доказательства, например, ежегодный рост прибыли¹ с приложений, исследующих активность человека, а также запросы пользователей на добавление функционала по автоматическому определению вида активности человека².

Целью исследования является повышение качества распознавания типов физических упражнений: приседания, отжимания, прыжки, пресс, выпады (далее ПОППВ) по сравнению с протоколом распознавания активности человека на основе носимых датчиков с использованием экспертных рекомендаций за счет исследования влияния размера окна сегментации данных и типа классификатора на качество распознавания типов физических упражнений ПОППВ.

Проблема заключается в отсутствии работ, наборов данных, содержащих данные об упражнениях ПОППВ, а также рекомендаций для всех этапов процесса HAR [1] по отношению к задаче распознавания типа физического упражнения, а именно ПОППВ. Большинство существующих работ направлены на определение типа повседневной активности человека, например, ходьба, бег, поднятие по лестнице и т. д.

Существует также ряд работ, которые работают уже с готовыми наборами данных, например, такими как WISDM [2], UCI HAR [3], NHAR [4]. Главным недостатком данных работ является то, что они в основном анализируют повседневную активность человека или спортивную, но не соответствующую полностью набору ПОППВ.

¹ The State of Sports Apps Report: Top Sports Apps by Revenue and Growth Forecast. Sensor Tower. URL: <https://sensortower.com/blog/top-sports-apps-by-revenue-and-growth-forecast> (дата обращения: 22.03.2025).

² [Feature Request] Google Fit – Strength Training with Exercise Detection. Issue Tracker. URL: <https://issuetracker.google.com/issues/188854881?pli=1> (дата обращения: 20.03.2025).

Материалы и методы

Понятие задачи har и методика ее решения. Исследуемая задача по классификации типа физического упражнения является частным случаем группы задач HAR (Human Activity Recognition). На сегодняшний день уже существует стандартный подход по решению задач HAR, состоящий из нескольких этапов, изображенных на Рисунке 1. Основной проблемой при применении данного метода к новым типам активности человека – является выбор гиперпараметров для каждого из этапов.




Рисунок 1 – Стандартные этапы решения задач класса HAR

Figure 1 – Standard steps for solving HAR class problems

Под физическим упражнением понимается двигательная деятельность человека³, направленная на решение задачи физического развития человека.

В проводимом исследовании мы будем рассматривать следующие физические упражнения: приседания, отжимания, прыжки, пресс, выпады (ПОППВ). Данный набор упражнений имеет свои особые характеристики: по типу сокращения основных мышц – динамические, по биохимическому признаку – циклические, по местонахождению человека – выполнение активности на месте нахождения человека.

По классификации задач HAR, исследуемые виды активности в условиях исследования имеют следующие критерии: тип активности – физические упражнения, используемые сенсоры – акселерометр, гироскоп, среда измерения – контролируемая, расположение устройства – плечо левой руки (Рисунок 1).

Процесс классификации физической активности человека к упражнениям ПОППВ с указанием различных гиперпараметров, а также входных и выходных параметров на каждом из этапов методики HAR изображены на Рисунке 2.

Методика решения любой задачи HAR состоит из пяти основных этапов. Главная разница между задачами HAR заключается в различии гиперпараметров на каждом из этапов, например, набор датчиков, размер окна сегментации, модель обучения и так далее. Первым этапом является «Сбор данных», на котором выбирается методика сбора данных с устройства, определяется формат получаемых данных и проводится сам сбор данных по описанной методике. После сбора сырых данных они попадают на этап

³ Баранова Т.И. Физиологические основы физического воспитания. В книге: *Тематический курс лекций по физической культуре и спорту*. Санкт-Петербург: Изд-во С.-Петерб. ун-та; 2012. С. 23–51.

Таблица 1 – Существующие наборы данных для задач HAR
Table 1 – Existing datasets for HAR tasks

Название	Кол-во участников	Типы датчиков	Частота	Список активностей
UCI	–	акселерометр	50 Гц	12 повседневных активностей (сидеть, стоять, прогулка и т.д.)
DLAs	23	акселерометр, гироскоп	–	прогулка, сидение, стояние и так далее
PAMAP2	9	акселерометр, гироскоп, пульсометр, магнитометр	100 Гц	16 видов активностей: прогулка, бег, игра в футбол и так далее
SBHAR	30	акселерометр, гироскоп	50 Гц	3 статических активности (сидение, лежание и так далее) и три динамических (бег, бег вниз, бег вверх)
MHealth	10	акселерометр, гироскоп, магнитометр	50 Гц	набор повседневных активностей, как статических, так и динамических
WISDM	29	акселерометр	20 Гц	
MobyAct	57	акселерометр, гироскоп	20 Гц	9 различных типов активностей человека: бег, прыжки, поднятие по лестнице, спуск и так далее

Одной из основных проблем перечисленного списка наборов данных в таблице является то, что список активностей ни одного из набора данных не соответствует всем активностям ПОППВ. Также при частичном слиянии нескольких наборов данных мы получаем данные, которые собирались в разных условиях и по разным методикам, что может негативно повлиять на исследование. Следовательно, было принято решение о сборе собственного набора данных в соответствии с необходимыми требованиями к решению задачи.

Сбор собственного набора данных. При формировании собственного набора данных были сформированные критерии, которые должны соблюдаться. Набор данных должен включать в себя следующий список упражнений, соответствующих ПОППВ: приседания, отжимания, прыжки, пресс, выпады.

Длительность выполнения одного упражнения должна быть не менее 5 секунд. Условия при получении данных были полностью контролируемые. Сбор данных при выполнении упражнений проводился в специальном закрытом помещении – тренажерный зал одного из учебных корпусов ВолгГТУ. Благодаря этому качество выполнения физических упражнений контролировался со стороны тренеров в зале. Каждый участник в течении 20 секунд выполнял каждое из перечисленных выше упражнений ПОППВ.

Для записи показаний были использованы android смартфоны следующих моделей: Samsung A21S и Samsung S21FE, которые оснащены датчиками акселерометра и гироскопа. Устройства были выбраны специально из разных ценовых категорий (бюджетный и премиальный), чтобы посмотреть на данных с сенсоров разного качества. Смартфон закреплялся на левом плече человека с помощью специального чехла для бегунов (Рисунок 3). Данное место крепления было выбрано из-за нескольких причин. Во-первых, смартфон должен располагаться в удобном месте человека и не мешать ему во время выполнения физических упражнений. Во-вторых, наличие существующего решения для расположения устройства в данном месте. В-третьих, чехлы для

смартфонов подобного вида достаточно плотно прилегают к телу человека, а также минимизируют перемещение смартфона внутри самого чехла, что позволяет уменьшить шумы в данных от нежелательных движений, таких, как если бы устройство находилось в кармане штанов.




Рисунок 3 – Idef-0 Место крепление смартфона
Figure 3 – Idef-0 Smartphone mounting location

Для сбора данных с датчиков акселерометра и гироскопа было разработано специальное мобильное приложение для платформ Android и IOS, которое позволяет записывать данные с датчиков и соотносить их с определенным видом активности. Помимо этого, данное мобильное приложение на дальнейшем этапе позволяет определять класс выполнения физической активности человека в реальном времени.

Данные из приложения выгружаются в JSON формате и содержат следующую информацию:

- id – уникальный идентификатор пользователя;
- firstName – имя пользователя;
- lastName – фамилия пользователя;
- age – возраст;
- weight – вес пользователя;
- height – рост пользователя;
- gender – пол пользователя;
- timestamp – время в момент снятия данных относительно начала записи упражнения;
- acc_gx – ускорение датчика акселерометра по оси x;
- acc_gy – ускорение датчика акселерометра по оси y;
- acc_gz – ускорение датчика акселерометра по оси z;
- gyr_gx – скорость вращения датчика гироскопа вокруг оси x;
- gyr_gy – скорость вращения датчика гироскопа вокруг оси y;
- gyr_gz – скорость вращения датчика гироскопа вокруг оси z;
- is_border – признак, показывающий является ли момент времени границей упражнения.

Частота записи данных была выбрана – 100Гц, так как это значение является максимально возможным технически для платформы Android.

В процессе сбора данных участвовало 19 человек (15 мужчин и 4 девушки), каждый из них выполнял по возможности все виды упражнений ПОППВ (в некоторых индивидуальных случаях человек не могу выполнить физическое упражнение). В итоге после снятия всех данных получилась 81 запись, каждая из них длительностью по 20 секунд. Набор данных получился сбалансированным и его распределение по видам упражнений представлено на Рисунке 4.



Рисунок 4 – Распределение данных по различным видам упражнений
Figure 4 – Distribution of data on different types of exercises

Для понимания и анализа данных перед обучением они были визуализированы. На Рисунке 5 изображен график данных с датчика акселерометра и гироскопа при выполнении упражнения «приседания». На графике отображены ускорения по каждому из измерений, а также вертикальными линиями отмечены границы выполнения упражнений. Из рисунка можно заметить четкие границы между выполнением одного полного «приседания», что в будущей работе может позволить определять не только тип физической активности, но и количество повторений при выполнении.




Рисунок 5 – Визуализация данных с датчиков акселерометра и гироскопа при выполнении упражнения «приседания»
Figure 5 – Visualization of data from accelerometer and gyroscope sensors during the squat exercise

Результаты и обсуждение

Обучение моделей классификации и определение оптимального размера окна. Перед обучением модели данные необходимо обработать. Одним из главных этапов обработки данных такого вида является удаление шумов, которые могут

создаваться из-за особенностей датчика, лишние колебаний устройства внутри чехла и т. д. В подобных исследованиях, связанных с задачами HAR, часто применяют медианный фильтр для удаления шумов подобного вида. С помощью данного фильтра и были обработаны данные, полученные с устройств.

Частота данных была тоже изменена, это связано с тем, что по существующим исследованиям частота деятельности человека изменяется от 0 Гц до 20 Гц [5], поэтому было принято решение для уменьшения избыточности данных привести все полученные данных со всех устройств к частоте 20 Гц.

Данные были поделены также на три вида выборки: обучающая (60 %), тестовая (20 %), валидационная (20 %). Одним из критериев разбиения было также условие, что в каждую из выборок должны попадать все виды исследуемых типов физической активности, которые выполняются разными людьми.

Так как данные в нашем случае представляют временной ряд, одним из используемых подходов при обработке таких данных является сегментация. Вид сегментации был выбран – фиксированный размер окна без наложения данных между окнами. Такой вид сегментации часто используется в существующих задачах HAR. Так как наша задача найти наименьший размер окна для получения класса данных по сегменту то были выбраны следующие варианты: 0,5; 2; 3; 5; 6 секунд. Такие размеры окон встречаются в различных работах по исследованию задач HAR и часто зависят от вида исследуемой деятельности человека. На основе эксперимента и обучения моделей мы определим минимальный необходимый размер окна.

Для реализации модели классификатора были выбраны как подходы из классического машинного обучения (Gradient Boosting Classifier, XGB Classifier, Random Forest Classifier, Linear SVC), так и глубокого (MLP, CNN, GRU, LSTM, GRU-BIG) [6]. Преимуществом моделей глубокого обучения является то, что они самостоятельно извлекают необходимые признаки из набора данных [7]. В случае с моделями классического машинного обучения необходимо самостоятельно дополнительно извлечь признаки [8]. На основе существующих исследований были выбраны следующие признаки [9]: среднее, максимальное, минимальное, дисперсия, стандартное отклонение из сегмента данных для каждой из осей каждого датчика; корреляция для каждой пары осей для каждого датчика; область амплитуды сигнала (Signal-Magnitude Area-SMA); результирующее значение для каждого датчика, вычисляемое как квадратный корень из суммы квадратов.

Оценка моделей происходила на основе метрик: accuracy, precision, recall, f-мера⁴ [10].

Полученные метрики после обучения перечисленных моделей со всеми возможными вариантами временных окон представлены в Таблице 2.

Таблица 2 – Результаты обучения моделей

Table 2 – Visualization of data from accelerometer and gyroscope sensors during the squat exercise

Размер окна	Модель	Accuracy	Precision	Recall	F-мера
0,5	GradientBoostingClassifier	0,66	0,70	0,66	0,65
	XGBClassifier	0,82	0,83	0,82	0,82
	RandomForestClassifier	0,82	0,82	0,82	0,81
	LinearSVC	0,67	0,68	0,67	0,67
	MLP	0,6163	0,6824	0,5257	0,5547

⁴ Alvarez S.A. An Exact Analytical Relation Among Recall, Precision, and Classification Accuracy in Information Retrieval. Technical report, BCCS-02-01, Computer Science Department, Boston College. ResearchGate. URL: https://www.researchgate.net/publication/228906049_An_exact_analytical_relation_among_recall_precision_and_classification_accuracy_in_information_retrieval (дата обращения: 20.03.2025).

Таблица 2 (продолжение)
Table 2 (continued)

	CNN	0,6375	0,7188	0,5559	0,5931
	GRU	0,5136	0,6419	0,4169	0,4426
	LSTM	0,5196	0,6235	0,4653	0,4932
	GRU BIG	0,4894	0,5294	0,4622	0,4700
2	GradientBoostingClassifier	0,82	0,84	0,82	0,81
	XGBClassifier	0,82	0,84	0,82	0,81
	RandomForestClassifier	0,78	0,79	0,78	0,77
	LinearSVC	0,83	0,83	0,83	0,82
	MLP	0,7500	0,7500	0,7500	0,7500
	CNN	0,8026	0,8219	0,7895	0,7995
	GRU	0,8026	0,8026	0,8026	0,8026
	LSTM	0,8026	0,8026	0,8026	0,8026
	GRU BIG	0,7763	0,7838	0,7632	0,7688
3	GradientBoostingClassifier	0,82	0,89	0,82	0,82
	XGBClassifier	0,80	0,83	0,80	0,81
	RandomForestClassifier	0,80	0,82	0,80	0,80
	LinearSVC	0,80	0,83	0,80	0,80
	MLP	0,7255	0,7551	0,7255	0,7418
	CNN	0,8431	0,8600	0,8431	0,8544
	GRU	0,8235	0,8400	0,8235	0,8352
	LSTM	0,8431	0,8400	0,8235	0,8352
	GRU BIG	0,8235	0,8235	0,8235	0,8269
5	GradientBoostingClassifier	0,84	0,84	0,83	0,82
	XGBClassifier	0,88	0,89	0,88	0,88
	RandomForestClassifier	0,80	0,82	0,80	0,79
	LinearSVC	0,84	0,89	0,84	0,83
	MLP	0,6163	0,6824	0,5257	0,5547
	CNN	0,8000	0,8000	0,8000	0,7143
	GRU	0,8000	0,7826	0,7200	0,6429
	LSTM	0,8823	0,8823	0,8823	0,8999
	GRU BIG	0,8400	0,8400	0,8400	0,7500
6	GradientBoostingClassifier	0,80	0,83	0,80	0,81
	XGBClassifier	0,80	0,83	0,80	0,80
	RandomForestClassifier	0,80	0,82	0,80	0,80
	LinearSVC	0,67	0,68	0,67	0,67
	MLP	0,625	0,625	0,625	0,6249
	CNN	0,75	0,75	0,75	0,75
	GRU	0,625	0,625	0,625	0,6249
	LSTM	0,7255	0,7551	0,7255	0,7418
	GRU BIG	0,7763	0,7838	0,7632	0,7688

Вычисление метрик происходило на основе валидационного набора данных, которые модели не использовали во время обучения. Исходя из полученных результатов можно сделать вывод, что наилучший размер окна, позволяющий достичь наилучшее значение метрик, является 5 секунд. На данном размере окна наилучшие результаты показали модели как классического машинного обучения, так и глубокого. Наиболее подходящей моделью классического машинного обучения, исходя из полученных результатов, является XGBClassifier, а в классе моделей глубокого машинного обучения

– LSTM. Графики обучения моделей, а именно зависимости метрик (recall, precision, accuracy и f1) от количества эпох во время обучения изображены на Рисунке 6.




Рисунок 6 – Графики метрик при обучении моделей
Figure 6 – Graphs of metrics when training models

При обучении моделей были использованы такие технологии, как python, keras, tensor flow, а для анализа данных использовалась не менее популярная библиотека pandas.

Заключение

В процессе исследования поставленной задачи по поиску оптимального окна сегментации данных при анализе физических упражнений ПОППВ на основе данных акселерометра и гироскопа смартфона были пройдены все этапы, необходимые для задач классификации HAR. А именно, определения подкласса задачи HAR, определение ограничений, сбор данных, обработка данных, обучение моделей, анализ результатов. Был собран собственный набор данных в контролируемых условиях под наблюдением специалистов для упражнений ПОППВ, а также разработан инструмент для сбора этих данных и с возможностью тестирования полученных моделей и легкого добавления новых видов упражнений при необходимости. В итоге были получены следующие результаты, что при анализе и работе с упражнениями вида ПОППВ рекомендуемым и оптимальным размером окна сегментации является значение 5 секунд, позволяющая получить наибольшую точность моделей как классического машинного обучения, так и глубокого. Лучшие результаты моделей классического машинного обучения показала

модель XGBClassifier, а глубокого машинного обучения – LSTM с показателями метрик: accuracy – 0,8823; precision – 0,8823; recall – 0,8823; F-мера – 0,8999.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Ann O.Ch., Theng L.B. Human Activity Recognition: A Review. In: *2014 IEEE International Conference on Control System, Computing and Engineering (ICCSCE 2014)*, 28–30 November 2014, Penang, Malaysia. IEEE; 2014. P. 389–393. <https://doi.org/10.1109/ICCSCE.2014.7072750>
2. Serpush F., Menhaj M.B., Masoumi B., Karasfi B. Wearable Sensor-Based Human Activity Recognition in the Smart Healthcare System. *Computational Intelligence and Neuroscience*. 2022;2022. <https://doi.org/10.1155/2022/1391906>
3. Kumar P., Suresh S. FLAAP: An Open Human Activity Recognition (HAR) Dataset for Learning and Finding the Associated Activity Patterns. *Procedia Computer Science*. 2022;212:64–73. <https://doi.org/10.1016/j.procs.2022.10.208>
4. Logacjov A., Bach K., Kongsvold A., Bårdstu H.B., Mork P.J. HARTH: A Human Activity Recognition Dataset for Machine Learning. *Sensors*. 2021;21(23). <https://doi.org/10.3390/s21237853>
5. Antonsson E.K., Mann R.W. The Frequency Content of Gait. *Journal of Biomechanics*. 1985;18(1):39–47. [https://doi.org/10.1016/0021-9290\(85\)90043-0](https://doi.org/10.1016/0021-9290(85)90043-0)
6. Orlova Yu., Gorobtsov A., Sychev O., Rozaliev V., Zubkov A., Donskaia A. Method for Determining the Dominant Type of Human Breathing Using Motion Capture and Machine Learning. *Algorithms*. 2023;16(5). <https://doi.org/10.3390/a16050249>
7. Dhaygude A.D., Varma R.A., Yerpude P., Swarnkar S.K., Jindal R.K., Rabbi F. Deep Learning Approaches for Feature Extraction in Big Data Analytics. In: *2023 10th IEEE Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON)*, 01–03 December 2023, Gautam Buddha Nagar, India. IEEE; 2023. P. 964–969. <https://doi.org/10.1109/UPCON59197.2023.10434607>
8. Dargie W. Analysis of Time and Frequency Domain Features of Accelerometer Measurements. In: *2009 Proceedings of 18th International Conference on Computer Communications and Networks*, 03–06 August 2009, San Francisco, CA, USA. IEEE; 2009. P. 1–6. <https://doi.org/10.1109/ICCCN.2009.5235366>
9. Avci A., Bosch S., Marin-Perianu M., Marin-Perianu R., Havinga P.J.M. Activity Recognition Using Inertial Sensing for Healthcare, Wellbeing and Sports Applications: A Survey. In: *ARCS '10: 23th International Conference on Architecture of Computing Systems: Workshop Proceedings*, 22–23 February 2010, Hannover, Germany. VDE Verlag; 2010. P. 167–176.
10. Powers D.M.W. What the F-Measure Doesn't Measure: Features, Flaws, Fallacies and Fixes. arXiv. URL: <https://doi.org/10.48550/arXiv.1503.06410> [Accessed 20th March 2025].

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Носкин Виктор Викторович, аспирант, **Viktor V. Noskin**, Postgraduate, Volgograd State
Волгоградский государственный технический Technical University, Volgograd, the Russian
университет, Волгоград, Российская Федерация. Federation.
e-mail: vitek2012rus@gmail.com
ORCID: [0000-0002-0795-2675](https://orcid.org/0000-0002-0795-2675)

Донская Анастасия Романовна, старший преподаватель кафедры программного обеспечения автоматизированных систем, Волгоградский государственный технический университет, Волгоград, Российская Федерация.

e-mail: donskakaia.anastasiya@yandex.ru

ORCID: [0000-0003-3086-4929](https://orcid.org/0000-0003-3086-4929)

Anastasia R. Donskaya, Senior Lecturer at Department of Software for Automated Systems, Volgograd State Technical University, Volgograd, the Russian Federation.

Черкашин Дмитрий Романович, аспирант, Волгоградский государственный технический университет, Волгоград, Российская Федерация.

e-mail: dimach.460@gmail.com

ORCID: [0000-0001-7421-3517](https://orcid.org/0000-0001-7421-3517)

Dmitriy R. Cherkashin, Postgraduate, Volgograd State Technical University, Volgograd, the Russian Federation.

Грошев Сергей Григорьевич, студент, Волгоградский государственный технический университет, Волгоград, Российская Федерация.

e-mail: wer113wer@yandex.ru

Sergey G. Groshev, Student, Volgograd State Technical University, Volgograd, the Russian Federation.

Статья поступила в редакцию 03.06.2025; одобрена после рецензирования 02.09.2025; принята к публикации 25.09.2025.

The article was submitted 03.06.2025; approved after reviewing 02.09.2025; accepted for publication 25.09.2025.