

Электронный научный журнал "Математическое моделирование, компьютерный и натурный эксперимент в естественных науках" <http://mathmod.esrae.ru/>

URL статьи: mathmod.esrae.ru/56-233

Ссылка для цитирования этой статьи:

Осипова И.Д., Осипов Д.И., Кондратова Ю.Н., Коробейников И.С., Вырыханов Д.А.

Применение методов машинного обучения для поиска аномалий в аудиоданных эксплуатируемого сервопривода авиационного назначения // Математическое моделирование, компьютерный и натурный эксперимент в естественных науках. 2026. №2

УДК 004.85: 629.7.062

DOI:10.24412/2541-9269-2026-2-8-17

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПОИСКА АНОМАЛИЙ В АУДИОДАНЫХ ЭКСПЛУАТИРУЕМОГО СЕРВОПРИВОДА АВИАЦИОННОГО НАЗНАЧЕНИЯ

Осипова И.Д.^{1,2}, Осипов Д.И.^{1,3}, Кондратова Ю.Н.², Коробейников И.С.^{1,4},
Вырыханов Д.А.^{1,3}

¹Акционерное общество «Конструкторское бюро промышленной автоматики»,
Россия, Саратов, pilot@kbpa.ru

²Саратовский национальный исследовательский государственный университет
имени Н.Г. Чернышевского, Россия, Саратов, rector@sgu.ru

³Саратовский государственный технический университет имени Гагарина Ю.А.,
Россия, Саратов, tmm@sstu.ru

⁴Федеральный исследовательский центр «Саратовский научный центр
Российской академии наук», Россия, Саратов, info@iptmuran.ru

Аннотация. Рассматривается применение методов машинного обучения для автоматического поиска аномалий в акустических сигналах авиационного сервопривода. Актуальность связана с переходом к диагностике по фактическому состоянию, тогда как традиционный анализ звука трудоёмок и субъективен. Цель – сравнение шести алгоритмов (Isolation Forest, One-Class SVM, DBSCAN, LOF, PCA, Autoencoder) для выявления дефектов. Результат: лучшие точность (75,55%) и F1-мера (78,06%) достигнуты методом Local Outlier Factor, что рекомендует его для акустической диагностики.

Ключевые слова: машинное обучение, обнаружение аномалий, аудиоданные, сервопривод, авиационная диагностика.

Abstract. This article explores the application of machine learning methods to automatically detect anomalies in the acoustic signals of an aircraft servo drive. This research is relevant given the shift toward condition-based diagnostics, as traditional sound analysis is labor-intensive and subjective. The objective is to compare six algorithms (Isolation Forest, One-Class SVM, DBSCAN, LOF, PCA, and Autoencoder) for defect detection. The results: the Local Outlier Factor method achieved the best accuracy (75.55%) and F1 score (78.06%), making it recommended for acoustic diagnostics.

Keywords: Machine learning, anomaly detection, audio data, servo drive, aviation diagnostics.

Введение. В настоящее время наблюдается активный переход от планового и регламентированного технического обслуживания и ремонта (ТОиР) по установленным показателям (наработка, моточасы и т.д.) к методам, основанным на анализе фактического режима работы и состояния конструктивных элементов сложных технических систем с последующей оценкой остаточного ресурса, что повышает эффективность использования ресурсов, обеспечивает необходимый уровень надежности, снижает вероятность аварийных ситуаций и смягчает их возможные последствия [1].

Особую актуальность задачи диагностики по фактическому состоянию приобретают в авиационной отрасли, где надежность бортовых систем напрямую связана с безопасностью полетов. Как показывают отчеты о надежности эксплуатируемых беспилотных летательных аппаратов, приводы системы управления полетом входят в число основных причин отказов, причем зачастую эти отказы обусловлены отсутствием полной отказоустойчивости и недостаточным контролем технического состояния электромеханических приводов. Одним из перспективных способов раннего выявления дефектов в таких приводах является анализ акустических сигналов, что делает разработку автоматизированных методов поиска аномалий в аудиоданных важной практической задачей для повышения надежности авиационного оборудования [2].

Анализ звуковых колебаний является одним из самых распространенных методов по оценке текущего технического состояния, прогнозирования остаточного ресурса и степени износа вращательных элементов сложных технических систем, находящий свое применение практически во всех отраслях промышленности, включая авиастроение [3-6].

Акустические сигналы, регистрируемые в процессе работы электромеханических систем, относятся к классу «больших данных»: длительность записей, высокая частота дискретизации и многомерность спектральных признаков порождают массивы информации, которые невозможно обработать вручную или с помощью традиционных пороговых методов. Именно поэтому возникает необходимость в автоматизированных подходах – методах машинного обучения (МО). МО позволяют эффективно анализировать такие объемы, извлекая скрытые закономерности без потери качества диагностики [7, 8].

Кроме того, звуковые данные часто содержат избыточность и шумы, что требует предварительного сжатия информации и выделения информативных признаков. Алгоритмы МО, включая ансамблевые классификаторы и методы снижения размерности (например, PCA или отбор признаков), справляются с этой задачей там, где классические методы оказываются непригодными из-за вычислительной сложности или низкой чувствительности [9].

В задачах диагностики по звуковым сигналам ключевым подходом является обнаружение аномалий. Аномалия – это объект, который значительно отличается от нормальных объектов и возник как результат присутствия в

конструкции или режиме работы исследуемой системы нештатных особенностей [10]. Применительно к работе редуктора сервопривода аномалиями выступают акустические фрагменты с высокочастотным или низкочастотным шумом, которые свидетельствуют о развитии дефекта. Аномалии могут быть точечными, контекстуальными или коллективными, а для их выявления применяются такие алгоритмы машинного обучения, как изолирующий лес (Isolation Forest), автоэнкодер и эллипсоидальная аппроксимация данных. Таким образом, применение алгоритмов поиска аномалий позволяет автоматически маркировать подозрительные акустические эпизоды без необходимости предварительной разметки всех возможных типов неисправностей, что критически важно для систем ранней диагностики авиационного оборудования [11, 12].

Получение аудиоданных работы сервопривода. В процессе отработки и обкатки сервоприводов генерируются акустические сигналы, на основании которых производится оценка наличия механических дефектов. Органолептический акустический контроль (субъективное восприятие звука оператором, проводящим испытания) позволяет заключить, что равномерный акустический фон без посторонних призывков свидетельствует об отсутствии дефектов механической части. Наличие высокочастотных или низкочастотных шумовых составляющих, сопровождающих движение зубчатых колёс и иных элементов трансмиссии, служит основанием для проведения углублённой диагностики элементов внутренней кинематической цепи с целью выявления неисправностей.

С целью формализации процесса детектирования дефектов и исключения влияния человеческого фактора разработана методика инструментального акустического контроля. В рамках данной методики сформирована база аудиозаписей с применением портативного многофункционального измерительного комплекса «Экофизика-110А». Регистрация акустических сигналов проводилась в условиях максимально возможного подавления внешних фоновых шумов, способных исказить результаты последующего анализа. Для снижения влияния внешних вибраций на процесс регистрации акустических эмиссий использовался демпфер на основе пористого эластичного материала (поролон). Положение микрофона при всех измерениях оставалось неизменным. В результате экспериментальных измерений получено 1092 аудиозаписи, из которых 490 соответствуют технически неисправным состояниям сервоприводов.

Предобработка аудиоданных. С помощью библиотеки librosa для анализа аудиосигналов вычислялись мел-кепстральные коэффициенты (MFCC), усредняя их по временной оси были получены признаки фиксированной длины. Также был выполнен анализ частотного спектра с помощью короткого преобразования Фурье (STFT), вычисляя статистические характеристики амплитудного спектра: минимум, максимум, среднее, медиану, квантили (25, 50, 75 процентов) и стандартное отклонение.

Обучение моделей машинного обучения для поиска аномалий. Для всех методов основной целью являлось сравнение производительности моделей при различных подходах к обнаружению аномалий в условиях обучения исключительно на нормальных данных, что достигается путем применения шести различных алгоритмов: Isolation Forest, One-Class SVM, DBSCAN, LocalOutlierFactor, PCA Reconstruction Error и Autoencoder. Работа включает этапы предобработки данных, обучения моделей с использованием только нормальных образцов, оценки их качества на полном наборе данных и сравнительной визуализации результатов. На первом этапе для всех моделей осуществляется преобразование входных данных, представленных в виде аудио- и меток классов, в массивы, что обеспечивает эффективную работу с числовыми данными. Далее применяется стандартизация, которая преобразует данные так, чтобы они имели нулевое среднее и единичную дисперсию.

Для оценки качества моделей были выбраны общая точность (accuracy) и F1-мера. Accuracy характеризует долю правильных ответов, а F1-мера – сбалансированный показатель, учитывающий как точность, так и полноту классификации, что особенно важно при работе с несбалансированными данными.

Изолирующий лес для поиска аномалий. Изолирующий лес (IsolationForest) использует принцип изоляции аномалий через построение ансамбля случайных деревьев, где аномальные точки изолируются быстрее благодаря их отличительным характеристикам. Модель обучается исключительно на нормальных наблюдениях, строя лес из решающих деревьев. В алгоритме по построенным деревьям вычисляется усредненная длина пути от корня до листьев. Вычисленная величина является мерой нормальности для объектов и используется для принятия решения об аномальности объекта. Аномальные точки, как правило, проходят более короткие пути от корня к листу, поскольку их легче изолировать из-за их отличительных характеристик. В работе модель Isolation Forest настраивается с помощью гиперпараметра contamination, который устанавливает ожидаемую долю аномалий в данных на основе известных меток, значение параметра random_state фиксируется для обеспечения воспроизводимости результатов.

Одноклассовая классификация для поиска аномалий. Одноклассовая классификация (One-Class SVM) строит гиперплоскость в пространстве признаков, отделяющую нормальные данные от остальных данных. В работе модель One Class SVM настраивается с радиальной базисной функцией (RBF) в качестве ядра, параметром для автоматического определения ширины ядра и параметром, который задает верхнюю границу доли ошибок обучения и нижнюю границу доли опорных векторов. Модель обучается исключительно на нормальных наблюдениях, чтобы изучить их распределение и построить границу, охватывающую область нормальных данных.

Плотностной алгоритм пространственной кластеризации с присутствием шума для поиска аномалий. Плотностной алгоритм

пространственной кластеризации с присутствием шума (DBSCAN) применяет кластеризацию на основе плотности, помечая точки в разреженных областях как шум (аномалии), что не требует предварительного знания о количестве аномалий. Модель DBSCAN настраивается с параметром, определяющим максимальное расстояние между точками для их включения в один кластер, и параметром, который задает минимальное количество точек для формирования плотной области. В отличие от предыдущих методов, DBSCAN применяется непосредственно ко всем тестовым данным без отдельного этапа обучения на нормальных наблюдениях. Алгоритм идентифицирует плотные регионы как кластеры, а точки, которые не попадают ни в один кластер из-за низкой плотности окружающих точек, помечаются как шум. Эти шумовые точки затем классифицируются как аномалии, в то время как все точки, вошедшие в кластеры, считаются нормальными.

Локальный фактор выброса для поиска аномалий. Локальный фактор выброса (Local Outlier Factor) оценивает локальную плотность каждой точки относительно ее k ближайших соседей, идентифицируя аномалии как точки с существенно меньшей локальной плотностью. Модель LOF настраивается с параметром, определяющим количество соседей для анализа локальной плотности, и параметром, который устанавливает ожидаемую долю аномалий в данных на основе известных меток. А также параметром указывающим, что модель будет обучена на нормальных данных, а затем применена для предсказания на новых данных. Модель обучается исключительно на нормальных наблюдениях, чтобы изучить их локальную структуру плотности.

Ошибка реконструкции для поиска аномалий. Ошибка реконструкции (PCA Reconstruction Error) использует метод главных компонент для снижения размерности и вычисляет ошибку реконструкции, предполагая, что аномальные данные будут иметь значительно более высокую ошибку восстановления. Сначала создается модель PCA, которая сохраняет 95 процентов дисперсии исходных данных, что позволяет уменьшить размерность, сохраняя при этом основную информацию. Модель обучается только на нормальных данных, чтобы научиться наилучшим образом представлять их структуру. Затем определяется функция ошибки восстановления, которая вычисляет среднеквадратичное отклонение между исходными данными и их версией, восстановленной после преобразования через PCA. Для всех тестовых данных вычисляются эти ошибки восстановления. Порог для обнаружения аномалий устанавливается как медиана ошибок плюс три стандартных отклонения, что соответствует статистическому подходу, при котором наблюдения, значительно отклоняющиеся от типичного распределения, считаются аномальными. Наблюдения с ошибкой восстановления выше этого порога классифицируются как аномалии.

Автоэнкодер для поиска аномалий. Автоэнкодер (Autoencoder) – нейросетевая архитектура, обучающаяся сжимать и восстанавливать нормальные данные, где высокая ошибка реконструкции свидетельствует об

аномалии. Сначала определяется архитектура автоэнкодера: входной слой соответствует размерности признаков нормальных данных, за которым следуют два кодирующих слоя с уменьшением размерности до 32 и 16 нейронов соответственно, а затем два декодирующих слоя, которые восстанавливают исходную размерность. После этого модель компилируется с оптимизатором и функцией потерь. Для предотвращения переобучения применяется ранняя остановка, которая отслеживает потерю на валидации и восстанавливает веса лучшей эпохи. Модель обучается только на нормальных данных, пытаясь реконструировать их на выходе. После обучения вычисляется ошибка восстановления для тестовых данных как среднее квадратичное отклонение между исходными и восстановленными значениями. Порог для обнаружения аномалий устанавливается таким образом, что аномалиями считаются 5 процентов наблюдений с наибольшей ошибкой восстановления, то есть наблюдения, чья ошибка превышает значения 95 процентов всех остальных наблюдений.

Анализ эффективности моделей. Модель Local Outlier Factor уверенно заняла первое место (см. рис. 1), показав наивысшие значения как по точности (75,55 %), так и по F1-мере (78,06 %). Isolation Forest продемонстрировала средние результаты. One-Class SVM, DBSCAN, PCA Reconstruction и Autoencoder существенно отстали, причем у последних трех F1-score оказался критически низким ($< 0,20$), что указывает на практически полную неспособность выявлять аномалии.

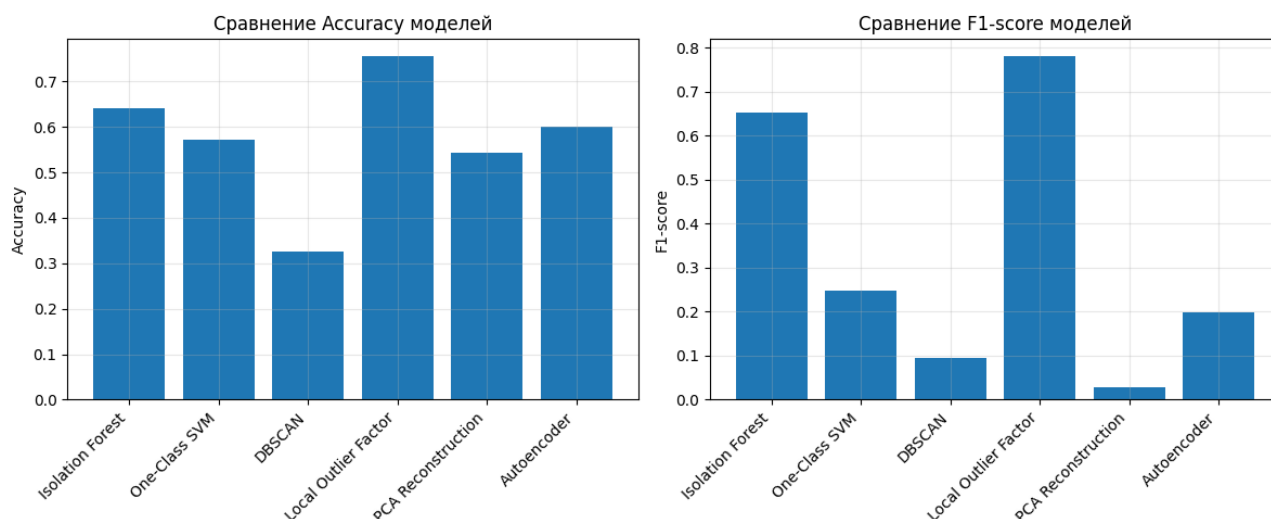


Рис. 1. Сравнение метрик моделей

Матрицы ошибок (см. рис. 2) позволяют детально разобрать типы ошибок каждой модели (исправные сигналы – класс 0, неисправные – класс 1).

Local Outlier Factor (лучшая модель):

- ложноотрицательных ошибок (неисправные классифицированы как исправные) всего 15 из 490.
- ложноположительных – 252.

Модель эффективно детектирует неисправности, но склонна к ложноположительным срабатываниям.

Isolation Forest:

– ложноотрицательных – 121, ложноположительных – 270.

Показатели качества классификации по двум классам сопоставимы, но остаются на недостаточно высоком уровне.

One-Class SVM и DBSCAN:

– очень большое количество ложноотрицательных ошибок (413 и 451 соответственно). Модели почти не выявляют аномалии.

PCA Reconstruction:

– только 7 правильно классифицированных аномалий из 490. Фактически модель игнорирует класс 1.

Autoencoder:

– аналогичная картина – всего 54 истинных аномалий обнаружено, при этом 436 аномалий пропущено.

Таким образом, нейросетевые и реконструкционные подходы (PCA и Autoencoder) показали наихудшую способность к обнаружению аномалий в аудиоданных, в то время как LOF продемонстрировал наиболее сбалансированное и надежное поведение.

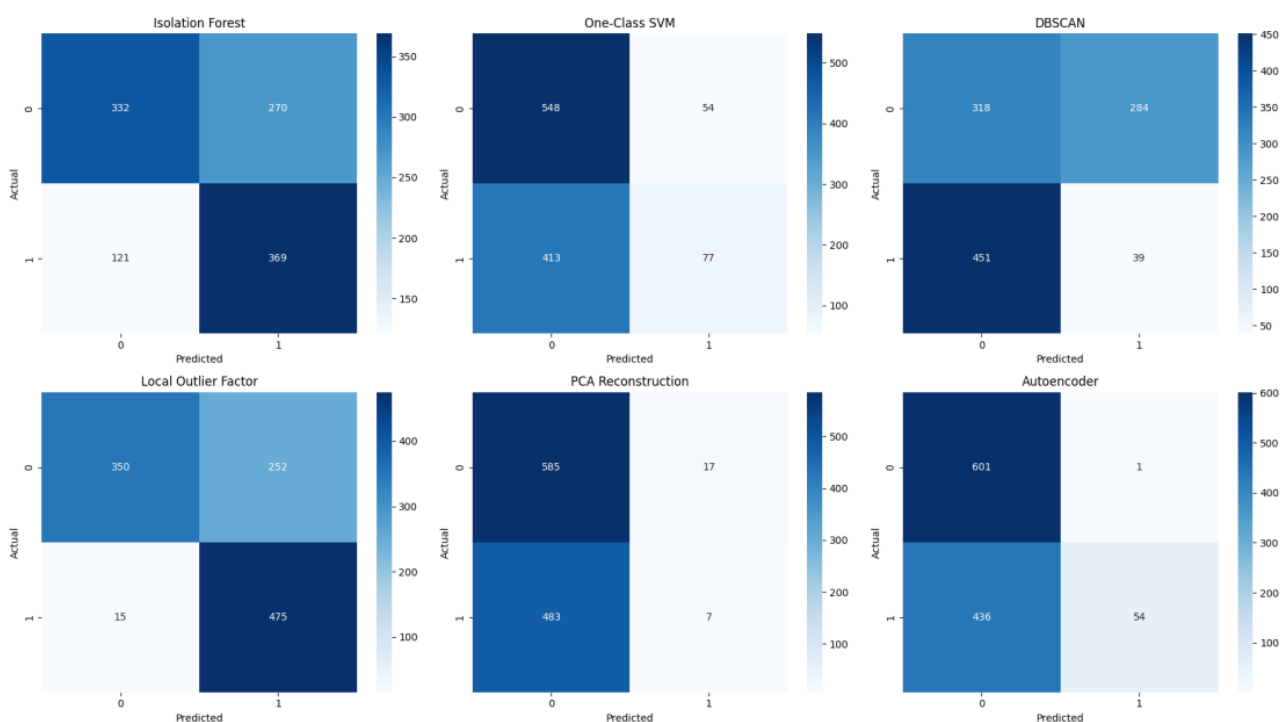


Рис. 2. Матрица ошибок

Для интерпретации результатов были построены проекции данных в двумерное пространство ($n_components = 2$) с помощью двух методов: Latent Dirichlet Allocation (рисунок 3) и Truncated SVD (рисунок 4). Цветовая шкала

отражает истинную метку: фиолетовый – класс 0 (исправные), красный – класс 1 (неисправные).

Latent Dirichlet Allocation (см. рис. 3): точки образуют практически совершенную диагональную линию: верхний левый угол – синие, середина – красные, нижний правый угол – смесь синих и красных. Это свидетельствует о высокой линейной разделимости классов в латентном представлении аудиопризнаков. Именно такая структура объясняет превосходство LOF, который эффективно работает в пространствах с выраженной локальной плотностью.

Truncated SVD (см. рис. 4): наблюдается более сложная кластерная структура. Четко выделяются плотные красные скопления в правой верхней части графика, в то время как синие точки распределены шире и частично пересекаются. Несмотря на наличие перекрытий, прослеживается общая тенденция к разделению классов, что дополнительно подтверждает возможность эффективного обнаружения аномалий, но требует более чувствительных к локальным плотностям алгоритмов (таких как LOF).

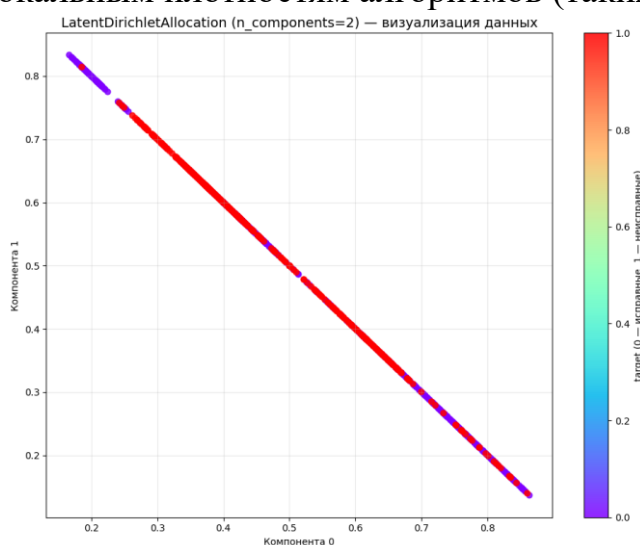


Рис. 3. Latent Dirichlet Allocatio

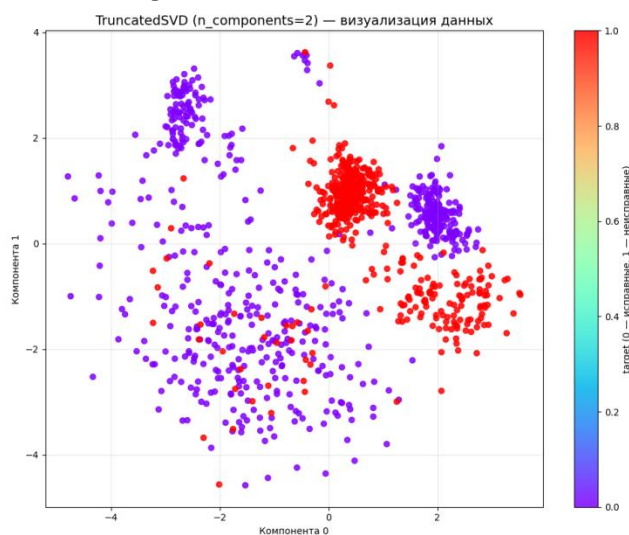


Рис. 4. Truncated SVD

Выводы. В ходе экспериментов по обнаружению аномалий в аудиоданных (исправные сигналы – класс 0, неисправные – класс 1) было обучено и протестировано шесть моделей: Isolation Forest, One-Class SVM, DBSCAN, LOF, PCA Reconstruction и Autoencoder.

Общий объем тестовой выборки составил 1092 образца (602 нормальных и 490 аномальных). Оценка проводилась по метрикам Accuracy и F1-score (для класса аномалий).

Проведенный анализ показал, что среди рассмотренных моделей Local Outlier Factor является наиболее подходящей для задачи обнаружения аномалий в аудиоданных. Ее превосходство объясняется как высокими метриками качества, так и отличной способностью работать с линейно разделимыми и локально плотными структурами, подтвержденными визуализациями.

Реконструкционные методы (PCA и Autoencoder) и DBSCAN оказались непригодными для данного типа данных. Полученные результаты позволяют рекомендовать LOF как базовый алгоритм для дальнейших исследований и промышленного применения систем акустической диагностики.

Литература

1. Кочегаров И.И., Юрков О.К., Абдирашев О.К. [и др.]. Методика оценки остаточного ресурса электронного блока с использованием ускоряющих факторов // Надежность и качество сложных систем. 2020. №4(32). С. 58-72.
2. Ismail, M.A., Bosch, C., Wiedemann, S., Bierig, A. Fault-Tolerant Actuation Architectures for Unmanned Aerial Vehicles // In Advances in Condition Monitoring and Structural Health Monitoring; Lecture Notes in Mechanical Engineering; Springer: Singapore, 2021; pp. 345-354.
3. Капранов Б.И., Коротков М.М. Акустические методы контроля и диагностики. Часть 1: учебное пособие. Томск: Изд-во Томского политехнического университета, 2008, 186 с.
4. Шалаков В.С., Коробейников И.С., Вырыханов Д.А. Методика оценки степени прикатки силового редуктора сервопривода на основании анализа издаваемых шумов // Математические методы в технологиях и технике. 2025. №2. С. 124-130.
5. Степанов П.И., Закураев В.В. Алгоритм прогнозирования остаточного ресурса электромеханического оборудования на основе комплексного анализа токовых и вибрационных сигналов // Омский научный вестник. 2017. №3(153). С. 99-103.
6. Шафиков Д.Р. Диагностика промышленного оборудования с помощью анализа упругих волн слышимого диапазона: обзор текущего состояния, проблем и будущих направления // Транспорт и хранение нефтепродуктов и углеводородного сырья. 2025. №1-2. С. 50-60.

7. Ковито М.А. Обнаружение неисправностей механического оборудования с использованием методов интеллектуального анализа данных // Информатика. Экономика. Управление. 2022. Т. 1, №2. С. 121-133.
8. Голев А.В. Классификация состояния узлов и агрегатов летательных аппаратов с использованием методов отбора информативных признаков и интеллектуального анализа данных // Управление развитием крупномасштабных систем (MLSD'2022). 2022. С. 1123-1128.
9. Сальников С.В., Солодкий К.М., Вишняков Д.Д. [и др.]. Диагностика асинхронного двигателя на основе машинного обучения // Международная конференция по мягким вычислениям и измерениям. 2023. Т. 1. С. 295-300.
10. Попова И.А. Обнаружение аномалий в наборе данных с помощью алгоритмов машинного обучения без учителя Isolation Forest и Local Outlier Factor // Student. 2020. Т. 3, №12. С. 1460-1470.
11. Ярош Е.А. Обнаружение аномалий в наборах данных: методы машинного обучения // Белорусский государственный университет информатики и радиоэлектроники. 2022. С. 177-178.
12. Селедец И.Е., Борунов Д.И., Рычков В.А. Обнаружение аномалий с помощью машинного обучения // Синергия Наук. 2020. №44. С. 415-422.