

## СЕКЦИЯ 12

### ИНФОРМАЦИОННОЕ И ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ СИСТЕМ УПРАВЛЕНИЯ КРУПНОМАСШТАБНЫМИ ПРОИЗВОДСТВАМИ

---

#### АВТОМАТИЗИРОВАННЫЙ ПОИСК МЕТОДА ОБНАРУЖЕНИЯ АНОМАЛИЙ ДЛЯ ДИАГНОСТИКИ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ЭЛЕКТРОМЕХАНИЧЕСКОГО ПРИВОДА<sup>1</sup>

Авхименко Г.М.

*Институт проблем управления им. В.А. Трапезникова РАН, Москва, Россия*  
grg9000k@mail.ru

*Аннотация. Научная работа описывает подход к оптимизации и синтезу алгоритма машинного обучения для диагностики технического состояния электропривода беспилотного летательного аппарата самолётного типа. Описана постановка задачи машинного обучения и оптимизации гиперпараметров. Приведено описание процесса извлечения признаков с применением вейвлет-преобразования и статистических показателей.*

*Ключевые слова: обнаружение аномалий, диагностика электроприводов, беспилотный летательный аппарат, оптимизация гиперпараметров.*

#### **Введение**

На протяжении последних лет беспилотные летательные аппараты прочно вошли в жизнь человечества. Они используются в разных областях: доставке грузов, сельскохозяйственных работах, в охране правопорядка и военной области.

Неисправности приводов на поверхностях управления, таких как элероны, рули высоты и штурвалы направления, могут вызывать риск системных сбоев и стать причиной аварии. Таким образом, эффективное и точное обнаружение неисправностей имеет решающее значение для повышения надежности и безопасности полётов беспилотных летательных аппаратов.

Для своевременного обнаружения неисправностей используется показания, снимаемые с датчиков. Для диагностики применяются различные методы: модельные методы и методы, основанные на данных.

Модельные методы моделируют поведение диагностируемой системы при помощи параметрических моделей, систем дифференциальных уравнений и т.д. Неисправность при таком подходе обнаруживается путём анализа отклонений параметров модели от показателей датчиков.

Второй способ, основанный на данных, это применение методов машинного обучения. Такие методы разделяются на два класса: методы обучения с учителем и методы обучения без учителя.

Методы обучения с учителем, являются алгоритмами классификации. На этапе обучения Они получают на вход множество объектов и множество правильных ответов. В данном случае множество ответов содержит конечный набор классов технического состояния электропривода. Недостаток этого метода заключается в том, что механизм может иметь обширное количество неисправностей, которые невозможно получить на этапе сбора данных.

Подход обучения без учителя заключается в обучении только на данных нормального технического состояния. В терминологии машинного обучения - это называется задачей обнаружения новизны или обнаружения аномалий. Обученный на нормальных данных метод может отнести новый образец к двум классам нормальный или аномальный. При обучении и разработке метода следует сосредоточить внимание на том, чтобы метод обнаружения аномалий как можно лучше изучил нормальные данные для отделения их от аномальных. Такой подход к диагностике нашёл широкое применение в диагностике технического состояния различных устройств: станков с числовым программным управлением [1], газовых турбин [2], подводных роботов [3], беспилотных летательных аппаратов [4, 5].

В данной работе описан автоматизированный процесс поиска метода обнаружения аномалий для диагностики состояния рулевого электропривода беспилотного летательного аппарата.

---

<sup>1</sup> Исследование частично выполнено за счет гранта Российского научного фонда (проект № 23-19-00464).

## 1. Описание данных

Набор данных для исследования получен в результате работы математической модели электропривода. Детальное описание модели приведено в работе [6]. Модель имитирует работу электропривода рулевой поверхности хвостовой части. Она способна описывать физические процессы, происходящие в электроприводе с учётом заданной траектории полёта, некоторых воздействующих погодных условий и физических параметров самого механизма.

Перед проведением моделирования нужно установить шесть параметров:

- Люфт соединительной муфты ротора двигателя и выходного вала. Параметр определяет зазор в соединительной муфте.
- Момент сухого трения. Это момент силы, который препятствует вращению двигателя в любом направлении.
- Коэффициент вязкого трения. Коэффициент связан с моментом вязкого трения, который пропорционален скорости вращения. Этот момент силы уменьшает момент сухого трения. То есть высокий коэффициент способствует меньшему моменту сопротивления вращению.
- Напряжение питания.
- Температура окружающей среды.
- Момент нагрузки. Параметр влияет на момент силы, прилагаемой к рулевой поверхности.

После задания шести параметров в модель подаётся управляющий сигнал траектории полёта. На выходе получают двенадцатимерный временной ряд, это снимаемые параметры:

- Управляющий сигнал. Задаёт траекторию движения выходного вала.
- Угол поворота ротора. Описывает положение вала ротора электродвигателя.
- Угол выходного вала. Описывает положение выходного вала электропривода. Оно отличается от угла поворота ротора.
- Сила тока питания.
- Напряжение питания.
- Мощность тока питания.
- Скорость вращения ротора электродвигателя.
- Крутящий момент ротора электродвигателя.
- Мощность ротора электродвигателя.
- Скорость вращения выходного вала.
- Крутящий момент выходного вала.
- Мощность выходного вала.

На (рис. 1) показан пример многомерного временного ряда, полученный в результате одного сеанса моделирования. Приведено первые четыре показателя.

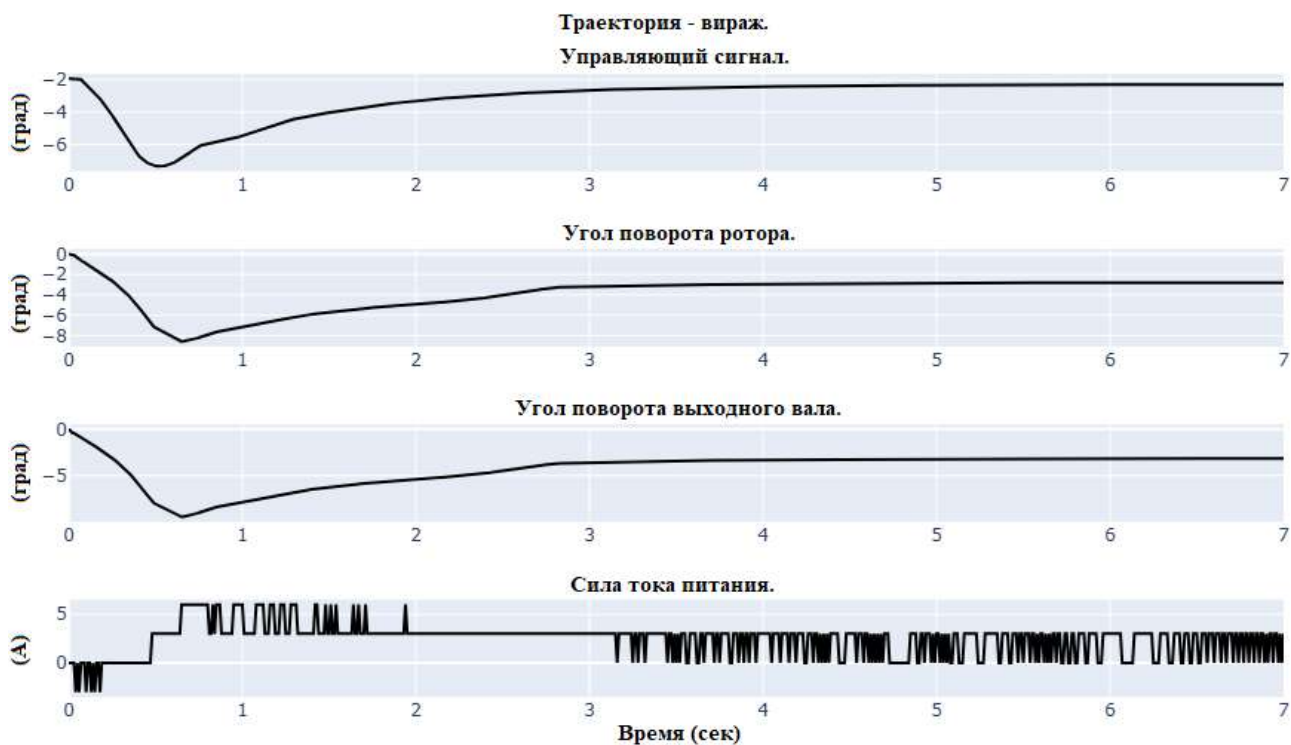


Рис. 1. Первые четыре показателя одного из сеансов моделирования

В следующем разделе будут кратко описаны использованные в работе методы обнаружения аномалий.

## **2. Описание методов обнаружения аномалий**

В этом разделе приведено описание алгоритмов выявления аномалий, использованных в исследовании.

Одноклассовый метод опорных векторов – это метод, основанный на принципах опорных векторов, используемый для обнаружения аномалий в данных, где обычные наблюдения представляют собой единственный класс. Модель обучается на положительных примерах, представляющих нормальные данные, и стремится найти границу, которая максимально отделяет эти данные от начала координат, минимизируя ошибку классификации. Принцип работы заключается в том, что модель создает гиперплоскость, которая охватывает как можно больше нормальных образцов, и любые точки, находящиеся за пределами этого пространства, считаются аномальными. Одноклассовый метод опорных векторов устойчив к выбросам и может работать в пространствах высокой размерности.

Локальный фактор выброса – это алгоритм, который оценивает степень аномалии образца на основе локальной плотности данных. Он сравнивает плотность данных в точке с плотностью ее соседей, определяя степень изоляции точки от других. Модель вычисляет оценку местного фактора выброса для каждой точки на основе расстояний до  $k$  ближайших соседей. Это позволяет выявлять точки, имеющие значительно меньшую плотность по сравнению с окружающими образцами. Одной из ключевых особенностей алгоритма является способность к обнаружению аномалий в данных с произвольной формой распределения. Это делает его полезным для глубинного анализа сложных структур.

Изолирующий лес – это ансамблевый метод, строящий множество решающих деревьев для обнаружения аномалий. Его основная идея заключается в изоляции наблюдений. Чем меньший уровень необходимо пройти, чтобы изолировать точку, тем более аномальной она воспринимается. Во время обучения алгоритм случайным образом выбирает признаки и значения разбиения, создавая большое количество деревьев. Каждая точка получает оценку на основе средней глубины, на которой она была изолирована во всех деревьях. Изолирующий лес эффективен и легко поддается масштабированию. Это делает его подходящим для работы с большими наборами данных.

Гауссовская смесь распределений – это статистическая модель, состоящая из нескольких плотностей нормального распределения, используемая для описания данных. В этом случае данные могут быть моделированы, как смесь нескольких кластеров. Одной из ключевых задач построения гауссовской смеси является оценка параметров. Она достигается с помощью алгоритма EM (англ. Expectation-Maximization) максимизации ожидания. При обучении модель изменяет параметры для максимального повышения вероятности наблюдаемых точек. Это помогает выявлять аномалии, когда точка имеет низкую вероятность принадлежности обучающей выборке. Гауссовская смесь хорошо работает с непрерывными типами данных. Также она позволяет учитывать случаи, когда аномалии могут находиться в плотных областях данных.

В следующем разделе будет описание использованных методов извлечения признаков.

## **3. Методы извлечения признаков и меры качества распознавания**

В этом разделе приведено описание применённых методов извлечения признаков из временных рядов.

### **3.1. Метод скользящего окна**

В целях создания образцов для обучения и тестирования к исходным временным рядам, длительностью 7 секунд применялся метод скользящего окна. Метод скользящего используется для анализа временных рядов и обработки последовательных данных, где окно фиксированного размера перемещается по данным для извлечения характеристик. Это позволяет захватывать локальные зависимости и тренды в данных, а также помогает в задачах обнаружения аномалий. Размер окна шаг его взятия влияет на результат в задаче обнаружения аномалий [7]. Поэтому имеет смысл провести оптимизацию ширины окна и шага его взятия.

После формирования набора образцов нужно из них извлечь признаки. Далее будут описаны способы извлечения признаков из сигнала.

### 3.2. Метод извлечения, основанный на вейвлет-преобразовании

Извлечение признаков из сигналов является ключевым этапом в процессе анализа и интерпретации данных, так как именно эти признаки позволяют эффективно характеризовать свойства сигналов и выявлять их уникальные особенности. В контексте сигналов, которые характеризуются изменяющимися частотами и амплитудами, а также не являются периодическими, необходимо применять подходы, способные захватывать их динамику. Непрерывное вейвлет-преобразование представляет собой мощный инструмент для анализа таких сигналов, так как оно обеспечивает многоуровневую декомпозицию, позволяя анализировать изменение частотного состава во времени.

Идея метода взята из работы [8], описывающей построение классификатора для распознавания ЭЭГ сигналов для нейрокомпьютерного интерфейса. Принцип работы метода показан на (рис. 2).

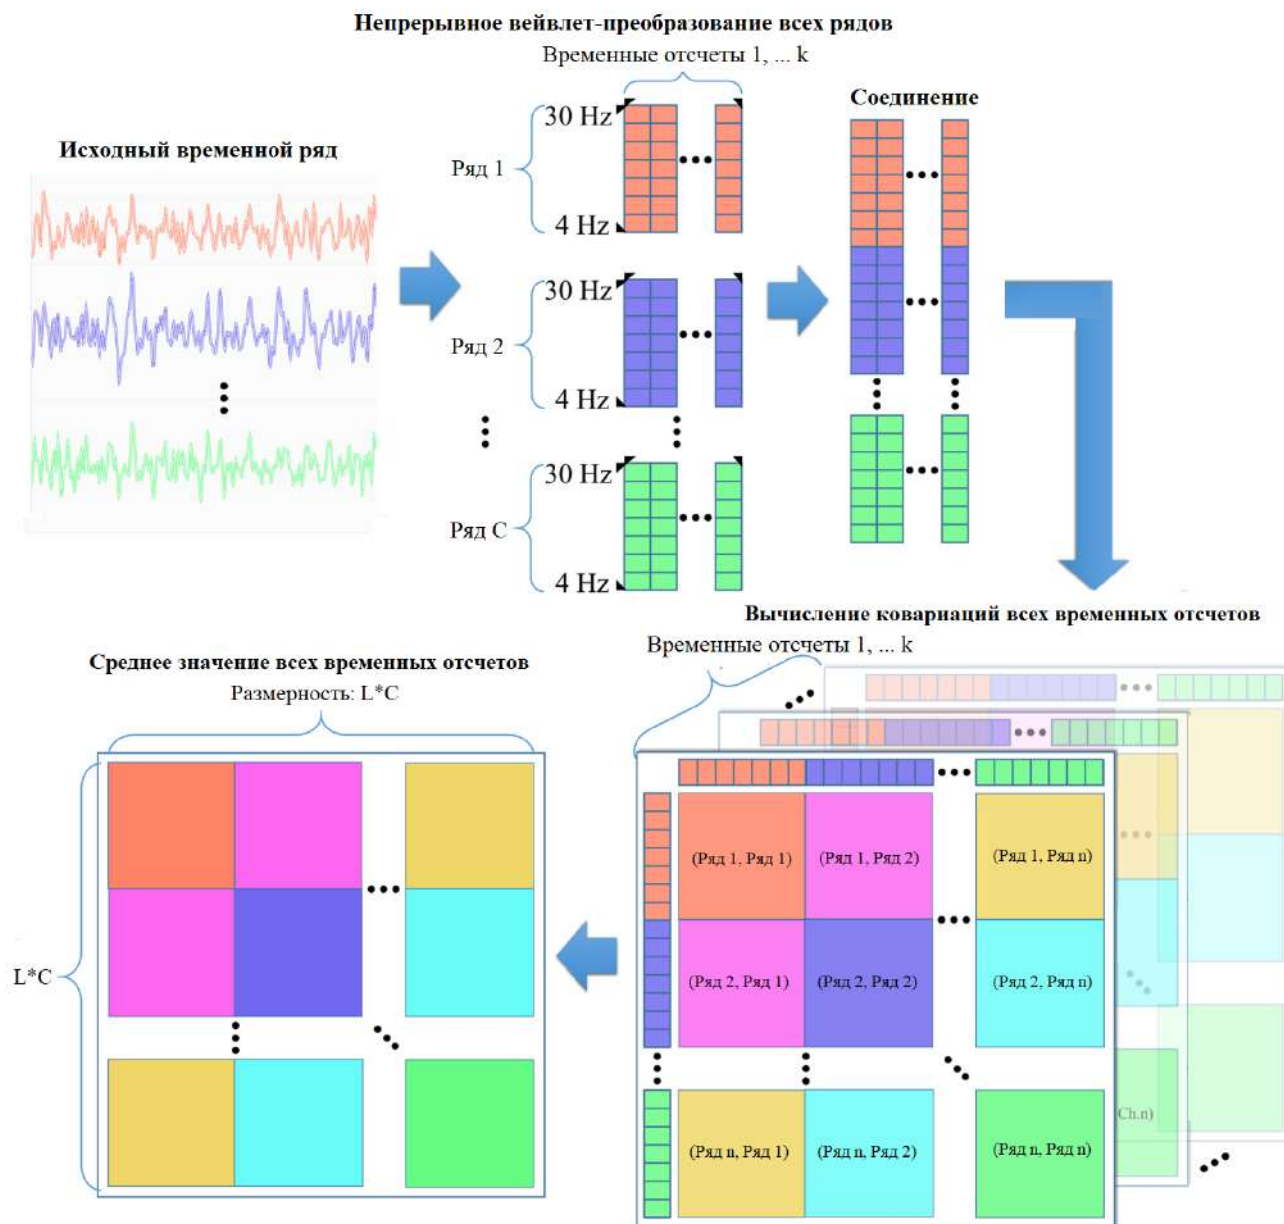


Рис. 2. Принцип работы метода извлечения признаков на основе вейвлет-преобразования

Исходный многомерный временной ряд имеет  $C$  измерений (рядов) и  $k$  временных отсчетов. При помощи непрерывного вейвлет-преобразования получают  $C$  матриц размерностью  $L$  на  $k$ , где  $L$  – количество частот в разложении сигнала. Эти матрицы соединяют в одну с размерностью  $L * C$  на  $k$ . Затем выполняется внешнее произведение столбцов матрицы, на выходе получают  $k$  матриц ковариации, как описано авторами в работе [8]. Эти матрицы отражают взаимосвязь частот в различных измерениях исходного сигнала. Наличие  $k$  таких матриц позволяет учесть эти взаимосвязи

по всех длительности сигнала. В итоге получается  $C*L*k$  признаков. В целях снижения размерности авторы предлагают брать среднее значение по оси времени, то есть рассчитать среднее по  $k$  матрица. Тогда на выходе получится  $C*L$  признаков. Это позволяет уменьшить размерность пространства и ускорить вычисления. Расчет ковариаций позволяет учитывать взаимосвязь нескольких рядов.

### 3.3. Агрегирование статистических показателей по скользящим окнам

Еще один вариант извлечения признаков заключается в вычислении статистических показателей по скользящему окну данных. В настоящем исследовании были применены следующие статистические показатели:

- Среднее арифметическое
- Медиана
- Максимальное значение

Эти показатели вычислялись по временным рядам сигнала: сила тока питания, напряжение тока питания. Это позволяет получать признаки из временной области сигнала. При операции извлечения можно брать заданные временные ряды сигнала и набор показателей.

Для извлечения признаков из углов управляющего сигнала и углов поворота вала и ротора был взят средний модель их разности. Например, средний модуль разности углов поворота вала и рота. Этот признак отражает величину люфта в соединительной муфте. А средний модуль разности угла поворота вала и управляющего сигнала может отражать изменения в траектории под воздействием различных факторов: момент сухого трения, момент внешней нагрузки и т. д.

Далее будут рассмотрены меры качества обнаружения аномалий.

### 3.4. Меры качества обнаружения аномалий

Для количественной оценки алгоритма и его способности к обнаружению аномалий использую те же метрики, что и для задачи бинарной классификации [4, 5, 6]. Это точность (Accuracy), полнота (Recall), F1-мера. Для настоящего исследования применялась мера F1, так как она способна оценить качество распознавания на несбалансированных наборах данных.

В следующем разделе будет описана постановка задачи автоматического поиска метода обнаружения аномалий, стратегия её решения, а также способ разделения данных на тренировочную и тестовую выборки.

## 4. Постановка и решение задачи автоматизированного поиска метода обнаружения аномалий

### 4.1. Постановка задачи

Задача поиска метода обнаружения аномалий ставится, как оптимизационная. Необходимо подобрать такие параметры скользящего окна, методы извлечения признаков, метод обнаружения аномалий с его гиперпараметрами, чтобы достичь максимума меры F1 на тестовой выборке. В учетом этих соображений целевая функция будет иметь вид:

$$L(A(w_{size}, w_{stride}, F_{ext}(\theta_1), \theta_2, X_{train}), X_{test}) \rightarrow \max_{w_{size}, w_{stride}, F_{ext}, \theta_1, A, \theta_2}, \quad (1)$$

где

- $L$  – целевая функция. Значение меры F1 на тестовой выборке для метода, обученного на тренировочной выборке;
- $A$  – метод обнаружения аномалий;
- $w_{size}$  – размер скользящего окна в секундах;
- $w_{stride}$  – размер шага взятия скользящего окна в секундах;
- $F_{ext}$  – методы извлечения признаков;
- $\theta_1$  – параметры для методов извлечения признаков из  $F_{ext}$ ;
- $\theta_2$  – гиперпараметры для метода  $A$ ;
- $X_{train}$  – тренировочная выборка;
- $X_{test}$  – тестовая выборка.

После определения целевой функции необходимо определить схему разделения данных на выборки разного назначения и стратегию оптимизации.

## 4.2. Схема разделения данных

Метод обнаружения аномалий обучается только на данных из нормального класса. А его тестирование производится на данных из нормального и аномального классов. Это обстоятельство вносит требует схемы проверки алгоритма, отличной от задачи бинарной классификации. В работе [3] была рассмотрена схема разделения данных на тренировочный набор, набор для промежуточного тестирования (валидационный) и тестовый для итоговой проверки. Схема разделения представлена на (рис. 3).




Рис. 3. Схема разделения данных

Тренировочный и валидационный наборы предназначены для обучения и оптимизации гиперпараметров алгоритма. Тестовый набор для итоговой оценки.

## 4.3. Стратегия решения задачи

Количество комбинаций размеров скользящего окна, шага, методов извлечения признаков и методов обнаружения аномалий с их гиперпараметрами очень велико. Предобработка временных рядов, включающая в себя создание окон и извлечение признаков из них, занимает время. Поэтому решено рассмотреть некоторый набор комбинаций из  $w_{size}$ ,  $w_{stride}$  и  $F_{ext}$ . Набор не является декартовым произведением и включает в себя методы извлечения признаков, описанные выше, в разных сочетаниях. После предобработки на выходе получены матрицы объектов и признаков и производится оптимизация гиперпараметров всех пяти алгоритмов. Процесс представлен на (рис. 4).

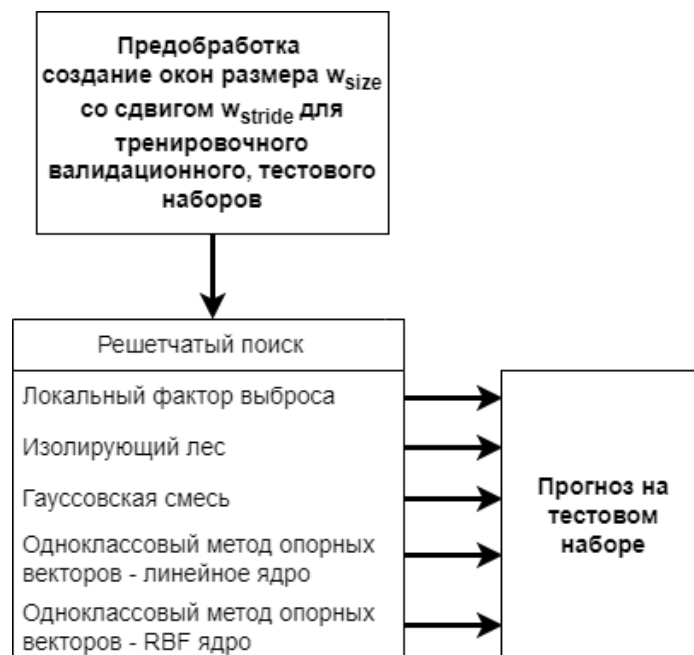


Рис. 4. Процесс поиска метода

Каждый из пяти алгоритмов оптимизируется с применением алгоритма решетчатого поиска, простоко перебора комбинаций гиперпараметров. Обучение происходит на тренировочном наборе, тестирование комбинации гиперпараметров на валидационном наборе. После этого все оптимизированные методы вырабатывают прогноз на тестовой выборке.

Далее будут рассмотрены результаты поиска метода.

#### 4.4. Результаты

В этом подразделе рассмотрены три лучших результата на тестовом наборе. Они приведены в таблице 1.

Таблица 1. Три лучших результата на тестовой выборке

| Ширина окна (сек) | Шаг окна (сек) | Извлечение признаков  | Метод             | Мера F1 |
|-------------------|----------------|---|-------------------|---------|
| 0,5               | 1              | Средний модуль разности сигналов углов (3 шт); среднее по окну для силы тока и напряжения тока (5 признаков)  | Гауссовская смесь | 0,837   |
| 0,25              | 1              | Средний модуль разности сигналов углов (3 шт); среднее по окну для силы тока и напряжения тока (5 признаков)  | Гауссовская смесь | 0,819   |
| 1                 | 1              | Средний модуль разности сигналов углов (3 шт); среднее и максимальное значение по окну для силы тока, напряжения тока, скорости вращения ротора (9 признаков) | Гауссовская смесь | 0,804   |

Из результатов следует, что лучшее качество обнаружения аномалий показал метод гауссовской смеси распределений, при размере скользящего окна в половину секунды и шаге в одну секунду — 0,837. Ширина окна в половину секунды позволила захватить локальные особенности в разные моменты времени и учесть их при обнаружении аномалий. Также, из результата следует, что добавление показателя скорости вращения ротора не дало прироста в повышении качества распознавания. Уменьшение размера окна также не гарантировало увеличение метрики.

Метод вычисления статистических показателей по скользящему окну внёс большой вклад в результаты, представленные в таблице 1. После применения этого метода матрица образцов имеет небольшой размер признакового пространства. Это позволяет методам обнаружения аномалий лучше изучить его и лучше распознавать отклонения в новых данных.

#### 5. Заключение

В настоящей работе рассмотрена задача автоматизированного поиска метода обнаружения аномалий для диагностики технического состояния электромеханического привода. Была поставлена задача оптимизации процесса предобработки данных и метода обнаружения аномалий с целью достижения высокого качества распознавания. В целом, описанный план поиска метода обнаружения аномалий и методов предобработки данных показал хороший результат распознавания неисправностей.

Дальнейшие исследования могут включать в себя следующие задачи: усовершенствование процесса оптимизации гиперпараметров алгоритмов, применение других методов извлечения признаков из сигналов, исследование поиска архитектуры нейронных сетей. Также интерес может представлять многокритериальная постановка задачи. Она может заключаться, например, в оптимизации по качеству распознавания, времени прогноза для одного образца, размера модели в памяти вычислительного устройства.

#### Литература

1. Felix Boltshauser - Degree Project - Anomaly detection for prediction of failures in manufacturing environments. <https://www.diva-portal.org/smash/get/diva2:1783647/FULLTEXT01.pdf> (дата обращения 19.02.2025).
2. Zhang Y. et al. Detection of Emerging Faults on Industrial Gas Turbines Using Extended Gaussian Mixture Models // International Journal of Rotating Machinery. – 2017. – Vol. 2017. – P. 1–31.
3. Kemp M., Raanan B. Actuator Fault-Detection for Autonomous Underwater Vehicles Using Unsupervised Learning // Proceedings of the Annual Conference of the PHM Society 2017. – St. Petersburg, 2017. – P. 1–7.
4. Erkan C.O. Vibration data-driven anomaly detection in UAVs: A deep learning approach // Engineering Science and Technology, an International Journal. – 2024. – Vol. 54. – P. 1–11.

5. *Lei Y. et al.* Spatio-temporal correlation-based multiple regression for anomaly detection and recovery of unmanned aerial vehicle flight data // *Journal of Computational Design and Engineering*. – 2024. – Vol. 11, № 2. – P. 176–193.
6. *Скрябин А.В.* Разработка методов и алгоритмов системы ранней диагностики технического состояния электромеханического рулевого привода летательного аппарата с использованием интеллектуального анализа данных. Диссертация на соискание учёной степени кандидата технических наук. <https://mai.ru/upload/iblock/a8d/6hpegsx4n6a1qzk1fzou20hmxw3ixx0y/Dissertatsiya-Skryabin.pdf> (дата обращения 14.08.2024).
7. *Chen F. et al.* Unmanned Aerial Vehicle Anomaly Detection Based on Causality-Enhanced Graph Neural Networks // *Drones*. – 2025. – Vol. 9, № 6. – P. 1–25.
8. *Liangsheng Z. et al.* Short-Time Fourier Transform Covariance and Selection, A Feature Extraction Method for Binary Motor Imagery Classification // 2021 IEEE International Conference on Real-time Computing and Robotics (RCAR). – Xining, 2021. – P. 1–6.