

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение  
высшего образования

**«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ  
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ  
ИМЕНИ Н. Г. ЧЕРНЫШЕВСКОГО»**

Кафедра математической кибернетики и компьютерных наук

**ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ  
ОПРЕДЕЛЕНИЯ НЕИСПРАВНОСТИ СЕРВОПРИВОДА ДЛЯ  
УПРАВЛЕНИЯ БЕСПИЛОТНЫМИ ЛЕТАТЕЛЬНЫМИ АППАРАТАМИ  
САМОЛЕТНОГО ТИПА НА ОСНОВАНИИ АКУСТИЧЕСКИХ ШУМОВ**

**АВТОРЕФЕРАТ МАГИСТЕРСКОЙ РАБОТЫ**

студентки 2 курса 273 группы  
направления 02.04.03 — Математическое обеспечение и администрирование  
информационных систем  
факультета КНиИТ  
Осиповой Ирины Денисовны

Научный руководитель

к. ф.-м. н., доцент

\_\_\_\_\_

Ю. Н. Кондратова

Заведующий кафедрой

доцент, к. ф.-м. н.

\_\_\_\_\_

С. В. Миронов

Саратов 2026

## ВВЕДЕНИЕ

Современные беспилотные летательные аппараты (БПЛА) играют важную роль в различных областях, включая оборону, промышленность, сельское хозяйство и логистику. Надежность их работы во многом зависит от состояния ключевых компонентов, таких как сервоприводы, обеспечивающие точность и устойчивость управления.

В основе диагностики состояния сервопривода по акустическому сигналу лежит представление о том, что неисправности проявляются в виде аномалий — отклонений акустического сигнала от эталонной нормы. Под аномалией в данном контексте понимается любое нетипичное поведение системы, которое может свидетельствовать о наличии дефекта: посторонние шумы, вибрации, изменение тона или характера звука. Таким образом, исходная задача диагностики может быть отнесена к классу задач обнаружения аномалий, где модель обучается на нормальных образцах и выявляет любые значимые отклонения от них. В то же время, поскольку техническое состояние сервопривода характеризуется двумя классами (исправен / неисправен), а в распоряжении имеется размеченная выборка, включающая записи обоих состояний, данная задача также может быть эффективно решена с использованием методов бинарной классификации. Каждый из этих подходов имеет свои достоинства и ограничения: классификация позволяет достичь высокой точности при наличии полной разметки, тогда как обнаружение аномалий применимо в условиях, когда данные о неисправностях ограничены или отсутствуют.

В соответствии с этим целью выпускной квалификационной работы является применение методов машинного обучения для определения неисправности сервопривода для управления беспилотными летательными аппаратами самолетного типа на основании акустических шумов.

Для достижения поставленной цели необходимо решить следующие задачи:

1. провести аналитический обзор литературных источников по теме исследования;
2. осуществить сбор и предварительную обработку аудиоданных, характеризующих работу сервопривода;
3. обучить модели машинного обучения, предназначенные для обнаружения аномалий;

4. обучить модели машинного обучения с использованием методов классификации;
5. провести сравнительный анализ эффективности обученных моделей;
6. разработать графический пользовательский интерфейс для системы анализа акустических сигналов.

Теоретическая значимость магистерской работы заключается в систематизации и сравнительном анализе методов классификации (логистическая регрессия, случайный лес, нейронная сеть) и методов обнаружения аномалий (изолирующий лес, одноклассовая классификация, алгоритм кластеризации (DBSCAN), локальный фактор выброса, ошибка реконструкции, автоэнкодер) применительно к задаче диагностики сервоприводов по акустическим сигналам. Выявлены достоинства и недостатки каждого подхода, определены оптимальные гиперпараметры моделей для решения поставленной задачи.

Практическая значимость работы состоит в разработке программного обеспечения «Анализатор аудиозаписей», позволяющего в автоматическом режиме определять техническое состояние сервопривода по звуку. Приложение собрано в автономный исполняемый файл, не требующий установки Python, и может быть использовано в системах технической диагностики беспилотных летательных аппаратов, на производстве при контроле качества сервоприводов, а также в сервисных центрах для первичной диагностики оборудования.

Магистерская работа состоит из введения, шести разделов, заключения, списка использованных источников из 39 наименований и 12 приложений. Общий объем работы составляет 85 страниц, из них 60 страниц — основное содержание, включая 26 рисунков и 2 таблицы.

## СОДЕРЖАНИЕ РАБОТЫ

**Первый раздел «Использование машинного обучения для выявления неполадок в оборудовании»** посвящён анализу современных методов машинного обучения, применяемых для диагностики технического состояния оборудования. Раздел состоит из следующих подразделов.

В первом подразделе рассмотрены основные понятия аномалий в контексте акустической диагностики: дано определение аномалии как отклонения акустического сигнала от эталонной нормы, описаны виды аномалий (посторонние шумы, вибрации, изменение тона или характера звука), приведена классификация методов обнаружения аномалий.

Во втором подразделе приведён обзор инструментов и технологий, используемых для разработки программных модулей диагностики. Рассмотрены языки программирования (Python), среды разработки (Google Colab), библиотеки для обработки данных и визуализации.

В третьем подразделе подробно описаны три метода классификации: логистическая регрессия (принцип построения гиперплоскости, минимизация логистической функции потерь), случайный лес (ансамбль решающих деревьев, бэггинг, случайный подбор признаков) и нейронная сеть (архитектура с полносвязными слоями, функции активации, обратное распространение ошибки). Для каждого метода приведены теоретические основы, области применения и особенности реализации применительно к анализу аудиоданных.

В четвёртом подразделе подробно описаны шесть методов обнаружения аномалий: изолирующий лес (построение случайных деревьев, изоляция аномалий через более короткие пути), одноклассовая классификация (построение гиперплоскости, отделяющей нормальные данные от начала координат), DBSCAN (кластеризация на основе плотности, выделение шумовых точек), локальный фактор выброса (оценка локальной плотности относительно соседей), ошибка реконструкции на основе PCA (проекция на главные компоненты, вычисление ошибки восстановления), автоэнкодер (сжатие и восстановление данных через нейронную сеть, ошибка реконструкции как критерий аномалии). Для каждого метода приведены теоретические основы, ключевые параметры и особенности применения. В конце раздела сформулирован вывод о целесообразности применения обоих подходов (классификации и обнаружения аномалий) для диагностики сервоприводов по акустическим сигналам.

**Второй раздел «Инструменты и технологии для разработки программного модуля»** посвящён описанию используемых библиотек и фреймворков. Раздел состоит из следующих подразделов.

В первом подразделе рассмотрены средства для обработки и анализа данных: Pandas — для работы с табличными данными (структуры DataFrame и Series, операции фильтрации и группировки); NumPy — для численных вычислений (многомерные массивы, матричные операции, преобразования Фурье); Matplotlib и Seaborn — для визуализации данных (построение графиков, тепловых карт, спектрограмм, матриц ошибок).

Во втором подразделе описаны библиотеки и фреймворки для машинного обучения: Scikit-learn (реализация классических алгоритмов, инструменты для предобработки и оценки качества); TensorFlow и Keras (построение и обучение нейронных сетей, поддержка GPU); Librosa (извлечение MFCC-признаков из аудиофайлов, построение спектрограмм); pickle и joblib (сериализация и десериализация обученных моделей); imbalanced-learn (методы борьбы с дисбалансом классов, включая SMOTE и взвешивание классов); Tkinter (создание графического пользовательского интерфейса).

В третьем подразделе описана среда для разработки и обучения моделей — Google Colab. Отмечены её преимущества: бесплатный доступ к GPU и TPU, возможность совместной работы, интеграция с Google Drive, предустановленные библиотеки для анализа данных и машинного обучения. Описаны особенности использования Colab в данном исследовании: подключение к диску, загрузка аудиофайлов, выполнение вычислительных экспериментов.

**Третий раздел «Сбор и обработка данных»** посвящён формированию исходного набора аудиоданных. Раздел состоит из следующих подразделов.

В первом подразделе описана методика записи звуков сервопривода с использованием прибора ЭКОФИЗИКА-110А. Приведены схема подключения сервопривода, условия записи (длительность 15 секунд, отсутствие посторонних шумов, поролон под микрофоном для исключения вибраций). Указано, что всего записано 1092 аудиообразца, из которых 602 исправных и 490 неисправных.

Во втором подразделе описана процедура преобразования файлов из формата EDT в WAV с использованием программы Signal+ Light. Приведены причины выбора формата WAV (непрерывное кодирование, пригодность для по-

следующей обработки в Python). Описано разделение файлов на папки wav-h (хорошие) и wav-p (плохие) для удобства присвоения меток классов.

В третьем подразделе описана разработка и реализация процедуры извлечения MFCC-признаков из звуковых файлов. Приведён код функций `extract_mfcc` (вычисление 13 MFCC-коэффициентов с усреднением по временной оси) и `analyze_frequencies` (анализ частотного спектра с вычислением статистических характеристик). Описано сохранение признаков и статистик в CSV-файлы.

В четвёртом подразделе описана предобработка данных: формирование матрицы признаков  $X$  и вектора меток  $y$ , разделение выборки на обучающую (873 образца, 80%) и тестовую (219 образцов, 20%) с сохранением стратификации, стандартизация признаков с помощью `StandardScaler` (приведение к нулевому среднему и единичной дисперсии). Приведены примеры визуализации спектрограмм и звуковых волн для исправных и неисправных образцов.

**Четвёртый раздел «Обучение моделей машинного обучения для поиска аномалий»** посвящён подбору гиперпараметров, реализации и сравнительному анализу шести методов обнаружения аномалий. Раздел состоит из следующих подразделов.

В первом подразделе описан общий подход к обучению: использование только нормальных данных для обучения ( $X_{\text{normal}} = X_{\text{scaled}}[y == 0]$ ), тестирование на всех данных. Приведена функция `evaluate` для единообразной оценки моделей с вычислением Accuracy, F1-score и матрицы ошибок.

Во втором подразделе для каждого из шести методов приведён экспериментальный подбор гиперпараметров: для изолирующего леса — параметр `contamination` (перебор от 0.05 до 0.5); для одноклассовой классификации — параметр `nu` (перебор от 0.01 до 0.3); для DBSCAN — параметр `eps` (перебор от 0.5 до 5.0); для LOF — параметр `n_neighbors` (перебор от 5 до 50); для PCA — параметр `variance` (перебор от 0.80 до 0.99); для автоэнкодера — порог обнаружения (перцентиль ошибки восстановления, перебор от 80% до 99%). Для каждого метода приведены графики зависимости F1-меры от параметров и обоснование выбора оптимальных значений.

В третьем подразделе описаны архитектуры моделей, процесс обучения и оценки качества. Для каждого метода приведён код реализации с комментариями. Подробно описан автоэнкодер: входной слой размерности 13, два кодирующих слоя (32 и 16 нейронов) с активацией ReLU, два декодирующих слоя (32

нейрона и выходной слой размерности 13) с линейной активацией, оптимизатор Adam, функция потерь MSE, ранняя остановка.

В четвёртом подразделе проведён анализ эффективности. Приведены таблицы сравнения моделей по метрикам Accuracy и F1-score. Показаны матрицы ошибок для каждой модели. Лучшие результаты показал метод локального фактора выброса (LOF) с Accuracy = 0.770 и F1 = 0.792. Высокая полнота обнаружения (recall = 0.98) делает этот метод предпочтительным для задач, где критично не пропустить дефект. Сформулированы рекомендации по выбору метода обнаружения аномалий в зависимости от требований к точности и полноте.

**Пятый раздел «Обучение моделей машинного обучения методами классификации»** посвящён подбору гиперпараметров, реализации и сравнительному анализу трёх методов классификации. Раздел состоит из следующих подразделов.

В первом подразделе описан общий подход: преобразование данных в массивы NumPy, разделение на обучающую (873 образца) и тестовую (219 образцов) выборки со стратификацией, стандартизация признаков.

Во втором подразделе для логистической регрессии проведён подбор гиперпараметра `max_iter` (перебор от 50 до 2000). Экспериментально установлено, что сходимость достигается уже при 50 итерациях, выбрано значение 1000 для гарантии. Приведены два варианта модели: базовая и с параметром `class_weight='balanced'`.

В третьем подразделе для случайного леса проведён подбор гиперпараметра `n_estimators` (перебор от 10 до 300). Наилучший результат достигнут при 10 деревьях (F1 = 0.9524), выбрано значение 10. Приведены два варианта модели: `RandomForestClassifier` и `BalancedRandomForestClassifier`.

В четвёртом подразделе для нейронной сети описана архитектура: входной слой размерности 13, два полносвязных слоя (64 и 32 нейрона) с активацией ReLU и dropout-регуляризацией (0.2), выходной слой с сигмоидной активацией. Проведён подбор гиперпараметра `dropout` (перебор от 0.0 до 0.5), оптимальным выбрано значение 0.2. Приведены два варианта обучения: базовая модель и модель с взвешиванием классов (вес миноритарного класса рассчитан как отношение числа исправных к числу неисправных образцов).

В пятом подразделе проведён анализ эффективности моделей классификации. Приведены таблицы сравнения метрик (Accuracy, F1, ROC AUC, PR

AUC) и матрицы ошибок. Наилучшие результаты показал случайный лес (RF) с параметром  $n\_estimators = 10$ , обеспечивающий Accuracy = 0.959 и F1 = 0.952. Сбалансированная версия случайного леса показала сопоставимые результаты (F1 = 0.953). Сформулированы рекомендации по выбору метода классификации в зависимости от доступности размеченных данных и требований к интерпретируемости модели.

**Шестой раздел «Разработка графического пользовательского интерфейса для системы анализа акустических сигналов»** посвящён созданию приложения «Анализатор аудиозаписей». Раздел состоит из следующих подразделов.

В первом подразделе описана общая концепция приложения: оно предназначено для загрузки аудиофайлов, извлечения MFCC-признаков, классификации состояния сервопривода с использованием обученной модели случайного леса и визуализации результатов. Приложение реализовано на Python с использованием библиотек Tkinter, Matplotlib и Librosa.

Во втором подразделе описана сборка приложения в автономный EXE-файл с помощью PyInstaller. Приведена команда сборки с параметрами: `–onefile` (единный файл), `–windowed` (без консоли), `–add-data` (включение папки `saved_models`), `–hidden-import` (явное указание скрытых модулей `scikit-learn`). Отмечено, что это позволяет запускать программу на любом компьютере под управлением Windows без установки Python.

В третьем подразделе приведена диаграмма взаимодействия компонентов, отражающая архитектуру системы. Описаны все компоненты: пользователь, графический интерфейс, контроллер (класс `AudioAnalyzerApp`), поток анализа, загрузчики моделей, библиотеки, внешние ресурсы. Пояснена последовательность обработки данных и использование многопоточности для сохранения отзывчивости интерфейса.

В четвёртом подразделе подробно описаны модули приложения: модуль загрузки данных (выбор файла, отображение информации: имя, частота дискретизации, длительность, количество сэмплов, максимальная амплитуда); модуль загрузки модели (десериализация модели случайного леса, стандартизатора и метаданных из директории `saved_models`); модуль извлечения признаков (вычисление MFCC-коэффициентов, усреднение по времени, масштабирование); модуль классификации (предсказание класса, вычисление вероятностей, оцен-

ка уверенности); модуль визуализации (построение графиков на четырёх вкладках).

В пятом подразделе описана структура пользовательского интерфейса: главное окно с панелью выбора файла, областью информации о файле, панелью результатов (вердикт, вероятности, детальная информация), областью визуализации в виде многостраничного блокнота с четырьмя вкладками (звуковая волна, спектрограмма, MFCC-коэффициенты, график вероятностей) и строкой состояния.

В шестом подразделе описана реализация многопоточности: основной поток обрабатывает события GUI, отдельный поток анализа выполняет вычислительные операции, результаты передаются через метод `after`. Приведён код запуска потока.

В седьмом подразделе описаны три типа визуализации аудиосигнала: звуковая волна (график амплитуды от времени), спектрограмма (распределение энергии по частотам и времени с цветовой шкалой), MFCC-коэффициенты (тепловая карта мел-кепстральных коэффициентов). Для каждого типа приведён код построения.

В восьмом подразделе описана визуализация результатов классификации: столбчатая диаграмма вероятностей для классов «ИСПРАВНО» и «НЕИСПРАВНО» с пороговой линией 0.5. Приведён код построения графика.

В девятом подразделе перечислены функциональные возможности приложения и сформулированы выводы о его практической ценности.

## ЗАКЛЮЧЕНИЕ

В результате выполнения выпускной квалификационной работы были применены методы машинного обучения для определения неисправности сервопривода для управления беспилотными летательными аппаратами самолетного типа на основании акустических шумов. Проведенное исследование подтверждает, что автоматизация процессов анализа данных, ранняя диагностика и минимизация простоев делают методы машинного обучения актуальными для современных промышленных систем и беспилотных летательных аппаратов. Анализ отечественных и зарубежных источников показал, что машинное обучение является ключевым инструментом для решения задач диагностики и прогнозирования отказов.

В ходе выполнения работы полностью решены все поставленные задачи:

1. проведен аналитический обзор литературных источников, систематизированы существующие подходы к диагностике оборудования методами машинного обучения;
2. осуществлен сбор и предварительная обработка аудиоданных, сформирован размеченный набор данных из 1092 записей (602 исправных и 490 неисправных образцов), выполнено извлечение MFCC-признаков;
3. обучены модели обнаружения аномалий (Isolation Forest, One-Class SVM, DBSCAN, LOF, PCA Reconstruction, Autoencoder) на нормальных данных;
4. обучены модели классификации (логистическая регрессия, случайный лес, нейронная сеть) с применением методов балансировки классов;
5. проведен сравнительный анализ эффективности моделей;
6. разработан графический пользовательский интерфейс для системы анализа акустических сигналов, реализующий загрузку файлов, извлечение признаков, классификацию и визуализацию результатов.

Среди шести рассмотренных методов поиска аномалий (Isolation Forest, One-Class SVM, DBSCAN, Local Outlier Factor, PCA Reconstruction, Autoencoder) наилучшие сбалансированные результаты показал Local Outlier Factor с параметрами  $n\_neighbors = 5$  и  $contamination = 0.5$ , обеспечивающий Accuracy = 0.770 и F1 = 0.792. Метод демонстрирует высокую полноту обнаружения неисправностей ( $recall = 0.98$ ), что критически важно для задач диагностики.

Все рассмотренные модели бинарной классификации (логистическая регрессия, случайный лес, нейронная сеть) продемонстрировали высокую эффек-

тивность, что свидетельствует о хорошей разделимости классов в пространстве извлеченных MFCC-признаков. Наилучшие результаты достигнуты моделью случайного леса (RF) с параметром `n_estimators = 10` (выбранным по результатам экспериментального подбора), которая обеспечивает точность 0.959 и F1-меру 0.952.

Рекомендованной моделью для использования в системах диагностики сервоприводов при наличии размеченной обучающей выборки является случайный лес.

Результаты исследования были представлены на 52-й Международной молодежной научной конференции (Московский авиационный институт, 14–17 апреля 2026 г.), где работа заняла второе место в секции «Разработка программных систем, машинное обучение и искусственный интеллект». Основные результаты изложены в статье «Применение методов машинного обучения для поиска аномалий в аудиоданных эксплуатируемого сервопривода авиационного назначения», принятой к публикации в электронном научном журнале «Математическое моделирование, компьютерный и натурный эксперимент в естественных науках». Также основные результаты работы были доложены на факультетской студенческой научной конференции. Разработанный графический пользовательский интерфейс для системы анализа акустических сигналов прошел практическую апробацию на реальных образцах сервоприводов и может быть использован в системах технической диагностики.