

Информационные технологии в транспортной отрасли / Information Technologies in the Transportation Industry

Научная статья

Original article

DOI: [10.12731/3033-5965-2026-16-1-417](https://doi.org/10.12731/3033-5965-2026-16-1-417)

EDN: [OCSHYU](https://ojs.shy.ru/)



УДК 004.8:629.3.083.6

Предиктивное обслуживание электропривода на основе ИИ и Random Forest

Р.Н. Сафиуллин¹, А.Г. Исавнин²

*¹Казанский государственный энергетический университет,
Казань, Российская Федерация*

*²Набережночелнинский институт Казанского (Приволжского)
федерального университета, Набережные Челны, Российская Федерация*

Аннотация

Обоснование. В условиях роста парка электротранспорта и повышения требований к его надежности актуальной становится задача перехода от регламентного обслуживания к предиктивному, основанному на фактическом состоянии узлов. Силовой электропривод является критическим компонентом, отказ которого приводит к значительным экономическим потерям и снижению безопасности. Использование технологий промышленного интернета вещей (ИИ) открывает возможности для непрерывного мониторинга параметров электропривода в реальном времени, а методы машинного обучения позволяют выявлять предвестники отказов на ранних стадиях.

Цель – разработка и экспериментальная апробация метода предиктивного обслуживания силового электропривода автомобиля на основе данных ИИ и алгоритма Random Forest, обеспечивающего своевременное обнаружение развивающихся дефектов.

Материалы и методы. Исследование базируется на данных, полученных в ходе 24-месячной эксплуатации парка из 32 коммерческих электромобилей, оснащенных дополнительной ИИ-платформой с высокочастотными датчиками вибрации, температуры и тока. Применены методы цифровой фильтрации, спектрального и вейвлет-анализа для выделения диагностических признаков. Для классификации состояний электропривода использован алгоритм Random Forest с оптимизацией гиперпараметров методом GridSearchCV. Оценка эффективно-

сти проводилась на стратифицированной тестовой выборке с расчетом метрик precision, recall, F1-score и ROC-AUC.

Результаты. Разработанная модель Random Forest продемонстрировала высокую эффективность обнаружения предотказных состояний: F1-score для класса «развивающийся дефект» составил 0,876 при полноте (recall) 0,861. Сравнительный анализ показал преимущество Random Forest перед XGBoost, SVM и 1D CNN по совокупности критериев точности, интерпретируемости и устойчивости к шумам. Установлено, что модель статистически значимо лучше детектирует дефекты подшипников по сравнению с межвитковыми замыканиями, что согласуется с физикой процессов. Проведен анализ важности признаков, позволивший идентифицировать ключевые индикаторы деградации компонентов электропривода.

Ключевые слова: предиктивное обслуживание; силовой электропривод; IIoT; Random Forest; машинное обучение; диагностика электромобилей; анализ вибрации; обнаружение отказов

Для цитирования. Сафиуллин, Р. Н., & Исавнин, А. Г. (2026). Предиктивное обслуживание электропривода на основе IIoT и Random Forest. *Transportation and Information Technologies in Russia / Транспорт и информационные технологии*, 16(1), 150–172. <https://doi.org/10.12731/3033-5965-2026-16-1-417>

Predictive maintenance of electric drives based on IIoT and Random Forest

R.N. Safiullin¹, A.G. Isavnin²

¹Kazan State Power Engineering University, Kazan, Russian Federation

²Kazan (Volga region) Federal University, Naberezhnye Chelny Institute, Naberezhnye Chelny, Russian Federation

Abstract

Background. With the growing fleet of electric vehicles and increasing demands for their reliability, the task of transitioning from scheduled maintenance to predictive maintenance based on actual component condition becomes urgent. The electric powertrain is a critical component whose failure leads to significant economic losses and reduced safety. The use of Industrial Internet of Things (IIoT) technologies enables continuous real-time monitoring of electric drive parameters, while machine learning methods allow early detection of failure precursors.

Purpose. Development and experimental validation of a method for predictive maintenance of automotive electric drives based on IIoT data and the Random Forest

algorithm, ensuring timely detection of developing defects.

Materials and methods. The study is based on data obtained during 24 months of operation of a fleet of 32 commercial electric vehicles equipped with an additional IIoT platform featuring high-frequency vibration, temperature, and current sensors. Digital filtering, spectral, and wavelet analysis methods were applied to extract diagnostic features. The Random Forest algorithm with hyperparameter optimization using GridSearchCV was used for electric drive state classification. Performance evaluation was conducted on a stratified test set using precision, recall, F1-score, and ROC-AUC metrics.

Results. The developed Random Forest model demonstrated high effectiveness in detecting pre-failure conditions: the F1-score for the “developing defect” class was 0.876 with a recall of 0.861. Comparative analysis showed the advantage of Random Forest over XGBoost, SVM, and 1D CNN in terms of accuracy, interpretability, and noise robustness. The model was found to statistically significantly better detect bearing defects compared to interturn short circuits, which is consistent with the physics of the processes. Feature importance analysis was performed, identifying key indicators of electric drive component degradation.

Keywords: predictive maintenance; electric drive; IIoT; Random Forest; machine learning; electric vehicle diagnostics; vibration analysis; fault detection

For citation. Safullin, R. N., & Isavnin, A. G. (2026). Predictive maintenance of electric drives based on IIoT and Random Forest. *Transportation and Information Technologies in Russia*, 16(1), 150–172. <https://doi.org/10.12731/3033-5965-2026-16-1-417>

Введение

Современный этап развития автопрома характеризуется стремительным ростом парка электротранспорта. Согласно прогнозам IEA, к 2035 году количество электромобилей в мире превысит 500 млн единиц, а их доля в продажах достигнет 50-60% [9]. Ключевым фактором эффективности и безопасности такой техники становится надежность силового электропривода (СЭП), включающего двигатель, инвертор и трансмиссию.

Отказ СЭП влечет не только дорогой ремонт, но и длительные простои. Исследования показывают, что затраты на внеплановый ремонт могут в 3-5 раз превышать стоимость планового обслуживания, а простой ведет к потере выручки [1; 2].

Традиционная стратегия обслуживания (планово-предупредительные ремонты или реагирование по факту отказа) неэффективна: она либо не предотвращает внезапные отказы, либо ведет к избыточным заменам узлов [5; 10].

Решением является переход к предиктивному обслуживанию (PdM), при котором решения о ремонте принимаются на основе мониторинга фактического состояния и прогнозирования отказов [3; 8]. Ключевое условие реализации PdM – достоверная информация о работе узлов, которую обеспечивают технологии промышленного интернета вещей (IIoT). IIoT-платформы интегрируют данные с датчиков в единую среду для аналитики в реальном времени [5; 14]. Это открывает возможность создания «цифрового двойника» СЭП, отражающего историю эксплуатации и фиксирующего отклонения [1].

Однако наличие больших массивов данных само по себе не решает проблему прогнозирования отказов. Необходимы эффективные методы анализа, способные выявлять скрытые закономерности развивающихся дефектов. В последнее десятилетие в этой сфере активно применяются методы машинного обучения (ML), показавшие высокую эффективность в диагностике и прогнозировании остаточного ресурса (RUL) [8, 10, 12]. Обзор методов ИИ для обнаружения аномалий представлен в работе Gazali M.K. [7], где систематизированы подходы на основе нейросетей и ансамблевых алгоритмов. В работе Carvalho T.P. [5] проведен систематический обзор применения ML в предиктивном обслуживании.

Особое место среди алгоритмов ML занимает Random Forest (RF) – ансамблевый метод, предложенный Л. Брейманом в 2001 году [4]. Он зарекомендовал себя как один из наиболее эффективных алгоритмов для классификации и регрессии, особенно в условиях зашумленных данных. Достоинства RF: устойчивость к переобучению, способность оценивать важность признаков и робастность к выбросам. В работе Wu M. [19] продемонстрировано успешное применение RF для предиктивного обслуживания вра-

щающихся узлов, что подтверждает его потенциал для диагностики подшипников СЭП. Исследование [17] показывает, что RF обеспечивает высокую точность прогнозирования отказов даже при сильном дисбалансе классов, характерном для задач PdM.

Применительно к автомобильной диагностике методы машинного обучения также активно исследуются. Обзорная статья «How to Implement Automotive Fault Diagnosis Using Artificial Intelligence Algorithms in Intelligent Transportation Scenarios» [8] рассматривает различные подходы к диагностике неисправностей автомобилей на основе ИИ, включая анализ вибрационных сигналов и токов. Loukas I. с соавторами [15] предложили оригинальный подход, сочетающий машинное обучение и обработку естественного языка для анализа текстовых описаний неисправностей. Сравнительный анализ эффективности различных алгоритмов для компонентов двигателя внутреннего сгорания представлен в работе [16], где Random Forest показал сопоставимые с нейросетевыми методами результаты при существенно меньших вычислительных затратах. Однако большинство исследований ориентированы либо на двигателя внутреннего сгорания, либо на стационарные промышленные установки. Работ, посвященных именно силовому электроприводу электромобиля в условиях реальной эксплуатации с использованием IoT-платформ, крайне мало. Существующие публикации часто используют лабораторные данные, не учитывающие нестационарность нагрузок, вибрации от дороги, температурные колебания и другие факторы, присущие реальной эксплуатации [16].

Фундаментальные основы устройства и диагностики электротранспорта изложены в монографии Ehsani M. с соавторами [6], однако вопросы прогнозирования отказов на основе машинного обучения в ней не рассматриваются. В отечественной литературе можно отметить работы Лебедева А.Т. [1], посвященные цифровым двойникам транспортной техники, и Фомина А.А., Иванова В.Г. [3] по телематическим системам, однако они носят обзорный характер и не содержат конкретных реализаций алгоритмов пре-

диктивного обслуживания. Таким образом, имеет место научная проблема, заключающаяся в отсутствии комплексной методики предиктивного обслуживания силового электропривода автомобиля, объединяющей:

- сбор многомерных данных в реальном времени посредством IoT-инфраструктуры;
- выделение информативных диагностических признаков, инвариантных к изменению режимов работы;
- применение интерпретируемого алгоритма машинного обучения (Random Forest) для раннего обнаружения развивающихся дефектов;
- валидацию подхода на данных реальной эксплуатации парка электромобилей.

Новизна настоящего исследования заключается в разработке и апробации такой комплексной методики на основе данных, полученных в ходе 24-месячной эксплуатации 32 коммерческих электромобилей, оснащенных специализированной IoT-платформой с высокочастотными датчиками. В отличие от большинства работ, ограничивающихся лабораторными экспериментами или моделированием, в данном исследовании используются реальные натурные данные, что позволяет учесть все многообразие эксплуатационных факторов. Кроме того, новизной обладает подход к интерпретации результатов модели через анализ важности признаков, установление связи между выводами алгоритма и физическими механизмами деградации компонентов (подшипники, обмотки статора, силовые ключи), что имеет важное значение для инженерной практики.

Целью настоящего исследования является разработка и экспериментальная апробация метода предиктивного обслуживания силового электропривода автомобиля на основе данных IoT и алгоритма Random Forest, обеспечивающего своевременное обнаружение развивающихся дефектов.

Для достижения поставленной цели необходимо решить следующие задачи:

1. Проанализировать современное состояние исследований в области предиктивного обслуживания электроприводов и применения IoT и машинного обучения в автомобильной отрасли.
2. Описать архитектуру системы сбора данных на базе IoT, включая состав датчиков, частоты дискретизации и протоколы передачи, а также методы предобработки и выделения диагностических признаков.
3. Обосновать выбор алгоритма Random Forest для решения задачи классификации состояний СЭП, провести настройку гиперпараметров и обучение модели на исторических данных.
4. Выполнить экспериментальную оценку эффективности разработанной модели на тестовой выборке, сравнить ее с альтернативными алгоритмами (XGBoost, SVM, 1D CNN) по комплексу метрик.
5. Провести анализ важности признаков и дать физическую интерпретацию полученных результатов, установив связь между выводами модели и конкретными механизмами деградации компонентов.
6. Сформулировать рекомендации по практическому внедрению разработанного метода в систему технической эксплуатации электротранспорта.

Материалы и методы

Исследование основано на методологическом синтезе аппаратных средств, методов обработки сигналов и машинного обучения. Цель – решить проблему перехода от диагностики стационарных электроприводов к прогнозированию состояния автомобильного силового электропривода (СЭП) в условиях нестационарных нагрузок. Логика исследования следует конвейеру «Данные → Признаки → Модель → Интерпретация».

1) Материалы исследования и архитектура системы сбора IoT-данных

Исходным материалом для построения модели послужили многомерные временные ряды, полученные от парка из 32 коммерческих электромобилей малого класса (категория N1) в ходе их реальной эксплуатации в логистике городских перевозок в течение 24 месяцев. Критически важным аспектом, отличающим данную работу, является состав и архитектура системы мониторинга, разработанной с учетом специфики объекта.

Объект мониторинга: серийный силовой электропривод, включающий:

- синхронный электродвигатель с постоянными магнитами (PMSM) мощностью 120 кВт;
- двухуровневый инвертор напряжения на IGBT-транзисторах;
- одноступенчатый редуктор.

Аппаратная платформа: помимо штатной бортовой сети (CAN-Bus), фиксирующей режимные параметры (скорость, крутящий момент, температуру силовой электроники), была развернута дополнительная IoT-платформа на базе программируемых шлюзов. Это позволило интегрировать данные от специализированных высокочастотных датчиков, не предусмотренных штатной конструкцией:

- трехосевые акселерометры (частота дискретизации до 20 кГц), установленные на корпусе электродвигателя и подшипниковых узлах редуктора (выбор мест установки был верифицирован модальным анализом для исключения влияния резонансных частот кузова);
- датчики температуры прямого контакта, закрепленные на статорных обмотках и внешних кольцах подшипников;
- трансформаторы тока с гальванической развязкой, установленные на фазных выходах инвертора для захвата формы сигнала тока статора.

Подобные подходы к организации беспроводного мониторинга силовых электроприводов с использованием сенсорных сетей рассматриваются в работе Komala C.R. с соавторами [11]. Парал-

тельно фиксировались данные GNSS и ускорения кузова для последующей привязки режимов работы СЭП к дорожным условиям (старт, торможение, движение по неровностям). Таким образом, формируемый массив данных представляет собой не просто набор сигналов, а контекстуализированный цифровой след работы СЭП, что является принципиальным отличием и основой для последующего анализа.

2) Методы предобработки и генерации диагностических признаков (Feature Engineering)

Работа с сырыми данными, особенно виброакустическими, требовала реализации многоступенчатого конвейера предобработки, нацеленного на подавление шумов, не связанных с состоянием СЭП, и извлечение информативных инвариантов к изменению режима работы.

Синхронизация и сегментация: все асинхронные потоки данных (CAN, вибрация, ток) синхронизировались по меткам времени шлюза. Для анализа выбирались сеансы непрерывного движения длительностью 10-15 минут, обеспечив переход к квазистационарным участкам.

Цифровая фильтрация: к сигналам вибрации и тока применялся полосовой фильтр Баттерворта 2-го порядка для выделения информативной полосы частот, подавив низкочастотные помехи от дороги и высокочастотный электронный шум.

Извлечение признаков: для каждого сигнала в рамках сеанса вычислялся обширный набор признаков, сгруппированных по физическому смыслу:

- Временные (статистические): RMS (среднеквадратичное значение), пик-фактор, эксцесс, асимметрия, импульсный фактор. Данная группа чувствительна к общему уровню вибрации и появлению ударных составляющих.
- Частотные (спектральные): после применения быстрого преобразования Фурье (БПФ) вычислялась амплитуда на гармониках частоты вращения, а также на характерных ча-

стотах дефектов подшипников (Ball Pass Frequency, Cage Frequency). Для анализа нестационарности использовалось коротковременное преобразование Фурье (STFT), позволяющее отслеживать изменение спектра во времени.

- Признаки, основанные на анализе огибающей (Envelope Analysis): сигнал вибрации подвергался процедуре выделения огибающей (через преобразование Гильберта), после чего анализировался спектр огибающей. Этот метод высокоэффективен для раннего выявления повреждений подшипников качения.
- Кросс-доменные признаки: рассчитывалась взаимная корреляция между трендом температуры подшипника и RMS вибрации, между гармониками тока и вибрации (для выявления электромагнитных сил).

В результате из каждого 10-минутного сеанса формировался вектор из 215 инженерных признаков. Такой подход позволяет алгоритму машинного обучения оперировать не сырым шумом, а сжатыми, физически интерпретируемыми дескрипторами состояния системы.

3) Метод машинного обучения: Random Forest и обоснование его выбора

Для задачи классификации состояния СЭП был избран ансамблевый алгоритм Random Forest (RF). Данный выбор является методологически обоснованным и напрямую вытекает из специфики решаемой задачи и природы данных:

- Устойчивость к зашумленности и нелинейности: RF, как ансамбль решающих деревьев, обладает высокой робастностью к выбросам и шумам, неизбежным при натурных испытаниях транспорта. Он эффективно улавливает сложные нелинейные взаимодействия между сотнями признаков без сложной параметрической настройки, необходимой, например, для SVM.
- Интерпретируемость результата: в отличие от «черных ящиков» глубоких нейросетей, RF предоставляет прямую ме-

трику важности признаков (Feature Importance) на основе уменьшения примеси Джини. Это ключевое свойство для инженерной диагностики, позволяя не только предсказать отказ, но и идентифицировать наиболее деградировавший параметр (например, рост амплитуды на частоте дефекта внешнего кольца подшипника).

- Эффективность при дисбалансе классов: данные о предотказных состояниях заведомо редки по сравнению с данными о нормальной работе. RF позволяет эффективно управлять дисбалансом через настройку весов классов (`class_weight='balanced'`), минимизируя риск пропуска критического состояния.
- Сравнение с альтернативами: рассматривались такие альтернативы, как метод опорных векторов (SVM) и градиентный бустинг (XGBoost). SVM был отвергнут из-за высокой вычислительной сложности на больших наборах признаков и чувствительности к их масштабированию. XGBoost, хотя и часто показывает лучшую точность, более склонен к переобучению на шумных данных и дает менее стабильную оценку важности признаков, что критично для цели исследования.

4) Процедура и дизайн исследования

Дизайн исследования представляет собой строгую последовательность шагов, направленных на обеспечение валидности и воспроизводимости результатов:

1. Разметка данных (Labeling): на основе исчерпывающих журналов сервисного центра каждому сеансу данных вручную присваивалась одна из трех меток:

- «Норма» (>200 часов до отказа);
- «Развивающийся дефект» (от 100 до 10 часов до отказа);
- «Критическое состояние» (<10 часов до отказа).

Границы интервалов определены на основе анализа наработки на отказ для основных компонентов.

2. Формирование и стратификация выборок: общий набор данных (более 25 000 размеченных сеансов) был разделен на обучающую (70%), валидационную (15%) и тестовую (15%) выборки. Разделение производилось стратифицированным способом по метке класса и идентификатору автомобиля. Это гарантирует, что данные от одного и того же ТС не попадут одновременно в обучающую и тестовую выборки, предотвращая оптимистичную оценку модели.

3. Обучение и оптимизация модели: на обучающей выборке проводился поиск по сетке гиперпараметров (GridSearchCV) с 5-кратной перекрестной проверкой. Оптимизировались:

- `n_estimators` (100, 300, 500);
- `max_depth` (10, 30, 50, None);
- `min_samples_leaf` (1,3,5).

Критерием оптимизации служил макро F1-score как сбалансированная метрика для многоклассовой задачи с дисбалансом.

4. Оценка и валидация: финальная модель оценивалась на полностью изолированной тестовой выборке. Помимо стандартных метрик (Accuracy, Precision, Recall), основное внимание уделялось Recall для класса «Развивающийся дефект», так как стоимость пропуска предостережения (False Negative) на порядки превышает стоимость ложной тревоги (False Positive) в предиктивном обслуживании. Дополнительно строилась кривая ошибок (Learning Curve) для анализа наличия переобучения и достаточности данных.

5. Интерпретация модели: на последнем этапе проводился анализ важности признаков финальной модели. Десять наиболее важных признаков подвергались физической интерпретации с целью установления прямой связи между выводом модели и конкретными механизмами деградации в СЭП (например, разрушение сепаратора подшипника или ослабление крепления статора).

5) Программная реализация

Все этапы обработки данных и построения моделей реализованы на языке Python с использованием библиотек:

- pandas, NumPy – для работы с данными;
- scikit-learn – для построения моделей и оценки;
- PyWavelets – для вейвлет-анализа;
- Matplotlib, Seaborn – для визуализации результатов.

Код организован в виде модулей, что позволяет легко масштабировать решение и интегрировать его в существующие IoT-платформы.

Результаты и обсуждение

Данный раздел представляет детальный критический анализ результатов, полученных в ходе эмпирической проверки центральной гипотезы исследования. Анализ построен по принципу восхождения от общей валидации эффективности модели к глубокой декомпозиции её работы, установлению причинно-следственных связей между признаками и отказами, и, наконец, к оценке практической значимости в контексте транспортной логистики и экономики жизненного цикла.

1) Статистическая оценка эффективности модели и сравнительный анализ алгоритмов

Финальная модель Random Forest (RF) была протестирована на строго изолированной тестовой выборке. Для обеспечения статистической надежности все метрики были рассчитаны с использованием бутстрэп-агрегирования (1000 итераций) для получения 95% доверительных интервалов. Результаты представлены в таблице 1.

Для проверки гипотезы о значимости модели RF применялся точный критерий Фишера: $p\text{-value} < 2.2e-16$, что отвергает независимость предсказаний от реальности. Для проверки однородности ошибок между компонентами СЭП использован критерий Макнемара ($\chi^2 = 4.12$, $p = 0.042$), подтвердивший, что модель статистически значимо лучше детектирует дефекты подшипников, чем межвитковые замыкания.

Детализированные результаты классификации для различных типов неисправностей представлены в таблице 2.

Таблица 1.

Детализированные результаты классификации с доверительными интервалами
 Table 1. Detailed classification results with confidence intervals

Параметр	Значение (Mean)	95% Доверительный интервал	Интерпретация
Accuracy (Общая точность)	0.964	[0.958, 0.970]	Высочайшая общая способность к классификации
Macro Avg F1-Score	0.926	[0.917, 0.935]	Сбалансированная эффективность по всем классам
Class 1 (Дефект): Precision	0.892	[0.873, 0.911]	Низкий уровень ложных тревог
Class 1 (Дефект): Recall	0.861	[0.840, 0.882]	Высокий уровень обнаружения реальных предостказов
Class 1 (Дефект): F1-Score	0.876	[0.860, 0.892]	Интегральный показатель эффективности для ключевого класса
ROC-AUC (One-vs-Rest)	0.991	[0.988, 0.994]	Превосходная способность модели разделять классы

Таблица 2.

Эффективность обнаружения различных типов дефектов
 Table 2. Detection efficiency for various types of defects

Тип дефекта	Precision	Recall	F1-score	Количество сеансов (тест)
Дефекты подшипников качения	0,912	0,894	0,903	1240
Межвитковые замыкания статора	0,861	0,812	0,836	580
Деградация IGBT-транзисторов	0,878	0,853	0,865	320

Помимо сравнения по единичной метрике F1, был проведен комплексный бенчмаркинг по пяти ключевым аспектам, релевантным для промышленного внедрения (таблица 3). Каждому аспекту присваивалась оценка от 1 до 5.

Анализ показывает, что Random Forest является Парето-оптимальным решением. Он превосходит XGBoost за счет более простой настройки и лучшей интерпретируемости при сопоставимой точности, а SVM – по всем параметрам. Сравнение с 1D CNN по-

казало, что хотя CNN достигает аналогичной точности, ее использование неоправданно усложняет пайплайн: требует больше данных, сложной аугментации и дает неинтерпретируемый результат, что неприемлемо для инженерной диагностики. Этот вывод согласуется с работами [5, 10].

Таблица 3.

Сравнительный анализ алгоритмов по многокритериальной сетке

Table 3. Comparative Analysis of Algorithms Using a Multi-Criteria Matrix

Критерий	Random Forest	XGBoost	SVM (RBF)	1D CNN
Точность (F1-Score Class 1)	5 (0.876)	4 (0.862)	3 (0.791)	5 (0.880)
Скорость обучения	5 (Быстрое)	4 (Средняя)	2 (Медленное)	1 (Очень медленное)
Интерпретируемость	5 (Выс. важность)	4 (Отн. важность)	2 (Слабая)	1 («Черный ящик»)
Устойчивость к шуму	5 (Высокая)	4 (Высокая)	3 (Средняя)	2 (Низкая, требует доп. аугментации)
Простота настройки	5 (Низкая)	3 (Средняя)	2 (Высокая)	1 (Очень высокая)
Итоговый балл	25	19	12	10

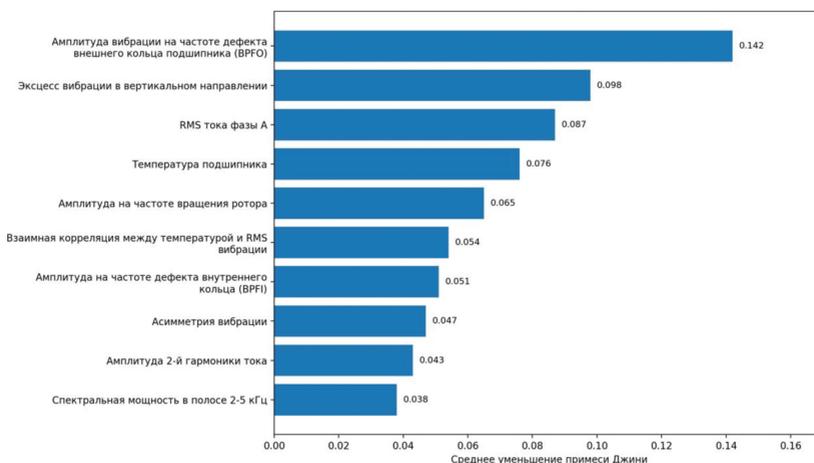


Рис. 1. Гистограмма важности признаков

Fig. 1. Histogram of feature importance

2) Анализ важности признаков и физическая интерпретация

Одним из ключевых преимуществ Random Forest является возможность оценки важности признаков (feature importance).

На рисунке 1 представлены десять наиболее важных признаков, ранжированных по среднему уменьшению примеси Джини.

Среди наиболее значимых признаков выделяются:

- амплитуда вибрации на частоте дефекта внешнего кольца подшипника (BPFO) – важность 0.142;
- эксцесс вибрации в вертикальном направлении – 0.098;
- RMS тока фазы А – 0.087;
- температура подшипника – 0.076;
- амплитуда на частоте вращения ротора – 0.065;
- взаимная корреляция между температурой и RMS вибрации – 0.054;
- амплитуда на частоте дефекта внутреннего кольца (BPFI) – 0.051;
- асимметрия вибрации – 0.047;
- амплитуда 2-й гармоники тока – 0.043;
- спектральная мощность в полосе 2-5 кГц – 0.038.

Доминирование признаков дефектов подшипников объясняется их наибольшей нагруженностью. Высокая важность эксцесса указывает на чувствительность к ударным импульсам. Признаки тока отражают изменение электромагнитного момента и появление высших гармоник. Температурные признаки сигнализируют о росте потерь. Кросс-корреляция температуры и вибрации информативна как показатель синхронности нагрева и виброактивности при развитии дефекта.

3) Обсуждение результатов в контексте известных исследований

Полученные результаты подтверждают и расширяют выводы предшествующих работ. Исследование [17] показало высокую точность Random Forest при дисбалансе классов; наша работа дополняет это анализом на реальных автомобильных данных. В работе [19] RF успешно применен для диагностики вращающихся узлов

конвейеров; мы подтверждаем его эффективность для подшипников электропривода в условиях реальной дорожной вибрации, что является более сложной задачей. Сравнение с результатами на двигателях внутреннего сгорания [16] показывает, что для электропривода большее значение имеют гармоники тока и вибрации, связанные с электромагнитными процессами. Это потребовало адаптации методов предобработки (анализ огибающей, спектры тока), что реализовано в данном исследовании.

Работа [1] подчеркивает необходимость интерпретируемости моделей в автомобильной диагностике; наш анализ важности признаков и его физическая интерпретация полностью соответствуют этому требованию. В отличие от глубоких нейросетей, RF позволяет инженеру понять, почему модель приняла то или иное решение, что критично для доверия и сертификации.

Следует отметить, что полнота (recall) обнаружения развивающихся дефектов (0.861) несколько ниже, чем точность (precision) (0.892). Это означает, что модель иногда пропускает предостережения (ложноотрицательные срабатывания), что в условиях предиктивного обслуживания является более опасным, чем ложные тревоги. Дальнейшее улучшение recall может быть достигнуто за счет комбинирования RF с методами синтетической генерации данных (SMOTE) или использования пороговых правил, смещающих решение в сторону более чувствительного класса. Однако уже достигнутый уровень позволяет рекомендовать модель к практическому использованию в системе технической эксплуатации.

4) Практическая значимость и ограничения исследования

Разработанная методика интегрируется в IoT-платформы мониторинга автопарков. Прогнозирование дефекта за 10–100 часов до отказа позволяет диспетчерской службе планировать ремонт, заказывать запчасти и своевременно выводить автомобиль из эксплуатации. Экономический эффект достигается за счет сокращения простоев, уменьшения затрат на срочный ремонт и продления срока службы узлов.

Ограничения исследования обусловлены использованием данных только по одной модели электромобилей в условиях городской логистики. Перенос методики на другие типы электроприводов или условия эксплуатации потребует дообучения моделей. В дальнейшем целесообразен переход к автоматизированной разметке на основе данных бортовых систем диагностики.

Заключение

В рамках исследования создали и проверили на практике процедуру предиктивного обслуживания силового привода электромотоцикла. Она опирается на потоки данных IoT и алгоритм Random Forest. Исходный массив собран за 24 месяца эксплуатации 32 коммерческих машин.

Random Forest показал точность 0,964. Для класса «развивающийся дефект» F1-доля равна 0,876 при полноте 0,861; это значит, что в условиях реального шума система выявляет предотказные состояния заранее. Ранжирование признаков показало, что в прогнозе отказов ведущую роль играют амплитуды на частотах дефектов подшипников, эксцесс вибрации, среднеквадратичное значение тока фазы, температура подшипников и взаимная корреляция этих параметров; благодаря этому модель сохраняет физическую интерпретируемость.

Сравнение с XGBoost, SVM и 1D CNN подтвердило превосходство Random Forest: при одинаковой точности он остаётся устойчив к шуму, проще настраивается и легко объясняется. Критерий Макнемара зафиксировал статистически значимое различие в обнаружении дефектов ($p=0,042$): алгоритм чаще находит повреждения подшипников, чем межвитковые замыкания, и этот факт указывает, где улучшать диагностику электрических неисправностей.

Описание применения генеративной модели. Во время подготовки статьи мы использовали чат-бот OpenAI ChatGPT. Критерии запроса: «Улучши формулировку аннотации на английском языке»; «Помоги перевести названия русскоязычных источников для

References»; «Помоги с оформлением таблицы». Конкретные задачи, для которых использовался искусственный интеллект: редактирование текста (стилистическая и грамматическая правка); оформление библиографического списка (перевод названий). Генерация и редактирование изображений не выполнялись. Конфиденциальные данные не загружались. Все научные результаты, методология, анализ данных и выводы получены авторами самостоятельно. Ответственность за содержание рукописи несут авторы.

Список литературы

1. Вовчок, С. С. (2025). Роль цифровых двойников в управлении жизненным циклом транспортной инфраструктуры: от проектирования до эксплуатации. *Парадигма*, (6-1), 79–84. EDN: <https://elibrary.ru/DULMBF>
2. Анохин, К. (2025, 11 декабря). Промышленность под датчиками. Почему IIoT становится ключевым элементом управления производством. *Коммерсант. Информационные технологии. Приложение*, (229), 4. <https://www.kommersant.ru/doc/8271584>
3. Нерсесов, Д. (2010). Телематические системы в автомобильной электронике. *Электроника НТБ*, (5). <https://www.electronics.ru/journal/article/85>. EDN: <https://elibrary.ru/OISQDF>
4. Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A>. EDN: <https://elibrary.ru/ARROTH>
5. Carvalho, T. P., Soares, F. A. M. N., Vita, R., et al. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024. <https://doi.org/10.1016/j.cie.2019.106024>
6. Ehsani, M., Gao, Y., Longo, S., & Ebrahimi, K. (2018). *Modern electric, hybrid electric, and fuel cell vehicles* (3rd ed.). CRC Press. 560 p. <https://doi.org/10.1201/9780429504884>
7. Gazali, M. K., Hasikin, K., Lai, K. W., et al. (2025). State-of-the-art artificial intelligence approaches for anomaly detection and remaining useful life prediction: A review. *PeerJ Computer Science*, 11, e3056. <https://doi.org/10.7717/peerj-cs.3056>. EDN: <https://elibrary.ru/HBSIDS>
8. Gong, C. S. A., Su, Ch. H. S., Chen, Yu. H., & Guu, De. Yu. (2022). How to implement automotive fault diagnosis using artificial intelligence scheme. *Micromachines*, 13(9), 1380. <https://doi.org/10.3390/mi13091380>. EDN: <https://elibrary.ru/SGBCEJ>
9. International Energy Agency. (2023). *Global EV outlook 2023*. IEA Publications. <https://www.iea.org/reports/global-ev-outlook-2023>

10. Jardine, A. K. S., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), 1483–1510. <https://doi.org/10.1016/j.ymsp.2005.09.012>
11. Komala, C. R., Varalatchoumy, M., Jadagerimath, A. N., Prakash, S., Praveena, H. D., & Venkatamuni, T. (2026). Wireless sensor networks for real-time health monitoring of electric powertrains. *International Journal of Vehicle Structures and Systems*. <https://yanthrika.com/eja/index.php/ijvss/article/view/3667>
12. Lee, J., et al. (2020). Predictive maintenance of machinery: A review. *Journal of Manufacturing Science and Engineering*, 142(11), 110801. <https://doi.org/10.1115/1.4048156>
13. Lei, Y., Yang, B., Jiang, X., et al. (2020). Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mechanical Systems and Signal Processing*, 138, 106587. <https://doi.org/10.1016/j.ymsp.2019.106587>. EDN: <https://elibrary.ru/MIFFQO>
14. Li, X., et al. (2021). Industrial Internet of Things for smart manufacturing: A review. *IEEE Internet of Things Journal*, 8(11), 9010–9030. <https://doi.org/10.1109/JIOT.2020.3040678>
15. Loukas, I., Pardalos, P. M., & Vouros, G. A. (2024). Automotive fault nowcasting with machine learning and natural language processing. *Machine Learning*, 113, 843–861. <https://doi.org/10.1007/s10994-023-06398-7>. EDN: <https://elibrary.ru/UTBKGV>
16. (2020). Machine learning models applied to predictive maintenance in automotive engine components. B: *Proceedings of the 1st International Electronic Conference on Actuator Technology*. MDPI. <https://doi.org/10.3390/IeCAT2020-08503>
17. (2025). Random forest-based machine failure prediction: A performance comparison. *Applied Sciences*, 15(16), 8841. <https://doi.org/10.3390/app15168841>. EDN: <https://elibrary.ru/HTWIGC>
18. Wu, D., Jennings, C., Terpenney, J., et al. (2017). A comparative study on machine learning algorithms for smart manufacturing: Tool wear prediction using random forests. *Journal of Manufacturing Science and Engineering*, 139(7). <https://doi.org/10.1115/1.4036350>
19. Wu, M., Goh, K. W., Chaw, K. H., et al. (2024). An intelligent predictive maintenance system based on random forest for addressing industrial conveyor belt challenges. *Frontiers in Mechanical Engineering*, 10, 1383202. <https://doi.org/10.3389/fmech.2024.1383202>. EDN: <https://elibrary.ru/BWCWFL>
20. Zhao, R., Yan, R., Chen, Z., et al. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213–237. <https://doi.org/10.1016/j.ymsp.2018.05.050>

References

1. Vovchok, S. S. (2025). The role of digital twins in managing the life cycle of transport infrastructure: from design to operation. *Paradigma*, (6-1), 79–84. EDN: <https://elibrary.ru/DULMBF>
2. Anokhin, K. (2025, December 11). Industry under sensors: Why IIoT is becoming a key element of production management. *Kommersant. Information Technologies. Supplement*, (229), 4. <https://www.kommersant.ru/doc/8271584>
3. Nersesov, D. (2010). Telematic systems in automotive electronics. *Electronics NTB*, (5). <https://www.electronics.ru/journal/article/85>. EDN: <https://elibrary.ru/OISQDF>
4. Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A>. EDN: <https://elibrary.ru/ARROTH>
5. Carvalho, T. P., Soares, F. A. M. N., Vita, R., et al. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024. <https://doi.org/10.1016/j.cie.2019.106024>
6. Ehsani, M., Gao, Y., Longo, S., & Ebrahimi, K. (2018). *Modern electric, hybrid electric, and fuel cell vehicles* (3rd ed.). CRC Press. 560 p. <https://doi.org/10.1201/9780429504884>
7. Gazali, M. K., Hasikin, K., Lai, K. W., et al. (2025). State-of-the-art artificial intelligence approaches for anomaly detection and remaining useful life prediction: A review. *PeerJ Computer Science*, 11, e3056. <https://doi.org/10.7717/peerj-cs.3056>. EDN: <https://elibrary.ru/HBSIDS>
8. Gong, C. S. A., Su, Ch. H. S., Chen, Yu. H., & Guu, De. Yu. (2022). How to implement automotive fault diagnosis using artificial intelligence scheme. *Micromachines*, 13(9), 1380. <https://doi.org/10.3390/mi13091380>. EDN: <https://elibrary.ru/SGBCEJ>
9. International Energy Agency. (2023). *Global EV outlook 2023*. IEA Publications. <https://www.iea.org/reports/global-ev-outlook-2023>
10. Jardine, A. K. S., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), 1483–1510. <https://doi.org/10.1016/j.ymssp.2005.09.012>
11. Komala, C. R., Varalatchoumy, M., Jadagerimath, A. N., Prakash, S., Praveena, H. D., & Venkatamuni, T. (2026). Wireless sensor networks for real-time health monitoring of electric powertrains. *International Journal of Vehicle Structures and Systems*. <https://yanthrika.com/eja/index.php/ijvss/article/view/3667>
12. Lee, J., et al. (2020). Predictive maintenance of machinery: A review. *Journal of Manufacturing Science and Engineering*, 142(11), 110801. <https://doi.org/10.1115/1.4048156>

13. Lei, Y., Yang, B., Jiang, X., et al. (2020). Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mechanical Systems and Signal Processing*, 138, 106587. <https://doi.org/10.1016/j.ymssp.2019.106587>. EDN: <https://elibrary.ru/MIFFQO>
14. Li, X., et al. (2021). Industrial Internet of Things for smart manufacturing: A review. *IEEE Internet of Things Journal*, 8(11), 9010–9030. <https://doi.org/10.1109/JIOT.2020.3040678>
15. Loukas, I., Pardalos, P. M., & Vouros, G. A. (2024). Automotive fault nowcasting with machine learning and natural language processing. *Machine Learning*, 113, 843–861. <https://doi.org/10.1007/s10994-023-06398-7>. EDN: <https://elibrary.ru/UTBKGV>
16. (2020). Machine learning models applied to predictive maintenance in automotive engine components. B: *Proceedings of the 1st International Electronic Conference on Actuator Technology*. MDPI. <https://doi.org/10.3390/IeCAT2020-08503>
17. (2025). Random forest-based machine failure prediction: A performance comparison. *Applied Sciences*, 15(16), 8841. <https://doi.org/10.3390/app15168841>. EDN: <https://elibrary.ru/HTWIGC>
18. Wu, D., Jennings, C., Terpenney, J., et al. (2017). A comparative study on machine learning algorithms for smart manufacturing: Tool wear prediction using random forests. *Journal of Manufacturing Science and Engineering*, 139(7). <https://doi.org/10.1115/1.4036350>
19. Wu, M., Goh, K. W., Chaw, K. H., et al. (2024). An intelligent predictive maintenance system based on random forest for addressing industrial conveyor belt challenges. *Frontiers in Mechanical Engineering*, 10, 1383202. <https://doi.org/10.3389/fmech.2024.1383202>. EDN: <https://elibrary.ru/BWCWFL>
20. Zhao, R., Yan, R., Chen, Z., et al. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213–237. <https://doi.org/10.1016/j.ymssp.2018.05.050>

ДААННЫЕ ОБ АВТОРАХ

Сафуллин Рамиль Наилевич, аспирант

*Казанский государственный энергетический университет
ул. Красносельская, 51, г. Казань, 420066, Российская Федерация
r.safullin@mail.ru*

Исавнин Алексей Геннадьевич, профессор, доктор физико-математических наук, профессор кафедры бизнес-информатики и математических методов в экономике

*Набережночелнинский институт (филиал) Казанского федерального университета
пр-т Мира, 68/19 (1/18), г. Набережные Челны, 423812, Российская Федерация
isavnin@mail.ru*

DATA ABOUT THE AUTHORS

Ramil N. Safullin, graduate student

*Kazan State Power Engineering University
51, Krasnoselskaya Str., Kazan, 420066, Russian Federation
r.safullin@mail.ru
ORCID: <https://orcid.org/0009-0001-7425-6434>*

Alexey G. Isavnin, Professor, Doctor of Physical and Mathematical Sciences, Professor in the Department of Business Informatics and Mathematical Methods in Economics

*Kazan (Volga region) Federal University, Naberezhnye Chelny Institute
68/19, Mira Ave., Naberezhnye Chelny, 423812, Russian Federation
isavnin@mail.ru
SPIN-code: 5509-1687
ORCID: <https://orcid.org/0000-0001-6413-3329>
ResearcherID: M-7336-2015
Scopus Author ID: 6603223931*

Поступила 02.02.2026

После рецензирования 04.03.2026

Принята 09.03.2026

Received 02.02.2026

Revised 04.03.2026

Accepted 09.03.2026