

УДК 004.85

DOI: [10.26102/2310-6018/2025.50.3.035](https://doi.org/10.26102/2310-6018/2025.50.3.035)

Методы определения нетиповых объектов в музыкальном ряде

В.В. Котельников✉, А.И. Ахлестин, Е.В. Паринава

*Воронежский государственный технический университет, Воронеж,
Российская Федерация*

Резюме. В статье рассматриваются современные методы автоматического обнаружения нетиповых (аномальных) музыкальных событий в музыкальном ряде, таких как неожиданные смены гармонии, нехарактерные интервалы, ритмические сбои или нарушения музыкального стиля, которые позволяют автоматизировать данный процесс и оптимизировать время работы специалистов. Задача выявления аномалий актуальна в музыкальной аналитике, цифровой реставрации, генеративной музыке и адаптивных рекомендациях. В работе используются как традиционные признаки (Chroma Features, MFCC, Tempogram, RMS-energy, Spectral Contrast), так и современные методы анализа последовательностей (self-similarity matrices, latent space embeddings). В качестве исходных данных применялись разнообразные MIDI-корпусы и аудиозаписи различных жанров, приведенные к единому частотному и временному масштабу. Были опробованы методы обучения с учителем и без него, включая кластеризацию, автоэнкодеры, нейросетевые классификаторы и алгоритмы изоляции аномалий (isolation forests). Полученные результаты демонстрируют, что наибольшую эффективность показывает гибридный подход, сочетающий структурные музыкальные признаки с методами глубокого обучения. Новизна работы заключается в комплексном сравнении традиционных и нейросетевых подходов для разных типов аномалий на едином корпусе данных. Практическая апробация показала перспективность предлагаемого метода для систем автоматического мониторинга музыкального контента и повышения качества музыкальных рекомендаций. В дальнейшем планируется расширение исследования на мультимодальные музыкальные данные и обработку в режиме реального времени.

Ключевые слова: музыкальный ряд, аномалия, темпограмма, музыкальный стиль, MFCC, Chroma, автоэнкодер, обнаружение музыкальных аномалий.

Для цитирования: Котельников В.В., Ахлестин А.И., Паринава Е.В. Методы определения нетиповых объектов в музыкальном ряде. *Моделирование, оптимизация и информационные технологии*. 2025;13(3). URL: <https://moitvvt.ru/ru/journal/pdf?id=1993> DOI: 10.26102/2310-6018/2025.50.3.035

Methods for detecting atypical objects in a musical sequence

V.V. Kotelnikov✉, A.I. Ahlestin, E.V. Parinova

Voronezh State Technical University, Voronezh, the Russian Federation

Abstract. The article explores modern methods for automatic detection of atypical (anomalous) musical events within a musical sequence, such as unexpected harmonic shifts, uncharacteristic intervals, rhythmic disruptions, or deviations from musical style, aimed at automating this process and optimizing specialists' working time. The task of anomaly detection is highly relevant in music analytics, digital restoration, generative music, and adaptive recommendation systems. The study employs both traditional features (Chroma Features, MFCC, Tempogram, RMS-energy, Spectral Contrast) and advanced sequence analysis techniques (self-similarity matrices, latent space embeddings). The source data consisted of diverse MIDI corpora and audio recordings from various genres, normalized to a unified frequency and temporal scale. Both supervised and unsupervised learning methods were tested, including clustering, autoencoders, neural network classifiers, and anomaly isolation algorithms

(isolation forests). The results demonstrate that the most effective approach is a hybrid one that combines structural musical features with deep learning methods. The novelty of this research lies in a comprehensive comparison of traditional and neural network approaches for different types of anomalies on a unified dataset. Practical testing has shown the proposed method's potential for automatic music content monitoring systems and for improving the quality of music recommendations. Future work is planned to expand the research to multimodal musical data and real-time processing.

Keywords: musical sequence, anomaly, tempogram, musical style, MFCC, Chroma, autoencoder, music anomaly detection.

For citation: Kotelnikov V.V., Akhlestin A.I., Parinova E.V. Methods for detecting atypical objects in a musical sequence. *Modeling, Optimization and Information Technology*. 2025;13(3). (In Russ.). URL: <https://moitvivi.ru/ru/journal/pdf?id=1993> DOI: 10.26102/2310-6018/2025.50.3.035

Введение

Анализ музыкального материала с целью выявления отклонений от нормы является важным направлением исследований в области музыкальной информатики и искусственного интеллекта. Под нетиповыми объектами в музыкальном ряде понимаются такие элементы, которые отличаются от общего стилизового, ритмического или гармонического контекста произведения. Это могут быть, например, резкие смены тональности, необычные аккордовые прогрессии, сбои в ритмической структуре, а также элементы, нехарактерные для выбранного жанра или композиторской манеры.

Подобные аномалии могут быть как намеренным художественным приемом, так и результатом ошибок в процессе создания, транскрибирования или цифровой обработки музыкального материала. Одной из ключевых проблем в автоматическом анализе музыкального ряда является разграничение между нетипичными, но допустимыми стилистическими приемами и фактическими аномалиями, указывающими на ошибки, сбои или шумовые искажения. В рамках данного исследования под аномалиями понимаются музыкальные события, не соответствующие статистически устойчивым паттернам, выявленным на корпусе произведений одного жанра или стилизованности, и не объяснимые внутренней логикой формы или гармонии. Предлагается различать три типа аномалий:

- художественные (контекстно-нормальные) – преднамеренные отклонения, обусловленные жанровой или авторской спецификой (например, синкопа в джазе, политональность в авангарде);
- техногенные – возникающие в результате ошибок записи, конвертации, цифровой обработки (например, потеря фазы, глитчи, сбита синхронизация);
- генеративные – обусловленные ограничениями алгоритмической композиции (например, нелогичные переходы в авто-сгенерированных треках).

Для предварительной маркировки аномальных фрагментов использовалась ручная аннотация подгруппы данных ($n = 200$), при которой фрагмент считался аномальным, если не соответствовал ни одному устойчивому стилизованному паттерну из обучающего корпуса. В спорных случаях решение принималось на основании экспертной оценки (музыковед + системный аналитик). Таким образом, вводится семантический фильтр, исключающий случаи ложноположительных срабатываний на нестандартные, но художественно оправданные элементы.

С ростом объемов музыкальных данных и появлением крупных аудио- и MIDI-корпусов возрастает потребность в автоматизированных инструментах анализа. Ручная разметка и прослушивание требуют значительных ресурсов, тогда как алгоритмические подходы позволяют проводить первичную фильтрацию и фокусироваться на действительно важных сегментах.

Одной из особенностей музыкального ряда, отличающей его от технических звуковых сигналов, является его структурная и стилистическая сложность. Музыка – это не просто сигнал, а организованная система, включающая множество уровней: от тембров и ритмов до фразировки и формы. В связи с этим методы анализа музыкальных аномалий должны учитывать как низкоуровневые признаки (спектральные характеристики, энергия сигнала), так и высокоуровневые аспекты, такие как гармония, метр, структура и повторяемость.

В последние годы активно развиваются алгоритмы, способные анализировать музыку на различных уровнях. Применяются как традиционные статистические методы, так и нейросетевые подходы, включая автоэнкодеры, трансформеры и модели с рекуррентной архитектурой. Особый интерес представляет интеграция методов обучения без учителя, позволяющая выявлять потенциальные аномалии в музыкальном потоке без предварительной аннотации данных.

В настоящей работе рассматривается методология автоматического обнаружения нетипичных музыкальных объектов с использованием акустических и структурных признаков. Целью является сравнение различных подходов к анализу музыкального ряда и оценка их применимости в задачах выявления аномалий. Исследование направлено на создание основы для последующей разработки систем интеллектуального анализа музыкальных данных, применимых в музыкознании, цифровом производстве и образовании.

Вопросы автоматического анализа музыкального ряда находят все более широкое отражение в современной научной литературе, особенно в контексте задач классификации, сегментации и генерации музыкальных данных. В частности, интерес исследователей сосредоточен на возможности выявления отклонений от "нормальной" музыкальной структуры, будь то стилистические, гармонические или ритмические аномалии.

Одним из базовых подходов к анализу музыкальных данных остается использование мел-частотных кепстральных коэффициентов (MFCC) – признаков, хорошо зарекомендовавших себя в задачах распознавания речи. Благодаря своей способности отражать тембровую составляющую сигнала, они получили широкое распространение и в музыкальном анализе. Среди классических исследований – [1, 2], где предложены глубокие архитектуры для обучения признаков, оптимизируемые с SSM-ориентированными loss-функциями. Для оценки гармонического содержания предпочтительны хроматические признаки (Chroma), отражающие распределение энергии по 12 полутонам в рамках октавы.

Для обучения без разметки широко используются методы кластеризации (KMeans, DBSCAN) и алгоритмы выявления выбросов, такие как Isolation Forest и LOF, эффективно работающие в мультимодальном музыкальном пространстве данных [3, 4].

Современные подходы включают использование встраиваний в скрытое пространство (latent embeddings), полученных с помощью нейросетевых архитектур: автоэнкодеров, Variational Autoencoders (VAE), а также моделей Transformer, таких как Music Transformer. Эти методы позволяют извлекать представления, чувствительные к глобальному контексту и структурным отклонениям, без необходимости явно задавать признаки [5, 6].

В задачах безразметочного анализа все чаще применяются методы обучения без учителя: кластеризация (KMeans, DBSCAN), а также алгоритмы выявления выбросов, такие как Isolation Forest и Local Outlier Factor (LOF). Они позволяют обнаруживать нетипичные музыкальные сегменты, не опираясь на априорную жанровую или стилевую информацию [7, 8].

Несмотря на разнообразие методов, большинство подходов ограничены узкой направленностью на отдельные аспекты музыкального сигнала: тембр, ритм или

гармонию по отдельности. Кроме того, существующие методы редко интегрируют несколько типов признаков, что снижает устойчивость анализа при наличии стилистической и жанровой неоднородности. Также остается недостаточно изученным вопрос интерпретируемости обнаруженных аномалий и их сопоставимости с музыкальной логикой [9, 10].

Цель настоящей работы – разработка и апробация комплексной методики автоматического выявления аномальных сегментов в музыкальном ряде с учетом гармонических и ритмических отклонений, выходящих за рамки типичной музыкальной структуры. Под аномалиями понимаются как импровизационные и стилистические фрагменты, так и потенциальные ошибки или «сбои» в генерируемых музыкальных данных.

В отличие от известных исследований, в данной работе:

- интегрируются гетерогенные признаки: MFCC (тембр), Chroma (гармония), Tempogram (ритм), Spectral Contrast (текстура) и latent embeddings (структура) в единое векторное представление музыкального сегмента;
- системно сравниваются методы обнаружения аномалий: автоэнкодер, Isolation Forest, кластеризация и SVM – с количественной и визуальной валидацией;
- применяется визуальная диагностика результатов (гистограммы ошибок восстановления, карты самопохожести, t-SNE-проекции, boxplot по Chroma), позволяющая не только детектировать, но и интерпретировать аномалии в музыкальном контексте.

Методика протестирована на разнотипных корпусах аудио и MIDI, что обеспечивает жанровую и форматную устойчивость предложенного подхода.

Материалы и методы

В качестве эмпирической базы использовались два типа музыкальных данных:

- Аудиозаписи, охватывающие различные жанры (классика, джаз, поп), взятые из общедоступных корпусов, таких как GTZAN и MAESTRO.
- MIDI-файлы, извлеченные из Lakh MIDI Dataset, предоставляющие удобный формат для анализа нотных событий и временной структуры.
- Аудиофайлы предварительно нормализовались, ресемплировались до частоты дискретизации 22050 Гц и сегментировались на окна длительностью 2048 отсчетов с перекрытием в 50 %. MIDI-файлы были синхронизированы по темпу и обработаны с использованием библиотеки pretty_midi.

Для каждого музыкального сегмента рассчитывались признаки, отражающие как низкоуровневые, так и высокоуровневые характеристики:

- Mel-Frequency Cepstral Coefficients (MFCC) – оценка тембровой составляющей, 13 коэффициентов на каждый кадр;
- Chroma Features – распределение энергии по 12 полутонам; применимы для анализа тональности и гармоний;
- Tempogram – временной спектр повторяемости ритмических событий, вычислялся с шагом 1/4 доли;
- Spectral Contrast – контраст между частотными пиками и впадинами, полезен при анализе текстур;
- Self-Similarity Matrix – матрица сходства между музыкальными сегментами; позволяет визуализировать структуру и выявлять отклонения;
- Latent Embeddings – скрытые представления, извлеченные с помощью предобученной модели Music Transformer для MIDI или с помощью автоэнкодера на аудио.

Для каждой характеристики рассчитывались агрегированные статистики: среднее, медиана, стандартное отклонение, а также экстремальные значения. Это позволило создать компактное, но содержательное представление музыкального сегмента в виде числового вектора.

Гибридная модель в настоящем исследовании базируется на объединении признаков, описывающих различные аспекты музыкального сигнала: тембр (MFCC), гармонию (Chroma), ритм (Tempogram), текстуру (Spectral Contrast) и глобальную структуру (Latent Embeddings). Поскольку указанные дескрипторы различаются по масштабу, размерности и семантической нагрузке, интеграция их в единое векторное представление требует предварительной обработки.

Признаки нормировались по стратегии z-score (среднее = 0, стандартное отклонение = 1) на обучающей выборке, после чего объединялись в общий вектор путем конкатенации. Для эмбедингов, извлеченных из автоэнкодера и модели Music Transformer, дополнительно применялось понижение размерности с помощью PCA (Principal Component Analysis), чтобы избежать избыточности и мультиколлинеарности.

Для учета неоднородности контекстов (например, tempogram агрегирует длительные ритмические фрагменты, а MFCC – короткие тембровые окна) были протестированы две стратегии:

- простая конкатенация нормированных признаков;
- взвешенное объединение с attention-механизмом, в котором вес каждого подпространства (тембр, ритм, гармония, структура) обучался совместно с основной моделью аномалий.

Анализ ablation-экспериментов показал, что использование комбинированного признакового пространства дает прирост F1-мера на ~7 % по сравнению с моделью на однородных признаках. Это подтверждает важность мультимодального подхода к описанию музыкальных сегментов, особенно при наличии жанровой или авторской неоднородности.

Формализованные векторы признаков использовались для обучения моделей выявления аномалий. Были опробованы следующие подходы:

- Autoencoder – нейросетевая модель, обучающаяся восстанавливать входные данные. Высокая ошибка восстановления интерпретировалась как признак аномалии;
- KMeans-кластеризация – использовалась для разделения музыкальных фрагментов на группы схожих по структуре и гармонии. Выбросы рассматривались как нетипичные объекты;
- Isolation Forest – ансамблевый алгоритм, ориентированный на поиск выбросов на основе случайных разделений пространства признаков;
- Support Vector Machine (SVM) – в случае ручной разметки части данных применялась классификация на основе метода опорных векторов.

Разделение данных на обучающую и тестовую выборки проводилось в пропорции 80:20. Для оценки качества работы моделей использовались метрики точности (accuracy), полноты (recall) и F1-мера. Особое внимание уделялось устойчивости моделей к музыкальному разнообразию и жанровым отклонениям.

Результаты

В результате проведения экспериментов были получены количественная и визуальная оценки эффективности различных методов обнаружения нетиповых объектов в музыкальном ряде. Анализ проводился на основе извлеченных признаков, включая MFCC, Chroma, Tempogram, Spectral Contrast и скрытые встраивания (latent embeddings).

Агрегированные характеристики признаков. Для музыкальных сегментов длиной 10 секунд (с перекрытием в 5 секунд) были рассчитаны усреднённые значения по всему корпусу ($n = 1200$ сегментов) (Таблица 1).

Таблица 1 – Усредненные значения по всему корпусу
Table 1 – Average values for the entire case

Признак	Среднее значение	Стандартное отклонение	Минимум	Максимум
MFCC-1	-245,87	26,14	-310,45	-180,63
Chroma	0,084	0,021	0,041	0,136
Tempogram	119,5	8,73	93	138
Spectral Contrast	28,43	3,62	21,76	34,19
Reconstruction Error (Autoencoder)	0,071	0,048	0,004	0,224

Гистограммы распределения значений ошибки восстановления автоэнкодером и темпа показали наличие правостороннего сдвига, что свидетельствует о присутствии участков, потенциально содержащих аномалии (Рисунок 1).




Рисунок 1 – Гистограмма распределения ошибок
Figure 1 – Histogram of the error distribution

Оценка эффективности алгоритмов проводилась на тестовой выборке (20 % от всего объема). В качестве целевой метки использовалась ручная аннотация 200 сегментов, включающая как музыкальные «аномалии» (неожиданные смены ритма, нехарактерные аккорды, синкопа вне метра), так и нормальные фрагменты (Таблица 2).

Таблица 2 – Эффективность алгоритмов
Table 2 – Efficiency of algorithms

Метод	Accuracy	Precision	Recall	F1-score
Autoencoder	0,91	0,88	0,94	0,91
Isolation Forest	0,87	0,84	0,89	0,86
KMeans	0,78	0,73	0,81	0,77
SVM	0,89	0,91	0,87	0,89

Наиболее высокую F1-меру (0,91) показала модель автоэнкодера, что указывает на его способность дифференцировать «типичные» и «выбивающиеся» музыкальные

паттерны без явной разметки. Метод опорных векторов (SVM) продемонстрировал наибольшую точность при наличии ручной классификации, но требует затрат на подготовку обучающей выборки.

Карта ошибок восстановления автоэнкодера: тепловая карта, где каждый сегмент окрашен в зависимости от величины reconstruction error. Четко видны «выбросы» – участки с повышенной ошибкой (Рисунок 2).




Рисунок 2 – Тепловая карта ошибки восстановления
Figure 2 – Heat map of the recovery error

Self-Similarity Matrix с наложением аномалий: самоподобие музыкального трека до и после появления нестандартной модуляции. Отчетливо видно нарушение симметрии (Рисунок 3).




Рисунок 3 – Self-Similarity Matrix с наложением аномалий
Figure 3 – Self-Similarity Matrix with superimposed anomalies

t-SNE проекция признаков: визуализация в 2D-пространстве, где нормальные и аномальные сегменты формируют отдельные кластеры. Аномалии распределены в более разреженной области (Рисунок 4).




Рисунок 4 – t-SNE проекция признаков
Figure 4 – t-SNE projection of features

Boxplot по значению Chroma (тональности) показывает увеличенную вариативность у аномальных фрагментов, особенно в диапазоне от C до E.




Рисунок 5 – Boxplot по значению Chroma (тональности)
Figure 5 – Boxplot by Chroma value (tonality)

Обсуждение

Полученные результаты подтверждают высокую информативность и практическую значимость многомерного анализа музыкального материала для выявления нетипичных элементов. Наиболее устойчивыми и надежными в рамках эксперимента оказались методы, использующие скрытые представления и обучающиеся на исходной структуре сигнала без необходимости внешней разметки. В частности, нейросетевой автоэнкодер продемонстрировал способность улавливать как

микроструктурные, так и макроформные нарушения, связанные с отклонениями от привычной гармонической или метрической логики.

Выделяется и практическая применимость моделей без учителя, особенно в контексте музыкальных архивов, где разметка отсутствует или затруднена из-за художественной неоднозначности. Такие модели способны на основе повторяемости и локального контекста оценивать степень типичности того или иного музыкального события, что полезно как в задачах фильтрации контента, так и в исследовательских целях.

Интересным наблюдением стал тот факт, что простые признаки, такие как дисперсия Chroma или пиковое значение темпограммы, могут быть не менее эффективны, чем сложные латентные представления, если использовать их в комплексе. Это дает основание полагать, что построение гибридных моделей, объединяющих интерпретируемые признаки и глубинные эмбединги, может стать оптимальным направлением дальнейшего развития.

Кроме того, визуализация в пространстве признаков (например, t-SNE или PCA) помогает не только интерпретировать работу модели, но и обнаруживать потенциальные подтипы аномалий – такие как ритмические сбои, тональные модуляции, или структурные разрывы, что делает такие подходы ценным инструментом музыкального анализа.

Заключение

В ходе данной работы была разработана и протестирована методика автоматического обнаружения нетипичных объектов в музыкальном ряде на основе анализа акустических и структурных признаков. Эксперименты показали, что комплексный подход, включающий как традиционные характеристики (Chroma, MFCC, Tempogram), так и современные методы извлечения скрытых признаков (Autoencoder, Self-Similarity Matrix), позволяет эффективно выявлять фрагменты, отклоняющиеся от типичной музыкальной логики.

Наиболее высокие показатели точности и устойчивости продемонстрировал автоэнкодер, не требующий предварительной разметки данных, что делает его особенно ценным в условиях отсутствия аннотаций. Методы кластеризации и анализа выбросов, в свою очередь, оказались полезны при необходимости предварительной сегментации музыкального материала.

Результаты указывают на перспективность использования интеллектуальных методов анализа в задачах музыкальной экспертизы, реставрации, адаптивных музыкальных систем и обучения. В будущем планируется расширение набора данных, применение мультимодальных признаков (например, объединение аудио и MIDI), а также исследование моделей, способных учитывать более глубокий контекст – форму, фразировку, стиль.

Таким образом, предложенная методология представляет собой надежный инструмент для систематического выявления музыкальных аномалий и может быть адаптирована под широкий спектр задач, включая как академическое, так и прикладное музыкознание.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Müller M. *Fundamentals of Music Processing: Audio, Analysis, Algorithms, Applications*. Cham: Springer; 2015. 487 p. <https://doi.org/10.1007/978-3-319-21945-5>

2. Tzanetakis G., Cook P. Musical Genre Classification of Audio Signals. *IEEE Transactions on Speech and Audio Processing*. 2002;10(5):293–302. <https://doi.org/10.1109/TSA.2002.800560>
3. Choi K., Fazekas G., Sandler M.B., Cho K. Convolutional Recurrent Neural Networks for Music Classification. In: *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 05–09 March 2017, New Orleans, LA, USA*. IEEE; 2017. P. 2392–2396. <https://doi.org/10.1109/ICASSP.2017.7952585>
4. Huang Yu-S., Yang Yi-H. Pop Music Transformer: Beat-Based Modeling and Generation of Expressive Pop Piano Compositions. In: *MM '20: Proceedings of the 28th ACM International Conference on Multimedia, 12–16 October 2020, Seattle, WA, USA*. New York: Association for Computing Machinery; 2020. P. 1180–1188. <https://doi.org/10.1145/3394171.3413671>
5. Luo Yi.-J., Su L. Learning Domain-Adaptive Latent Representations of Music Signals Using Variational Autoencoders. In: *Proceedings of the 19th International Society for Music Information Retrieval Conference (ISMIR), 23–27 September 2018, Paris, France*. 2018. P. 653–660.
6. Foote J. Visualizing Music and Audio Using Self-Similarity. In: *MULTIMEDIA '99: Proceedings of the 7th ACM international Conference on Multimedia (Part 1), 30 October – 5 November 1999, Orlando, FL, USA*. New York: Association for Computing Machinery; 1999. P. 77–80. <https://doi.org/10.1145/319463.319472>
7. Peeters G., Angulo F. SSM-Net: Feature Learning for Music Structure Analysis Using a Self-Similarity-Matrix Based Loss. In: *ISMIR 2022: Proceedings of the 23rd International Society for Music Information Retrieval Conference, 04–08 December 2022, Bengaluru, India*. 2022. <https://arxiv.org/abs/2211.08141>
8. McFee B., Ellis D. Analyzing Song Structure with Spectral Clustering. In: *ISMIR 2014: Proceedings of the 15th International Society for Music Information Retrieval Conference, 27–31 October 2014, Taipei, Taiwan*. 2014. P. 405–410.
9. Sigtia S., Benetos E., Dixon S. An End-to-End Neural Network for Polyphonic Piano Music Transcription. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*. 2016;24(5):927–939. <https://doi.org/10.1109/TASLP.2016.2533858>
10. Lattner S., Grachten M., Widmer G. Learning Transposition-Invariant Interval Features from Symbolic Music and Audio. In: *Proceedings of the 19th International Society for Music Information Retrieval Conference (ISMIR), 23–27 September 2018, Paris, France*. 2018. <https://doi.org/10.48550/arXiv.1806.08236>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Котельников Владимир Владимирович, магистрант, Воронежский государственный технический университет, Воронеж, Российская Федерация.
e-mail: vv.kotelnikov@inbox.ru

Vladimir V. Kotelnikov, Master's Degree student, Voronezh State Technical University, Voronezh, the Russian Federation.

Ахлестин Андрей Игоревич, магистрант, Воронежский государственный технический университет, Воронеж, Российская Федерация.
e-mail: ahlestin.and@yandex.ru

Andrey I. Ahlestin, Master's Degree student, Voronezh State Technical University, Voronezh, the Russian Federation.

Паринова Евгения Викторовна, магистрант, Воронежский государственный технический университет, Воронеж, Российская Федерация.
e-mail: ysahno86@gmail.com

Evgeniya V. Parinova, Master's Degree student, Voronezh State Technical University, Voronezh, the Russian Federation.

*Статья поступила в редакцию 24.06.2025; одобрена после рецензирования 29.07.2025;
принята к публикации 07.08.2025.*

*The article was submitted 24.06.2025; approved after reviewing 29.07.2025;
accepted for publication 07.08.2025.*