

УДК 004.852

DOI: 10.22213/2410-9304-2025-4-86-92

Интерпретируемая диагностика механических неисправностей асинхронного электропривода по токовым признакам с использованием методов машинного обучения

П. А. Санников, аспирант, ИжГТУ имени М. Т. Калашникова, Ижевск, Россия

П. В. Лекомцев, кандидат технических наук, доцент, ИжГТУ имени М. Т. Калашникова, Ижевск, Россия

В работе рассматривается подход к диагностике механических неисправностей асинхронного электропривода на основе анализа фазных токов. Экспериментальные данные получены на стенде для испытания асинхронного электропривода при двух режимах работы – на холостом ходу и с нагрузкой 0,5 от номинальной и двумя видами технического состояния: исправное, неисправное с дефектом «несоосность подключенной нагрузки», неисправное с дефектом «изношенный подшипник». Предварительная обработка сигналов включала фильтрацию, выделение огибающей и нормализацию. Из исходных сигналов токов извлекались статистические признаки, такие как среднее квадратическое значение, коэффициенты эксцесса и асимметрии, отражающие изменение формы и распределения сигнала при возникновении дефектов. Дополнительно из огибающих вычислялись спектральные характеристики и интегральные показатели, описывающие относительный вклад гармонических составляющих и основной гармоники, что позволило учесть особенности модуляции сигнала при различных неисправностях. На основе сформированных признаков обучена модель классификации на основе метода случайного леса (Random Forest, RF), показавшая среднюю точность 85 % при кросс-валидации. Проведен анализ важности признаков с использованием метода SHAP (Shapley Additive exPlanations), а также интерпретация их физического смысла, что позволило установить связь отдельных признаков с типами механических неисправностей и подтвердить обоснованность выбранных диагностических показателей. Полученные результаты подтвердили возможность эффективного применения классического алгоритма машинного обучения Random Forest для диагностики механических дефектов электропривода, позволили выделить набор признаков, наиболее чувствительных к изменению его технического состояния, и могут быть использованы при разработке систем мониторинга и оценки состояния оборудования.

Ключевые слова: машинное обучение, разработка признаков, техническая диагностика, электропривод, метод случайного леса, интерпретация модели, метод SHAP.

Введение

Асинхронные двигатели находят широкое применение в различных отраслях промышленности, таких как металлургия, нефтехимия, водоснабжение, транспорт и производство. Несмотря на высокую надежность, асинхронные двигатели подвержены различным неисправностям.

Наиболее распространенной причиной отказов являются повреждения подшипников, на долю которых приходится до половины всех случаев отказа электродвигателей [1]. Кроме того, встречаются электрические неисправности (межвитковые замыкания, пробой изоляции, обрыв фазы и т. д.), а также механические (дисбаланс, перекос оси ротора и подключаемой нагрузки и т. д.) и нарушения в питающей сети.

Эти неисправности могут привести к простою производства, снижению качества продукции и значительным финансовым потерям. В связи с этим особое значение приобретает применение современных и эффективных методов мониторинга состояния, позволяющих своевременно выявлять и диагностировать неисправности асинхронного электропривода.

Методы диагностики электроприводов условно делятся на модельно-ориентированные и основанные на данных [2]. Первые требуют знания параметров и структуры системы, что ограничивает их применение в промышленности. Вторые используют эксперимен-

тальные данные и алгоритмы машинного обучения, обеспечивая гибкость и возможность автоматического распознавания неисправностей.

В задачах мониторинга и диагностики состояния электроприводов наибольшее распространение получили анализ вибрационных сигналов и фазных токов [3]. Вибрационные данные традиционно применяются для выявления механических неисправностей, тогда как токовые сигналы позволяют диагностировать как электрические, так и косвенно – механические дефекты, отражающиеся на электромагнитных процессах [4].

Для повышения эффективности и интерпретируемости моделей диагностики применяется отбор информативных признаков, позволяющий исключить избыточные параметры. В качестве методов отбора и оценки значимости признаков используются порог дисперсии, анализ корреляции, метод главных компонент (PCA), а также современные подходы интерпретации – MDI, Permutation Importance и SHAP [5–8].

После формирования оптимального набора признаков осуществляется построение модели классификации, предназначенной для распознавания состояния электропривода. В задачах технической диагностики применяются как классические алгоритмы машинного обучения, так и современные методы глубокого обучения. Наибольшее распространение получили метод случайного леса (Random Forest),

метод опорных векторов (*Support Vector Machine*), метод ближайших соседей (*k-Nearest Neighbors*) и различные модификации нейронных сетей [9]. Выбор конкретного подхода определяется особенностями исходных данных, объемом выборки и требованиями к интерпретируемости модели.

Цель данной работы – оценить возможности диагностики механических неисправностей асинхронного электропривода путем анализа фазных токов. Экспериментальные данные, представляющие собой временные ряды фазных токов в разных режимах работы и при различных неисправностях, были получены на экспериментальном стенде. В работе описан процесс их обработки, а также формирования информативных признаков в двух областях: временной и частотной. На основе извлеченных признаков была обучена модель классического машинного обучения *Random Forest* и проведена оценка точности ее классификации по основным метрикам. В работе также выполнен анализ важности признаков с использованием метода *SHAP*. Проведена работа по интерпретации физического смысла информативных признаков, что позволило установить их связь с типами механических неисправностей и подтвердить обоснованность выбранных диагностических показателей.

Методика эксперимента

Исходные данные для исследования были получены с использованием ранее разработанного экспериментального стенда [10], внешний вид и структурная схема которого приведены на рис. 1, а и б соответственно.

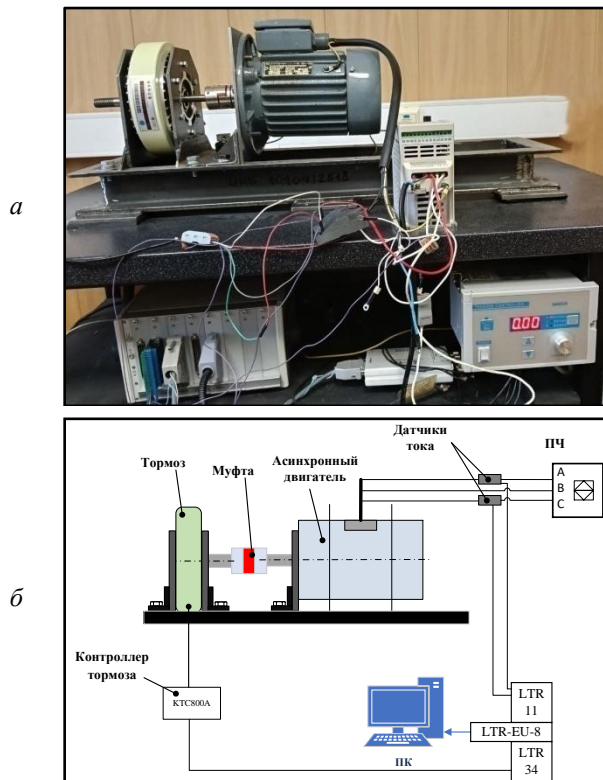


Рис. 1. Внешний вид (а) и структурная схема (б) стендового оборудования для исследования асинхронного двигателя

Fig. 1. Test bench equipment for induction motor investigation (a) and its structural diagram (b)

Объект исследования – асинхронный двигатель ЕЛПРОМ ТРОЯН 0,75 кВт, подключенный по схеме «треугольник». Питание двигателя и регулирование частоты осуществлялось с помощью частотного преобразователя (ПЧ) Веспер *ES-8200S1L*. Для моделирования механических неисправностей и варьирования нагрузки, вал двигателя соединен с тормозным устройством *FZ25K-3* через упругую муфту. Для записи временных рядов фазных токов использовались датчики тока *ACS712*, подключенные к модулю аналого-цифрового преобразователя *LTR11* измерительного крейта *LTR-EU-8*, в состав которого входил также модуль цифроаналогового преобразователя *LTR34* для управления тормозом *FZ25K-3* через контроллер *KTC800A*.

Сбор данных проводился путем регистрации сигналов двух фаз тока с частотой дискретизации 10 кГц при следующих условиях работы: электрическая частота питания – 20 Гц, два режима нагрузки – 0 и 50 % от номинальной мощности двигателя.

Было исследовано три диагностируемых состояния электропривода, которым соответствуют следующие классы:

Класс 1: «Исправный» – соответствовал работе двигателя без дефектов.

Класс 2: «Несоосность вала» – соответствовал дефекту «несоосность валов двигателя и подключаемой нагрузки», достигался установкой плоских шайб толщиной 0,5 мм под кронштейн крепления двигателя.

Класс 3: «Износ подшипника» – воспроизводился установкой в двигатель подшипника с искусственным дефектом на внешнем кольце (рис. 2).



Рис. 2. Подшипник с просверленным отверстием на внешнем кольце

Fig. 2. Bearing with a drilled hole on the outer ring

Для обеспечения статистической достоверности каждый эксперимент повторялся многократно. Испытания проводились по фиксированному протоколу: разгон двигателя до установившегося режима в течение 10–15 секунд, запись сигнала длительностью 10 секунд и сохранение метаданных эксперимента (класс дефекта, режим работы, дата/время). Полученные временные ряды разбивались на последовательные отрезки с использованием скользящего окна длиной 4096 отсчетов и перекрытием 50 % между соседними сегментами. На заключительном этапе подготовки данных была проведена фильтрация сегментов с выбросами, что позволило сформировать

сбалансированную выборку объемом 360 сегментов (по 120 на каждый класс) для последующего анализа.

Методика извлечения признаков

Для каждого сегмента сигнала фазного тока, полученного в процессе сегментации, вычислялся набор статистических признаков, отражающих форму, энергию и вариативность сигнала во временной области. Эти характеристики позволяют количественно описывать основные свойства сигнала без перехода в частотную область и широко применяются в задачах диагностики технического состояния электрических машин. В работе были использованы следующие признаки: среднее квадратичное значение, коэффициент асимметрии, коэффициент эксцесса, коэффициент формы, коэффициент корреляции между фазами Аи В [11].

Для анализа частотных характеристик сигналов фазных токов использовались методы спектрального анализа и анализа огибающей. Предварительный анализ амплитудно-частотных спектров показал наличие выраженных гармонических составляющих, обусловленных широтно-импульсной модуляцией частотного преобразователя. На графиках спектра токового сигнала (рис. 3) отчетливо проявлялись две доминирующие гармоники, соответствующие несущей частоте – около 1665 и 3330 Гц, не связанные с механическим состоянием двигателя. Их присутствие маскировало диагностически значимые низкочастотные составляющие, что делало прямое применение преобразования Фурье неинформативным.



Рис. 3. Спектр исходного сигнала (класс «Исправный»)

Рис. 3. Spectrum plot of original signal («Healthy» class)

В связи с этим для выделения информативной низкочастотной компоненты огибающей тока была применена методика демодуляции с использованием преобразования Гильберта [12]. Обработка каждого сегмента сигнала включала следующие этапы:

1. Полосовая фильтрация.

Сигнал $x(t)$ пропусклся через полосовой фильтр Баттерворта четвертого порядка с частотой $f_c = 1670$ Гц и полосой пропускания 100 Гц:

$$x_f(t) = \text{BPF}\{x(t)\}, \quad 1620 \text{ Гц} \leq f \leq 1720 \text{ Гц}. \quad (1)$$

2. Преобразование Гильберта.

Для вычисления мгновенной амплитуды (огибающей) формировался аналитический сигнал:

$$e(t) = |z(t)| = \sqrt{x_f^2(t) + \mathcal{H}^2\{x_f(t)\}}. \quad (2)$$

3. Фильтрация низких частот.

Для устранения остаточных высокочастотных колебаний применялся фильтр нижних частот (ФНЧ) с граничной частотой $f_{LP} = 200$ Гц, обеспечивающий выделение диагностически значимых низкочастотных составляющих огибающей:

$$x_{LP}(t) = \text{LPF}\{e(t)\}, \quad f \leq f_{LP} = 200 \text{ Гц}. \quad (3)$$

4. Спектральный анализ.

Для оценки спектральной плотности мощности огибающего сигнала использовался метод Вэлча с окном Ханна длиной 512 отсчетов с перекрытием 50 % (рис. 4). Итоговая оценка спектральной плотности мощности вычислялась по формуле:

$$P_{xx}(f) = \frac{1}{K} \sum_{k=1}^K \frac{|\text{FFT}\{w(n)x_{LP}(n)\}|^2}{U}, \quad (4)$$

где $w(n)$ – окно Ханна, U – нормировочный коэффициент энергии окна, K – число сегментов.

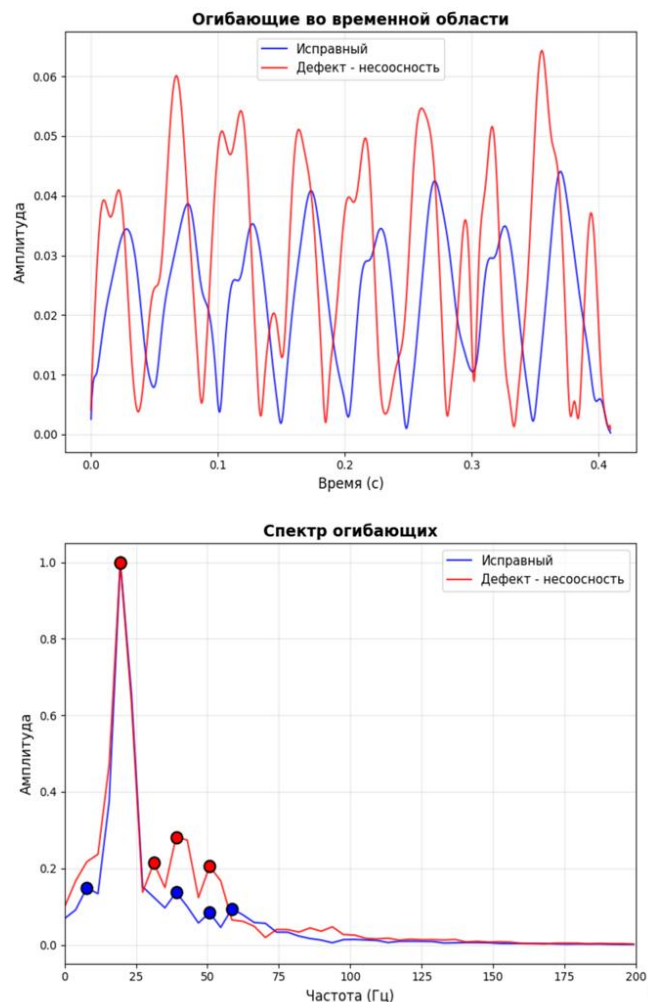


Рис. 4. Сравнение огибающих сигнала тока для исправного двигателя и при несоосности вала: слева – временная область, справа – спектр огибающей

Fig. 4. Comparison of current envelope signals for the «Healthy» and «Shaft misalignment» classes: left — time domain, right — envelope spectrum

5. Извлечение признаков.

После получения огибающей сигнала тока из нее извлекались статистические и спектральные признаки [13]. Дополнительно были вычислены интегральные показатели, отражающие относительный вклад гармонических составляющих и основной гармоники огибающей H_{env} и P_{env} :

$$H_{env} = \frac{\sum_{k \in H} P_k}{\sum_f P(f)}, \quad (5)$$

где H_{env} – доля гармонической мощности огибающей; $P(f)$ – спектр мощности огибающей; P_k – мощность k -й гармоники; H – множество индексов гармоник. Показатель H_{env} характеризует долю гармонических составляющих в общей мощности спектра огибающей.

$$P_{env} = \frac{P_1}{\sum_f P(f)}, \quad (6)$$

где P_{env} – доля мощности основной гармоники огибающей, P_1 – мощность основной гармоники. Показатель P_{env} отражает относительный вклад основной частоты в общую энергию спектра.

Обучение модели-классификатора и анализ важности признаков

Для решения задачи классификации технического состояния асинхронного электропривода использовался алгоритм случайного леса. После выполнения процедур предобработки данных исходная выборка была разделена на обучающую и тестовую в соотношении 80/20. Разбиение проводилось с сохранением баланса между классами. Для получения статистически устойчивой оценки обобщающей способности модели использовалась кросс-валидация на 5 блоков ($K=5$). Эффективность предложенной модели оценивалась с помощью ряда стандартных для задач классификации метрик: *Accuracy* (точность), *Precision* (точность прогноза по классам), *Recall* (полнота) и *F1-мера* (*F1-score*) [14].

Результаты классификации представлены в виде метрик качества по каждому классу, а также их средневзвешенных значений. В табл. 1 приведены показатели точности по классам, полноты и *F1*-меры для всех категорий технического состояния асинхронного электропривода, а также средние значения, характеризующие общую производительность модели.

Таблица 1. Метрики качества классификации по классам

Table 1. Class-wise classification metrics

Класс	Precision	Recall	F1-Score
Исправный	0,8739	0,8667	0,8703
Несоосность вала	1,0000	0,7833	0,8785
Износ подшипника	0,7347	0,9000	0,8090
Среднее значение	0,8695	0,8500	0,8526

Для наглядной оценки правильности классификации была построена матрица ошибок, отражающая распределение прогнозов по каждому классу относительно истинных меток (рис. 5).




Рис. 5. Матрица ошибок классификатора

Fig. 5. Classifier confusion matrix

Точность предложенной модели (*Accuracy*) при кросс-валидации достигла $0,85 \pm 0,05$. Наибольшая точность классификации составила 100 % для класса «Несоосность вала». Класс «Исправное состояние» имеет средние по модели метрики (точность – 0,87, полнота – 0,86). Наиболее сложной для классификации оказалась категория «Износ подшипника». Несмотря на то, что модель демонстрирует высокую полноту, обеспечивая корректное выявление 90 % реальных случаев этой неисправности, данный класс сопровождается значительным числом ложноположительных срабатываний, что приводит к снижению точности. Вероятной причиной является ограниченная чувствительность фазного тока к начальным стадиям развития дефекта подшипника.

Сложность интерпретации решений модели RF ввиду ее комплексной структуры требует применения известных методов анализа значимости признаков [15]. Для интерпретации результатов классификации и анализа вклада отдельных признаков в процесс принятия решений был использован метод оценки важности *SHAP*. Данный подход позволяет количественно оценить вклад каждого признака в формирование итогового решения модели для каждого класса. Анализ наиболее информативных признаков проводился с учетом их физического смысла, что позволило установить взаимосвязь между вычисленными признаками токовых сигналов и типами диагностируемых неисправностей.

На рис. 6 представлен график, отражающий совокупный вклад наиболее информативных признаков в процесс классификации.




Рис. 6. Глобальная важность признаков по средним абсолютным значениям SHAP

Fig. 6. Global feature importance based on mean absolute SHAP values

В табл. 2 приведены обозначения и краткие описания диагностических признаков показанных на рисунке выше.

Таблица 2. Обозначения и краткие описания диагностических признаков

Table 2. Designations and brief descriptions of diagnostic features

Обозначение	Наименование признака
RMS	Среднеквадратичное значение фазного тока
r_{AB}	Коэффициент корреляции тока, протекающего в фазах А и В
H_{env}	Доля гармонической мощности огибающей
Load	Категориальный признак, отражающий режим работы двигателя (0 — холостой ход, 1 — нагрузка)
K_{kurt}	Коэффициент эксцесса сигнала тока
P_{env}	Доля мощности основной гармоники огибающей
RMS_{env}	Среднее квадратическое значение огибающей
$K_{env,form}$	Коэффициент формы огибающей
$K_{env,cen}$	Частотный центр спектра огибающей (centroid)
$K_{env,skew}$	Коэффициент асимметрии огибающей

В табл. 3–5 представлены признаки с наибольшими значениями важности по каждому классу, определенные методом *SHAP*.

Таблица 3. Наиболее информативные признаки для класса «Износ подшипника» (по данным анализа *SHAP*)

Table 3. Most informative features for the “Bearing wear” class (according to *SHAP* analysis)

Ранг	Признак	Среднее	СКО	Мин	Макс
1	RMS	0,1424	0,0181	0,1187	0,1707
2	r_{AB}	-0,1715	0,4425	-0,7684	0,5621
3	K_{kurt}	-1,4389	0,0665	-1,5420	-1,251
4	H_{env}	0,5517	0,0630	0,2176	0,6238
5	Load	0,5000	0,5000	0,0000	1,0000

Таблица 4. Наиболее информативные признаки для класса «Несоосность вала» (по данным анализа *SHAP*)

Table 4. Most informative features for the “Shaft misalignment” class (according to *SHAP* analysis)

Ранг	Признак	Среднее	СКО	Мин	Макс
1	RMS	0,1717	0,0230	0,1319	0,1971
2	r_{AB}	-0,6129	0,4474	-0,9933	0,4612
3	H_{env}	0,5304	0,0494	0,2471	0,6012
4	Load	0,5000	0,5000	0,0000	1,0000
5	P_{env}	0,5052	0,0519	0,2471	0,5742

Таблица 5. Наиболее информативные признаки для класса «Исправный двигатель» (по данным анализа *SHAP*)

Table 5. Most informative features for the “Healthy” class (according to *SHAP* analysis)

Ранг	Признак	Среднее	СКО	Мин	Макс
1	RMS	0,1330	0,0200	0,1106	0,1669
2	r_{AB}	0,4515	0,5007	-0,6596	0,8968
3	H_{env}	0,5389	0,0891	0,1468	0,6257
4	K_{kurt}	-1,4158	0,1021	-1,5267	-0,9675
5	P_{env}	0,5069	0,0973	0,1232	0,6038

Интерпретация результатов *SHAP*-анализа показала, что два наиболее значимых признака остаются неизменными для всех классов: (1) среднее квадратическое значение (RMS) фазного тока и (2) корреляция между фазными токами. Средние значения RMS тока и корреляции между фазными токами позволяют разграничить состояния двигателя: среднеквадратичное значение тока растет от исправного состояния к износу подшипника и достигает максимума при несоосности вала, тогда как межфазная корреляция уменьшается от положительной при исправном состоянии до сильно отрицательной при несоосности, отражая нарастающее влияние механической асимметрии и дисбаланса нагрузки. Доля гармонической мощности огибающей отражает степень периодичности механических модуляций. Хотя по средним значениям различия между классами небольшие, *SHAP* показывает ее высокую информативность, указывая на скрытую нелинейную зависимость.

Оставшиеся информативные признаки – индикатор состояния нагрузки и коэффициент эксцесса тока – отражают стабильность работы двигателя и помогают уточнять интерпретацию основных токовых характеристик. Индикатор нагрузки работает в связке с RMS тока: он учитывает влияние текущего режима нагрузки на амплитуду тока, позволяя модели корректно различать изменения, связанные с механическим состоянием оборудования, а не с рабочим режимом. Отрицательные значения эксцесса соответствуют плавной форме тока без выраженных импульсов. Доля мощности основной гармоники огибающей характеризует регулярность механической модуляции – при исправной работе и несоосности преобладает выраженный фундаментальный компонент, тогда как при дефекте подшипника модуляция становится более нерегулярной и широкополосной.

Заключение

В данной работе была исследована возможность диагностики механических неисправностей асинхронного электропривода на основе анализа фазных токов. Экспериментальные данные, полученные на стенде, позволили изучить изменения токов в различных режимах работы и при разных типах дефектов. Для анализа сигналов были сформированы информативные признаки во временной и частотной областях, включая корреляцию между фазами, статистические и спектральные характеристики огибающей тока.

Разработанная модель классификации неисправностей продемонстрировала высокую эффективность: средняя точность при кросс-валидации составила $0,85 \pm 0,05$, класс «Несоосность вала» был распознан идеально, «Исправное состояние» показало точность 0,87 и полноту 0,86. Наиболее сложным оказался «Износ подшипника», где высокая полнота (90 %) сопровождалась ложноположительными срабатываниями, вероятно, из-за ограниченной чувствительности фазного тока к ранним стадиям дефекта.

Основные признаки, определяющие различие состояний двигателя, включают амплитуду тока, фазную симметрию и гармоническую структуру огибающей, а второстепенные признаки отражают ха-

ракетные диагностические признаки каждой неисправности. Анализ вклада признаков с помощью SHAP позволил интерпретировать решения модели и подтвердить их физическую значимость. Полученные результаты подтверждают применимость предложенного подхода для диагностики механических дефектов асинхронного электропривода.

Библиографические ссылки

1. Maulik S., Konar P., Chattopadhyay P. Fusion of Vibration and Current signals for Improved Multi Class Fault Diagnosis of Three Phase Induction Motor // 2023 IEEE 3rd Applied Signal Processing Conference (ASPCON). 2023, pp. 152-155, DOI: 10.1109/ASPCON59071.2023.10396244.
2. Zhao J., Wang W., Huang J. A comprehensive review of deep learning-based fault diagnosis approaches for rolling bearings: Advancements and challenges // AIP Adv. 2025. vol. 15, no. 2, DOI: 10.1063/5.0255451.
3. Jaros R., Byrtus R., Dohnal J. et al. //Advanced Signal Processing Methods for Condition Monitoring. Archives of Computational Methods in Engineering. 2022. vol. 30, pp. 1553-1577, DOI: 10.1007/s11831-022-09834-42018.
4. Maciejewski N., Treml A., Flauzino R. A Systematic Review of Fault Detection and Diagnosis Methods for Induction Motors // 2020 FORTEI-International Conference on Electrical Engineering (FORTEI-ICEE). 2020. pp. 86-90. DOI: 10.1109/FORTEI-ICEE50915.2020.9249890.
5. Han J., Park S., Hong S. A Study of the Effectiveness of Current Data in Motor Mechanical Fault Diagnosis Using XAI // 2021 24th International Conference on Electrical Machines and Systems (ICEMS). Pp. 710-715. DOI: 10.23919/ICEMS52562.2021.9634398.
6. Okwuosa C., Hur J. Enhancing Induction Motor Reliability Through Advanced Feature Selection and Diagnostic Models in Low-Load Conditions // 2025 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC), Fukuoka, Japan, 2025, pp. 1134-1139, doi: 10.1109/ICAIIIC64266.2025.10920696.
7. Kumar R. Health monitoring and fault analysis of induction motors: a review // Engineering Research Express. 2024. pp.1-28. DOI:10.1088/2631-8695/ad8b10.
8. Jian Y., Zeyang Z., Yunguang G. Research on Fault Diagnosis of Motor Bearings Based on SBOA-VMD-TCN // IEEE Access, 2025. Vol. 13, pp. 174815-174830. DOI: 10.1109/ACCESS.2025.3608063.
9. Санников П. А., Лекомцев П. В. Определение технического состояния и прогнозирование остаточного ресурса электропривода в предсказательном обслуживании: обзор зарубежных источников // Интеллектуальные системы в производстве. 2025. Т. 23, № 1, С. 82–93. DOI: 10.22213/2410-9304-2025-1-82-93
10. Шихов Е. А., Санников П. А., Лекомцев П. В. Разработка стенда для исследования асинхронного электропривода // «Выставка инноваций – 2022» (осенняя сессия) : сборник материалов XXXIV Республиканской выставки-сессии студенческих инновационных проектов, Ижевск, 15 декабря 2022 года. Ижевск : ИжГТУ имени М. Т. Калашникова, 2023. С. 187–196. EDNLDCAWO.
11. Zhenggaoyuan F., Wang Q., Wenjing S. Research on Improved Fault Detection Method of Rolling Bearing Based on Signal Feature Fusion Technology // Applied Sciences. 2023.p.12987. DOI:10.3390/app132412987.
12. Zhang B., Meng Q. Rolling bearing fault diagnosis based on wavelet packets and Hilbert envelope spectrum // Mech. Manag. Develop. 2024. Vol. 39, no. 3, pp. 1–3, DOI: 10.16525/j.cnki.cn14-1134/th.2024.03.001.
13. Atamuradov V., Medjaher K., Camci F. et al. Machine Health Indicator Construction Framework for Failure Diagnostics and Prognostics // Journal of Signal Processing Systems. 2020. Vol. 92 (8). DOI: 10.1007/s11265-019-01491-4.
14. Bundasak S., Wittayasirikul P. Predictive maintenance using AI for Motor health prediction system // 2022 International Electrical Engineering Congress (iEECON). 2022. pp. 1-4. DOI: 10.1109/iEECON53204.2022.9741620.
15. Amir K., Bilal A., Vaimann K. An Advanced Diagnostic Approach for Broken Rotor Bar Detection and Classification in DTC Controlled Induction Motors by Leveraging Dynamic SHAP Interaction Feature Selection (DSHAP-IFS) GBDT Methodology //2024. Machines. 12. 495. DOI: 10.3390/machines12070495.

References

1. Maulik S., Konar P., Chattopadhyay P. (2023) Fusion of Vibration and Current signals for Improved Multi Class Fault Diagnosis of Three Phase Induction Motor. 2023 IEEE 3rd Applied Signal Processing Conference (ASPCON). Pp. 152-155. DOI: 10.1109/ASPCON59071.2023.10396244.
2. Zhao J., Wang W., Huang J. (2025) A comprehensive review of deep learning-based fault diagnosis approaches for rolling bearings: Advancements and challenges. AIP Adv. Vol. 15, no. 2. DOI: 10.1063/5.0255451.
3. Jaros R., Byrtus R., Dohnal J. et al. (2022) Advanced Signal Processing Methods for Condition Monitoring. Archives of Computational Methods in Engineering. Vol. 30, pp. 1553-1577, DOI: 10.1007/s11831-022-09834-4.
4. Maciejewski N., Treml A., Flauzino R. (2020) A Systematic Review of Fault Detection and Diagnosis Methods for Induction Motors. 2020 FORTEI-International Conference on Electrical Engineering (FORTEI-ICEE). Pp. 86-90. DOI: 10.1109/FORTEI-ICEE50915.2020.9249890.
5. Han J., Park S., Hong S. A Study of the Effectiveness of Current Data in Motor Mechanical Fault Diagnosis Using XAI. 2021 24th International Conference on Electrical Machines and Systems (ICEMS). 2021. Pp. 710-715. DOI: 10.23919/ICEMS52562.2021.9634398.
6. Okwuosa C., Hur J. Enhancing Induction Motor Reliability through Advanced Feature Selection and Diagnostic Models in Low-Load Conditions. 2025 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC), Fukuoka, Japan, 2025, pp. 1134-1139, doi: 10.1109/ICAIIIC64266.2025.10920698
7. Kumar R. (2024) Health monitoring and fault analysis of induction motors: a review. Engineering Research Express. 6. 1-28. DOI:10.1088/2631-8695/ad8b10.
8. Jian Y., Zeyang Z., Yunguang G. (2025) Research on Fault Diagnosis of Motor Bearings Based on SBOA-VMD-TCN. IEEE Access, vol. 13, pp. 174815-174830. DOI: 10.1109/ACCESS.2025.3608063
9. Sannikov P.A., Lekomtsev P.V. [Conditional monitoring and remaining useful life prediction of electric motor and predictive maintenance]. *Intellektual'nye sistemy v proizvodstve*. 2025. Vol. 23, no. 1, pp. 82-93 (in Russ.). DOI: 10.22213/2410-9304-2025-1-82-93.
10. Shikhov E.A., Sannikov P.A., Lekomtsev P.V. *Razrabotka stenda dlya issledovaniya asinhronnogo elektroprivoda* [Development of a test bench for studying an induction electric drive]. *Vystavka innovatsii - 2022 (osenyaya sessiya): sbornik materialov XXXIV Respublikanskoy vystavki-sessii studenteskikh innovatsionnykh proektov* ["Innovation Exhibition - 2022" (autumn session): a collection of materials from the XXXIV Republican exhibition-session of student innovation projects], Izhevsk, 15 December 2022. Izhevsk, IzhGTU

imeni M. T. Kalashnikova, 2023, pp. 187-196. EDN: LDCAWO (in Russ.).

11. Zhenggaoyuan F., Wang Q., Wenjing S. (2023) Research on Improved Fault Detection Method of Rolling Bearing Based on Signal Feature Fusion Technology. *Applied Sciences*. 13. P. 12987. DOI:10.3390/app132412987.

12. Zhang B., Meng Q. (2024) Rolling bearing fault diagnosis based on wavelet packets and Hilbert envelope spectrum. *Mech. Manag. Develop.* 2024. vol. 39, no. 3, pp. 1-3, DOI: 10.16525/j.cnki.cn14-1134/th.2024.03.001.

13. Atamuradov V., Medjaher K., Camci F. et al. (2020) Machine Health Indicator Construction Framework for Failure

Diagnostics and Prognostics. *Journal of Signal Processing Systems*. Vol. 92 (8). DOI: 10.1007/s11265-019-01491-4.

14. Mudasak S., Wittayasirikul P. Predictive maintenance using AI for Motor health prediction system. 2022 International Electrical Engineering Congress (iEECON). pp. 1-4. DOI: 10.1109/iEECON53204.2022.9741620.

15. Amir K., Bilal A., Vaimann K. (2024) An Advanced Diagnostic Approach for Broken Rotor Bar Detection and Classification in DTC Controlled Induction Motors by Leveraging Dynamic SHAP Interaction Feature Selection (DSHAP-IFS) GBDT Methodology. 2024. *Machines*. 12. 495. DOI: 10.3390/machines12070495.

Interpretable Machine Learning-Based Diagnosis of Mechanical Faults in Induction Motors Using Current Features

P. A. Sannikov, Post-graduate, Kalashnikov Izhevsk State Technical University, Izhevsk, Russia

P. V. Lekomtsev, PhD in Engineering, Associate Professor, Kalashnikov Izhevsk State Technical University, Izhevsk, Russia

The study presents an approach to diagnosing mechanical faults in an induction motor drive based on phase current analysis. Experimental data were obtained on a dedicated test bench for the induction motor drive under two operating conditions—no-load and 50% of nominal load—and two technical conditions: healthy, faulty with a “load misalignment” defect, and faulty with a “worn bearing” defect. The preprocessing of current signals included filtering, envelope extraction, and normalization. Statistical features such as root mean square value, kurtosis and skewness coefficients were extracted from the original current waveforms to reflect changes in the waveform shape and distribution under different fault conditions. Additionally, spectral characteristics and integral indicators were calculated from the current envelopes to describe the relative contribution of harmonic components and the fundamental harmonic, allowing for the analysis of signal modulation features associated with various mechanical faults. A classification model, based on the extracted features and using the Random Forest (RF) algorithm with an average accuracy of 85% under cross-validation, was trained. Feature importance analysis was performed using the SHAP (Shapley Additive exPlanations) method, followed by physical interpretation to enable establishing the relationships between specific features and fault types and confirm the validity of the selected diagnostic indicators. The obtained results confirmed the effectiveness of the classical Random Forest algorithm for diagnosing mechanical faults in induction motor drives, identified the most sensitive features to changes in motor technical condition, and demonstrated the potential for application in condition monitoring and equipment health assessment systems.

Keywords: machine learning, feature engineering, diagnosis, electric drive, random forest, model interpretation, SHAP method.

Получено: 13.11.25

Образец цитирования

Санников П. А., Лекомцев П. В. Интерпретируемая диагностика механических неисправностей асинхронного электропривода по токовым признакам с использованием методов машинного обучения // Интеллектуальные системы в производстве. 2025. Т. 23, № 4. С. 86–92. DOI: 10.22213/2410-9304-2025-4-86-92.

For Citation

Sannikov P.A., Lekomtsev P.V. [Interpretable machine learning-based diagnosis of mechanical faults in induction motors using current features]. *Intellectual'nye sistemy v proizvodstve*. 2025, vol. 23, no. 4, pp. 86-92 (in Russ.). DOI: 10.22213/2410-9304-2025-4-86-92.