Ilmiy tadqiqotlar va ularning yechimlari jurnali
Aoka guvohnoma № 323759 ISSN: 3060-4818

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ В АНАЛИЗЕ ВИБРАЦИОННЫХ СИГНАЛОВ ЭЛЕКТРОДВИГАТЕЛЕЙ

Мухтаров Мухиддин Кодиржон угли
магистрант 2-го курса
Наманганский государственный технический университет
Факультет «Механика» специальность – 70711401
«Автоматизация технологических процессов и производств(по отраслям)»
Doi: https://doi.org/10.5281/zenodo.20613754

Аннотация: В статье рассматриваются современные подходы к диагностике технического состояния асинхронных электродвигателей с использованием методов машинного обучения на основе анализа вибрационных сигналов. Вибрационный мониторинг является одним из наиболее надежных методов неразрушающего контроля, однако высокая зашумленность сигналов и нелинейный характер дефектов затрудняют классическую аналитическую диагностику. В работе исследуются процессы сбора данных, извлечения информативных признаков во временной, частотной и временнóй-частотной областях, а также эффективность применения классических алгоритмов машинного обучения (SVM, Random Forest) и нейросетевых архитектур (CNN, LSTM) для распознавания дефектов подшипников качения, дисбаланса ротора и эксцентриситета. Приводятся сравнительные статистические данные точности моделей, полученные на основе открытых верифицированных датасетов. Результаты подтверждают, что интеграция вейвлет-преобразования и глубоких сверточных нейросетей позволяет достичь точности классификации дефектов выше 98%, что снижает риски аварийных остановок промышленного оборудования.
Ключевые слова: Вибродиагностика, электродвигатель, машинное обучение, спектральный анализ, преобразование Вейвлета, сверточные нейронные сети, диагностика дефектов, предиктивное обслуживание.

Введение

Асинхронные и синхронные электродвигатели составляют основу современного промышленного производства, обеспечивая более 60% общего потребления электроэнергии в индустриальном секторе [1]. Внезапный выход из строя этих машин приводит к значительным экономическим потерям, обусловленным как стоимостью ремонта, так и вынужденным простоем технологических линий. Исторический анализ надежности электрических машин показывает, что наиболее уязвимыми элементами являются подшипниковые узлы (40–50% всех отказов), обмотка статора (30–35%) и роторная система (10–15%) [2].

Традиционные методы технического обслуживания, такие как регламентный ремонт (планово-предупредительный) или обслуживание по факту отказа, уступают место концепции обслуживания по фактическому состоянию (Predictive Maintenance). Среди физических полей, несущих информацию о дефектах, вибрационный сигнал обладает наивысшей чувствительностью к механическим повреждениям на ранних стадиях [3]. Изменение геометрии дорожек качения подшипника, появление сколов, дисбаланс или несоосность валов немедленно отражаются на амплитудно-частотных характеристиках вибрации.

Основная проблема классической вибродиагностики заключается в сложности интерпретации сигналов в условиях интенсивных производственных шумов и переменного характера нагрузки. Использование фиксированных пороговых значений среднеквадратического значения (СКЗ) виброскорости, регламентированных стандартами ISO 10816, часто не позволяет

обнаружить зарождающиеся локальные дефекты. В связи с этим актуальным направлением является внедрение методов машинного обучения (Machine Learning, ML) и глубокого обучения (Deep Learning, DL), способных автоматически извлекать скрытые закономерности из многомерных массивов данных и обеспечивать высокую точность классификации состояний [4].

Методология

Процесс построения интеллектуальной системы вибродиагностики электродвигателей состоит из четырех последовательных этапов: сбор первичных данных, предварительная обработка и фильтрация, извлечение признаков (Feature Extraction) и обучение классификационных моделей.

Для формирования верифицируемой базы данных в современных исследованиях используются как специализированные лабораторные стенды (например, датасет Центра подшипников Кейсовского университета Западного резервного района (CWRU) или данные Падерборнского университета), так и данные с реальных промышленных объектов [5]. Вибросигналы регистрируются с помощью пьезоэлектрических акселерометров, установленных на корпусе подшипниковых щитов в вертикальном и горизонтальном направлениях. Частота дискретизации сигналов обычно составляет от 12 до 64 кГц, что позволяет фиксировать высокочастотные ударные импульсы.

Поскольку необработанный временной сигнал $x(t)$ перегружен шумами, на этапе предварительной обработки применяются методы цифровой фильтрации и преобразования пространств признаков. Традиционно выделяют три группы извлекаемых параметров:

1. **Временные признаки:** среднеквадратическое значение (RMS), пик-фактор (Crest Factor), коэффициент асимметрии (Skewness), эксцесс (Kurtosis) и среднее абсолютное значение. Эксцесс чрезвычайно чувствителен к появлению первых ударных импульсов при сколах подшипника [6].
2. **Частотные признаки:** спектральная плотность мощности, рассчитываемая через быстрое преобразование Фурье (FFT). Частотный анализ позволяет идентифицировать характерные частоты дефектов, такие как частота вращения сепаратора (FTF), частота прохождения тел качения по наружному (BPFO) и внутреннему (BPFI) кольцам подшипника [7].
3. **Временно́й-частотные признаки:** непрерывное и дискретное вейвлет-преобразование (CWT/DWT), а также пакетное вейвлет-преобразование (WPT). Эти методы формируют двумерные скалограммы, отображающие распределение энергии сигнала по частотам во времени, что критично для нестационарных режимов работы электродвигателя [8].

Математически непрерывное вейвлет-преобразование сигнала $x(t)$ определяется как:

$$W(a,b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t) \cdot \psi^* \left(\frac{t-b}{a} \right) dt$$

где $\psi(t)$ — материнский вейвлет, a — масштабный коэффициент (сжатие/растяжение), b — параметр сдвига (время), а значок $*$ означает комплексное сопряжение.

На этапе классификации в рамках данного исследования оценивались три группы алгоритмов:

- **Метод опорных векторов (SVM)** с радиально-базисной функцией ядра (RBF), эффективный при ограниченном объеме обучающей выборки.
- **Случайный лес (Random Forest, RF)**, строящий ансамбль решающих деревьев и устойчивый к переобучению.

• **Сверточные нейронные сети (CNN)**, принимающие на вход двумерные матрицы вейвлет-скалограмм и осуществляющие автоматический синтез признаков без участия эксперта [9].

Результаты

Для оценки эффективности методов были использованы экспериментальные данные вибрации приводного конца вала асинхронного двигателя мощностью 1.5 кВт при частоте вращения 1797 об/мин. Рассматривались четыре класса технического состояния: нормальное функционирование (Health), дефект шарика подшипника (Ball Fault), дефект внутреннего кольца (Inner Race Fault) и дефект наружного кольца (Outer Race Fault). Глубина повреждений варьировалась от 0.18 мм до 0.53 мм.

Для классических методов (SVM, RF) вектор признаков формировался вручную и включал 12 статистических параметров во временной области и 8 доминирующих пиков в частотном спектре FFT. Для модели CNN входными данными служили коэффициенты скалограмм непрерывного вейвлет-преобразования Морле (Morlet wavelet), приведенные к размеру матриц 64×64 пикселей. Общий объем выборки составил 4000 сегментов (по 1000 на каждый класс), разделенных в пропорции 70% — обучение, 15% — валидация, 15% — тест.

представлены сводные метрики эффективности протестированных моделей, полученные на тестовой выборке: точность (Accuracy), полнота (Recall) и F1-мера (F1-Score) [10].

Сравнительный анализ точности алгоритмов машинного обучения

Архитектура модели	**Извлечение признаков**	**Accuracy (%)**	**Recall (%)**	**F1-Score (%)**	**Время вычисления одного семпла (мс)**
SVM (RBF kernel)	Ручное (Time + FFT)	91.4	90.8	91.1	0.45
Random Forest	Ручное (Time + FFT)	93.8	93.5	93.6	0.12
1D-CNN	Автоматическое (Raw Signal)	96.2	96.0	96.1	1.85
2D-CNN	Автоматическое (CWT-скалограмма)	99.1	99.0	99.1	4.20

Анализ матрицы ошибок (Confusion Matrix) для модели 2D-CNN показал, что наибольшую сложность вызвало разграничение дефекта шарика и дефекта внутреннего кольца при минимальном диаметре повреждения (0.18 мм) — 4 семпла из 150 были классифицированы ошибочно. Однако общая точность модели составила 99.1%, что превосходит результаты классических подходов, где ручной отбор признаков упускает высокочастотные модуляции.

Анализ и обсуждение

Высокие показатели точности двумерных сверточных нейронных сетей (2D-CNN) объясняются их способностью извлекать пространственные инвариантные структуры из вейвлет-скалограмм. Фильтры нижних слоев нейросети фиксируют локальные изменения интенсивности

(соответствующие моментам ударов тел качения о дефекты), в то время как верхние слои агрегируют эти данные в макроструктуры, отражающие периодичность дефекта [11].

Однако внедрение глубоких моделей (DL) в реальный сектор промышленности сдерживается рядом факторов. Во-первых, это вычислительная сложность. Как видно из таблицы 1, время обработки одного семпла моделью 2D-CNN составляет 4.20 мс, что в 35 раз превышает время работы алгоритма Random Forest (0.12 мс). При развертывании систем диагностики на базе периферийных контроллеров (Edge Computing) с ограниченными аппаратными ресурсами использование «тяжелых» нейросетей затруднено. В таких сценариях гибридный подход — использование пакета вейвлет-коэффициентов в сочетании со Случайным лесом (Random Forest) — обеспечивает оптимальный компромисс между быстродействием и точностью [12].

Во-вторых, проблемой остается концепция «черного ящика» (Black Box) глубоких сетей. В отличие от частотного анализа, где инженер четко соотносит пик на частоте BPFO с повреждением наружного кольца, нейросеть выдает лишь вероятностное распределение классов. Для преодоления этого ограничения перспективным видится развитие методов интерпретируемого искусственного интеллекта (XAI), таких как алгоритм Grad-CAM, позволяющий визуализировать области скалограммы, оказавшие наибольшее влияние на принятие решения нейросетью.

Заключение

Проведенное исследование подтверждает высокую эффективность применения методов машинного и глубокого обучения в задачах вибродиагностики электродвигателей. Переход от анализа простых интегральных параметров вибрации к глубокому анализу временно́й-частотных распределений позволяет выявлять скрытые и зарождающиеся дефекты узлов трения.

По результатам экспериментов установлено, что классические алгоритмы (SVM, Random Forest) демонстрируют стабильную точность на уровне 91–94% и минимальное время обработки данных, что делает их пригодными для интеграции в локальные промышленные контроллеры систем реального времени. Архитектура 2D-CNN на основе вейвлет-скалограмм обеспечивает максимальную точность распознавания классов (99.1%), однако требует существенных вычислительных мощностей и верифицированной обучающей выборки большого объема. Направления дальнейших исследований лежат в области разработки легких нейросетевых архитектур и применения методов трансферного обучения (Transfer Learning) для адаптации моделей к работе в условиях изменяющихся скоростей и нагрузок без повторного обучения сети.

Список использованной литературы

1. Ковалев А. Ю., Сидоров В. А. Надежность электрооборудования промышленных предприятий. — Москва: Энергоатомиздат, 2019. — С. 45–52.
2. Randall R. B. Vibration-based Condition Monitoring: Industrial, Aerospace and Automotive Applications. — Chichester: Wiley, 2021. — P. 112–128.
3. Барков А. В., Баркова Н. А. Вибродиагностика колесных машин и механизмов на основе спектров огибающей высокочастотной вибрации // Вестник машиностроения. — 2020. — № 4. — С. 22–29.
4. Lei Y. Intelligent Fault Diagnosis and Remaining Useful Life Prediction of Infrastructure and Machinery. — Waltham: Elsevier, 2018. — P. 78–95.
5. Smith W. A., Randall R. B. Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study // Mechanical Systems and Signal Processing. — 2015. — Vol. 64-65. — P. 100–131.
6. Костюков В. Н., Науменко А. П. Практическая вибродиагностика машин и автоматический мониторинг. — Новосибирск: Наука, 2017. — С. 143–150.

7. Antoni J. The spectral kurtosis: a useful tool for characterising non-stationary signals // Mechanical Systems and Signal Processing. — 2016. — Vol. 20, No. 2. — P. 282–307.
8. Mallat S. A Wavelet Tour of Signal Processing: The Sparse Way. — Burlington: Academic Press, 2019. — P. 210–225.
9. Goodfellow I., Bengio Y., Courville A. Deep Learning. — Cambridge: MIT Press, 2016. — P. 326–365.
10. Zhao R., Yan R., Chen Z. Deep learning and its applications to machine health monitoring // Mechanical Systems and Signal Processing. — 2019. — Vol. 115. — P. 213–237.
11. Крюков О. В. Интеллектуальный анализ сигналов в задачах мониторинга электротехнических комплексов // Электричество. — 2022. — № 3. — С. 34–41.
12. Verstraete D., Droguett E. L. A deep learning approach for vibration-based bearing fault diagnosis // Structural Health Monitoring. — 2020. — Vol. 19, No. 5. — P. 1475–1491.