

СРАВНЕНИЕ ЭФФЕКТИВНОСТИ МЕТОДОВ ИЗВЛЕЧЕНИЯ ПРИЗНАКОВ В ЗАДАЧЕ РАННЕЙ ДИАГНОСТИКИ ТЕХНИЧЕСКИХ ОБЪЕКТОВ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ

Голев А.В., Московцев А.М., Петров Д.А.

Институт проблем управления им. В.А. Трапезникова РАН, Москва, Россия
oiw23@mail.ru

Аннотация. В рассматриваемом докладе поднимается задача обеспечения безопасности полета с применением различных методов диагностики и классификации технического состояния систем и узлов летательного аппарата. Основная цель доклада заключается в сравнительном анализе двух методов анализа вибрационных сигналов — быстрого преобразования Фурье и Вейвлет-преобразований — с целью оценки их эффективности при решении задачи классификации технического состояния редуктора вертолета.

Ключевые слова: интеллектуальный анализ данных, классификация, диагностика, редуктор, летательный аппарат, состояние технического объекта.

Введение

Анализ вибрационных сигналов стал востребованной областью науки и техники в последние десятилетия. Это связано с развитием потребности в методах мониторинга состояний различных механизмов и агрегатов. Мониторинг состояния производится с целью раннего обнаружения процессов, ведущих к отказу и поломке агрегатов. Такой метод позволяет оптимизировать затраты на штатное техническое обслуживание, своевременно обнаружить неисправное состояние и принять меры к его устранению.

Современные технологии и методы анализа данных играют ключевую роль в обеспечении безопасности и надежности функционирования сложных инженерных систем, таких как летательные аппараты. Особую актуальность данная проблема приобретает в контексте диагностики важных узлов, например, электродвигателей, трансмиссий или редукторов. Такие ключевые узлы являются неотъемлемыми компонентами систем управления, и их надежность влияет на безопасность полета и эффективность эксплуатации летательных аппаратов. Поэтому точная классификация их технического состояния на основе качественного анализа данных является задачей национального масштаба.

Используя опыт в области интеллектуального анализа данных и машинного обучения, можно выделить несколько методов для эффективного анализа вибрационных показателей критически важных узлов летательных аппаратов. Особый интерес представляют методы извлечения признаков — они играют важную роль в эффективности и точности систем машинного обучения. Например, эти методы могут уменьшить размерность данных для более быстрого и эффективного обучения, повысить интерпретируемость модели и уменьшать шум. Они также могут значительно повысить точность классификации, уменьшить риск переобучения и добавить вычислительную эффективность. Отобранные признаки могут быть напрямую связаны с ключевыми показателями точности классификации, что упрощает процесс принятия решений. Кроме того, хорошо подобранные признаки могут сделать модель более специализированной и универсальной, что особенно важно в критических и высокочувствительных задачах.

В работе рассматривается применение методов быстрого преобразования Фурье (БПФ) и Вейвлет-преобразований. Данные методы позволяют решить задачу классификации состояния технического объекта, но каждый из них имеет свои преимущества и недостатки. В то время как БПФ хорошо подходит для анализа стационарных сигналов, Вейвлет-преобразования выделяются способностью анализировать непостоянные или динамические состояния системы.

В свете нарастающей сложности и требований к летательным аппаратам, возникает необходимость интеграции современных методов анализа и классификации данных для более точной и своевременной диагностики технических объектов. Тогда актуальными становятся задачи:

1. Анализ и сравнение применения методов быстрого преобразования Фурье и Вейвлет-преобразований на данных с использованием критериев оценки качества моделей классификации.
2. Анализ и сравнение оценок точности решения задачи классификации технического состояния редуктора вертолета по вибрационным данным.

Таким образом, данная работа направлена на исследование и сравнение методов БПФ и Вейвлет-преобразований в контексте их применения для классификации технического состояния редуктора

вертолета. С учетом быстрого развития технологий в области машинного обучения и анализа данных, а также высоких стандартов безопасности в авиации, изучение этой проблемы представляет собой важный шаг на пути к созданию более надежных и безопасных систем диагностики.

1. Анализ исходного набора данных

Исходный набор данных для сравнения методов извлечения признаков состоит из записей данных датчика вибрации, установленного на редукторе вертолета. Эти данные представлены в формате временных рядов и были получены в ходе испытаний, в которых вертолет отрабатывал заданные циклограммы полета. В процессе этих испытаний вертолет находился в четырех различных состояниях, где изменялось состояние обработки с дополнительной нагрузкой:

- 1) исправное состояние, работа под нагрузкой;
- 2) исправное состояние, работа без нагрузки;
- 3) неисправное состояние, работа под нагрузкой;
- 4) неисправное состояние, работа без нагрузки.

Отработка четырех состояний позволяют создать комплексный набор данных, охватывающий широкий спектр рабочих условий и неисправностей, что является критически важным для анализа вибрационных характеристик и последующей классификации технического состояния редуктора.

Исходные данные эксперимента были представлены в виде четырех бинарных файлов, по файлу на каждое из испытаний. Частота опроса датчика 250 Гц. Размер каждого файла составляет 65535 записей. Примеры графиков временных записей представлены на Рис. 1, где по оси абсцисс отмечаются временные отсчеты, а по оси ординат амплитудные значения вибраций (m/s^2).

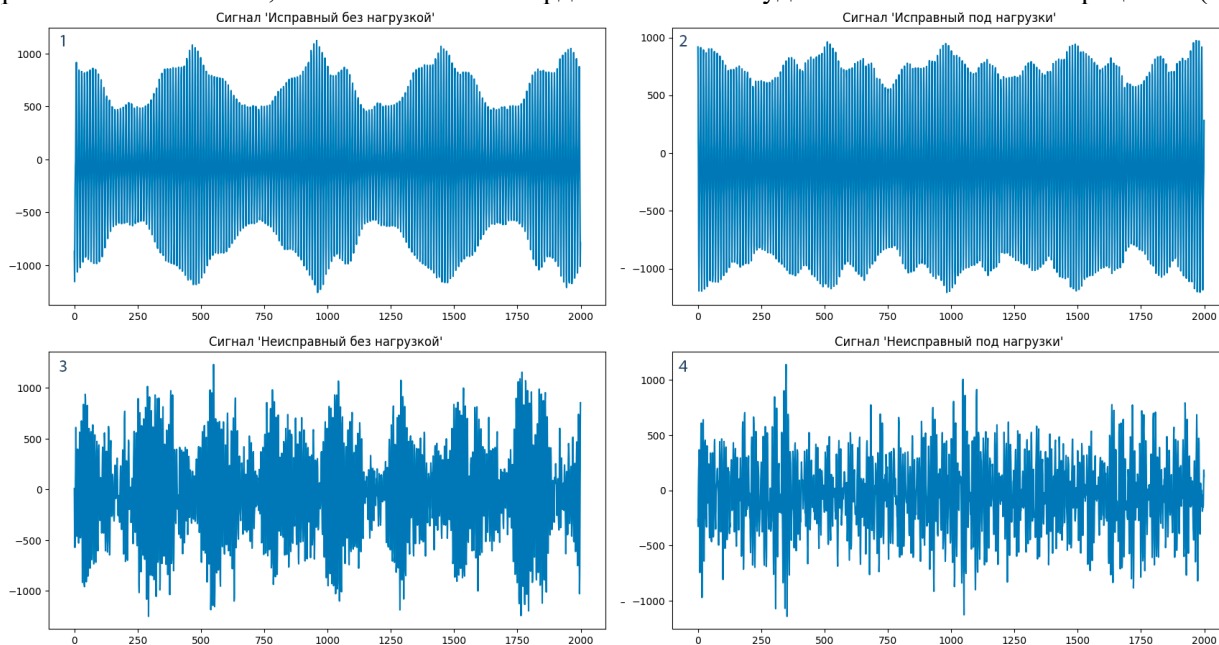


Рис. 1. Примеры показаний датчика вибраций при отработке циклограммы полета в различных состояниях (1 – сигнал исправный без нагрузки; 2 – сигнал исправный под нагрузкой; 3 – сигнал неисправный без нагрузки; 4 – сигнал неисправный под нагрузкой)

Для решения поставленных задач на Рис. 2 предлагается схема по формированию наборов данных извлеченных признаков и применению алгоритмов оценки технического состояния технического объекта. Решение задачи состоит из нескольких этапов: получение и обработка данных, создание набора векторов методами извлечения признаков, интеграция методов выделения информативных признаков и применение методов классификации.

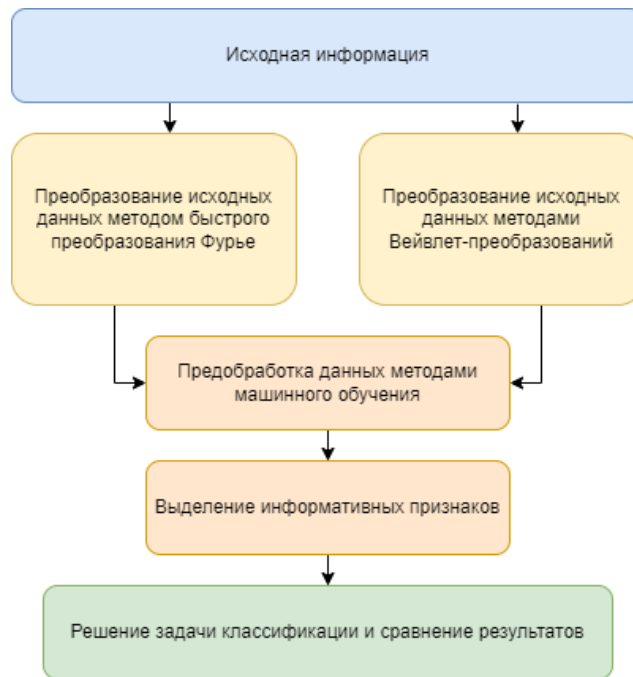


Рис. 2. Схема анализа данных для сравнения эффективности методов извлечения признаков

В процессе обработки экспериментальных данных анализируемые сигналы были представлены в виде динамических временных рядов. С использованием дополнительных преобразований были получены два набора векторов. Первый набор векторов, состоящий из амплитудных спектров Фурье, был сформирован с помощью БПФ, где каждый элемент вектора служит признаком. Второй набор векторов был создан на основе спектров вейвлетов, полученных из временного ряда с использованием Вейвлет-преобразований. Они представляет собой анализ вибрационных сигналов в пространстве частот и времени, в отличие от традиционного преобразования Фурье, которое предоставляет информацию только в частотных компонентах сигнала. Таким образом, вейвлет-анализ позволяет получить более детализированную информацию, учитывая частотные и временные характеристики сигнала. Спектры вейвлетов были рассчитаны с применением различных типов Вейвлет-преобразований, таких как вейвлет Шеннона, вейвлеты Гаусса, МНАТ-вейвлет, В-сплайн вейвлет и вейвлеты Морле [1]. Примеры сформированных наборов векторов можно увидеть на Рис. 3-4.

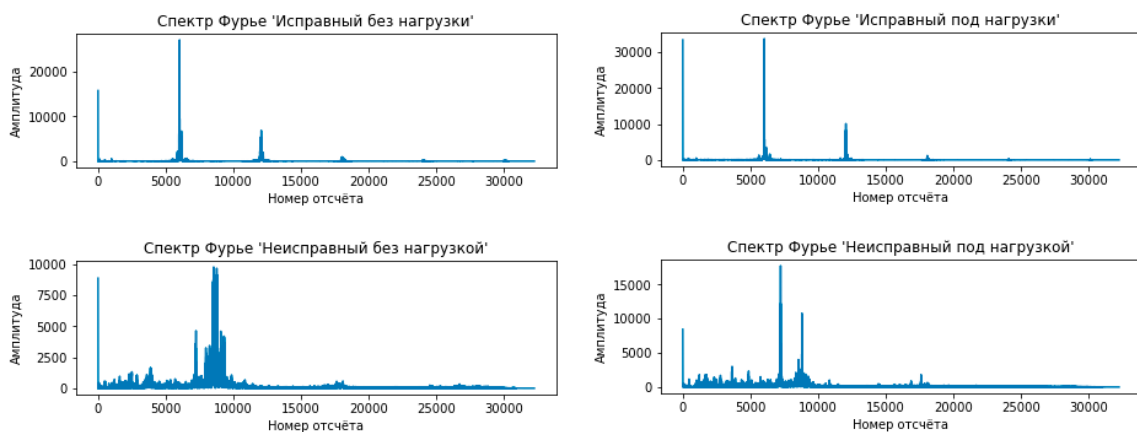


Рис. 3. Пример графиков спектров Фурье, формирующий первый набор векторов

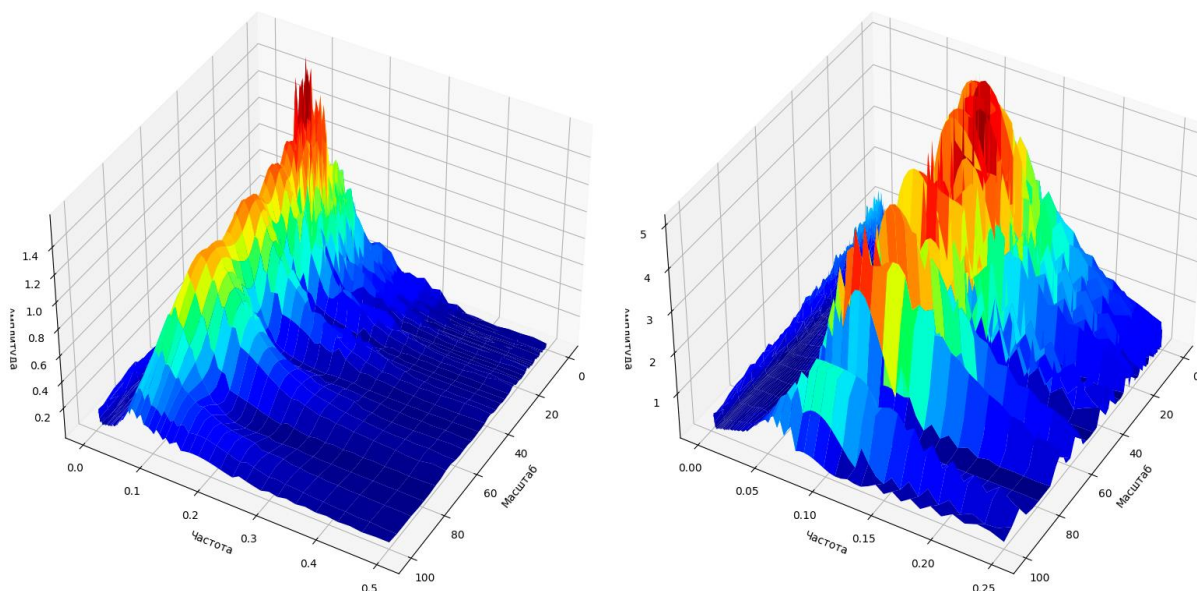


Рис. 4. Пример графиков набора спектра МНАТ-вейвлета, формирующих второй набор векторов

2. Методы отбора информативных признаков

Для ранней диагностики и классификации технического состояния редуктора вертолета были использованы алгоритмы выделения информативных признаков, базирующиеся на трех ключевых типах [2-3]:

- 1) Методы фильтрации: Information gain (IG), критерий хи-квадрат, критерий Фишера.
- 2) Оберточные методы: Прямой отбор признаков.
- 3) Встроенные методы: Случайный лес.

Применение этих методов к двум наборам данных привело к формированию множеств информативных признаков по каждому из методов. Результаты работы этих моделей представлены на диаграммах Рис. 5-6.

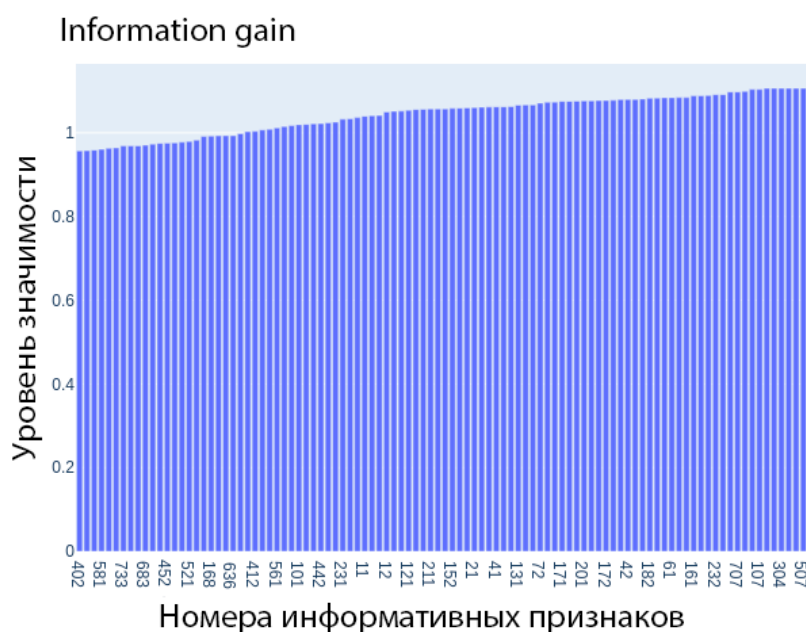


Рис. 5. Пример диаграммы уровня значимости признаков с использованием метода Information gain по набору данных, сформированному с использованием БПФ

Метод случайного леса




Рис. 6. Пример диаграммы уровня значимости признаков с использованием метода случайного леса из второго набора данных, сформированном с использованием вейвлета Гаусса 8

Дополнительно к отобраннным признакам фиксировалось время работы моделей для их сравнения (Таблица 1). Быстрее всего сработал встроенный метод случайного леса. Его время работы составило 0,125 секунды.

Таблица 1. Время работы моделей отбора информативных признаков

Название модели	Время работы по 1 набору данных (с.)	Время работы по 2 набору данных (с.)
Information Gain	7,76	58,22
Критерий Фишера	5,81	39,13
Хи-квадрат тест	5,42	34,38
Прямой отбор признаков	232,4	1147,07
Случайный лес	0,125	2,01

3. Результаты моделей классификации

Для решения задачи диагностики технического состояния редуктора вертолета использовались модели классификаций [4-6]: классификация случайным образом, метод k-ближайших соседей, логистическая регрессия, деревья решений, случайный лес. На основе отобранных множеств признаков производилось обучение с учителем, где каждый вектор признаков был отнесен к одному из двух классов состояния: исправный или неисправный.

Были получены следующие оценки точности по метрике Accuracy [7] на тестовых данных (Таблица 2). Полученные результаты на Рис.7-8 показывают, что при малом объеме выборки (от 5% до 20%) модели классификации, обученные на наборе данных спектров вейвлетов с отобранными информативными признаками, показывают высокую оценку точности классификации.

Таблица 2. Оценки точности классификации

	Быстрое преобразование Фурье	Комплексный вейвлет Морле	Вейвлет Шеннона	В-сплайн вейвлет	Комплексный вейвлет Гаусса 8	Комплексный вейвлет Гаусса 1
Случайный лес	0.995	0.997	0.998	0.997	0.994	0.997
Деревья решений	0.997	0.996	0.997	0.999	0.997	0.764
Логистическая регрессия	0.941	0.884	0.998	0.984	0.857	0.827
Метод опорных векторов	0.925-	0.887	0.995	0.992	0.936	0.769

Сравнение показывает, что точность оценок классификации при использовании Вейвлет-преобразований выше, чем с использованием БПФ при малом объеме обучающей

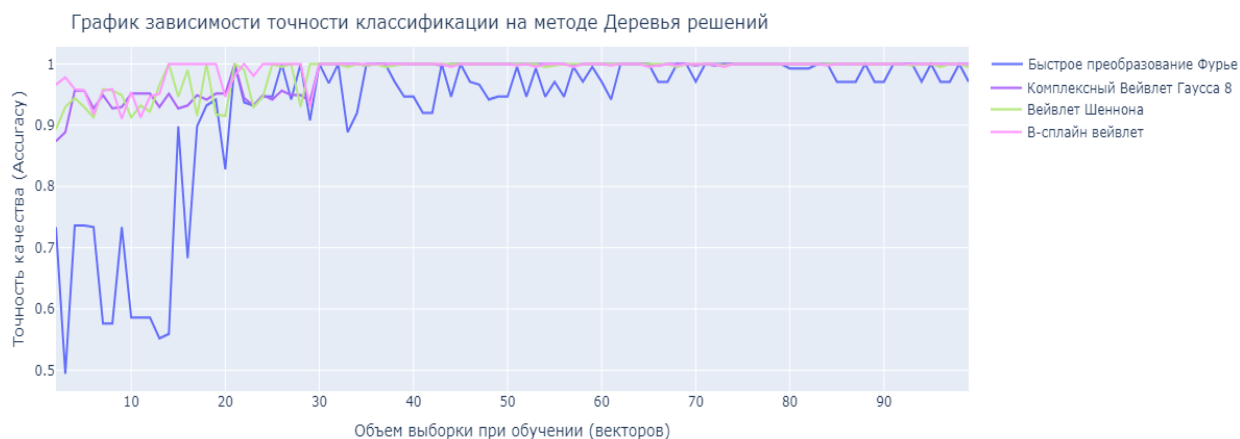


Рис. 7. График оценки точности классификации методом деревьев решений по информативным признакам, отобранном критерием случайный лес




Рис. 8. График оценки точности классификации методом случайного леса по информативным признакам, отобранном критерием хи-квадрат

4. Заключение

Выполнен анализ и сравнение эффективности методов извлечения признаков по данным, полученных от вибродатчика, установленного на редукторе вертолета. Выполнено сравнение алгоритмов выделения информативных признаков на сформированных наборах данных. Результаты проведенной работы показали, что применение методов извлечения признаков Вейвлет-преобразованиями с выделением информативных признаков в задаче диагностики с использованием методов машинного обучения может обеспечить снижение размерности исходных данных, решить проблему мультиколлинеарности и улучшить точность классификации. В частности, методы фильтрации, показывают отличную оценку точности классификации.

Данная работа показывает возможность применения методов извлечения признаков для ранней диагностики технического состояния критически важных узлов летательного аппарата. Результаты могут быть использованы для разработки более эффективных систем мониторинга и диагностики, что, в свою очередь, способствует повышению безопасности и надежности эксплуатации летательных аппаратов.

Литература

1. *Яковлев А.Н.* Введение в вейвлет-преобразования: Учеб. Пособие. // Новосибирск: Изд-во НГТУ, 2003. – 104 с. ISBN 5-7782-0405-1
2. *Мыльник В.В., Титаренко Б.П., Волочиенко В.А.* Исследование систем управления. 2-е изд., перераб. и доп. // М.: Академический Проект, 2003. – 352 с.
3. *Уоссермен Ф.* Нейрокомпьютерная техника: теория и практика: Пер. с англ. // М.: Мир, 1992. – 157 с.
4. *Rokach L.* Data Mining With Decision Trees: Theory and Applications (2nd Edition) // World Scientific Publishing Company/ 2014, P. 328
5. *He Q. P., Wang J.* Fault Detection Using the k-Nearest Neighbor Rule for Semiconductor Manufacturing Processes // IEEE Transactions On Semiconductor Manufacturing. Vol. 20. 2007, № 4.
6. *Jayadeva, Khemchandani R., Chandra S.* Twin Support Vector Machines: Models, Extensions and Applications, // Springer. 2016, P. 211.
7. *Panthong R., Srivihok A.* Wrapper Feature Subset Selection for Dimension Reduction Based on Ensemble Learning Algorithm // The Third Information Systems International Conference // Procedia Computer Science. vol. 72. 2015, P. 162-169.