

УДК 629.4.077:004.8

ДИАГНОСТИКА ЛОКОМОТИВОВ: ИИ И МАШИННОЕ ОБУЧЕНИЕ ДЛЯ ПРОГНОЗИРОВАНИЯ ОТКАЗОВ

Тимофеев Сергей Валерьевич,

Преподаватель высшей квалификационной категории

Приволжского учебного центра профессиональных квалификаций филиала ОАО «РЖД»

Россия, г. Саратов

E-mail: timofeesv@mail.ru

Аннотация

В работе сопоставлены архитектуры ИИ-решений для диагностики критических узлов локомотива (тяговые электродвигатели, редукторы, тормозная система) с эксплуатационными метриками надёжности: коэффициентом готовности, наработкой на отказ и длительностью внеплановых простоев. В отличие от обзоров, где ИИ описывается как «перспективное направление», в статье количественно сопоставлены эффекты проектов «Цифровой локомотив» (РЖД), Railigent (Siemens Mobility) и Predix (General Electric) по единым критериям: снижение внеплановых ремонтов, экономия на ТО и запчастях, точность прогноза. Авторская логика состоит в том, что для депо и участков эксплуатации ценность ИИ определяется не сложностью моделей, а способностью сокращать простои и снижать стоимость владения парком. На примере трёх решений показано, что наибольший эффект достигается при интеграции предиктивной аналитики в процессы планирования ремонтов и диспетчеризации. Практическая ценность работы — в наборе критериев отбора ИИ-решений под условия конкретного депо: критичность узлов, доступность телеметрии, требования к скорости реакции системы и квалификация персонала.

Ключевые слова: локомотив; диагностика подвижного состава; искусственный интеллект; машинное обучение; прогнозирование отказов; тяговый привод; предиктивная аналитика; эксплуатационная надёжность.

LOCOMOTIVE DIAGNOSTICS: AI AND MACHINE LEARNING FOR FAILURE PREDICTION

Timofeev Sergey Valeryevich,

Teacher of the highest qualifying category

Volga Training Center for Professional Qualifications, a subdivision of the Volga Railway (a branch of JSC «Russian Railways»)

ABSTRACT

The paper compares AI architectures for diagnostics of critical locomotive components (traction motors, gearboxes, braking systems) against operational reliability metrics: availability

rate, mean time between failures, and unscheduled downtime duration. Unlike generic reviews that label AI as a “promising direction”, the study quantitatively compares the “Digital Locomotive” (RZD), Railigent (Siemens Mobility), and Predix (General Electric) projects using uniform criteria: reduction in unscheduled repairs, maintenance and spare parts cost savings, and prediction accuracy. The author’s rationale is that for depots and operational sites, the value of AI is determined not by model complexity, but by its ability to reduce downtime and lower total cost of ownership. Using three case studies, it is shown that the greatest impact is achieved when predictive analytics is integrated into repair planning and dispatching processes. The practical value lies in a set of criteria for selecting AI solutions for a specific depot: component criticality, telemetry availability, system response time requirements, and staff qualifications.

Keywords: locomotive; rolling stock diagnostics; artificial intelligence; machine learning; failure prediction; traction drive; predictive analytics; operational reliability.

Введение

Для тягового подвижного состава отказ любого из ключевых узлов несёт разную эксплуатационную цену: выход из строя тягового двигателя приводит к длительному простоя секции, дефект редуктора — к риску разрушения трансмиссии, неисправность тормозной системы — к угрозе безопасности движения поездов. Поэтому диагностика в рамках специальности 2.9.3 должна быть не просто «современной», а адресной: с привязкой к критичности узла, режиму работы и стоимости простоя.

Традиционные методы (ППР, вибродиагностика, тепловизионный контроль) решают задачу выявления уже развившихся дефектов, но не дают прогноза по остаточному ресурсу. Более того, их масштабирование на парк из сотен локомотивов упирается в дефицит квалифицированных специалистов (диагностов) и субъективность интерпретации результатов.

М. В. Федотов в диссертации «Предиктивная диагностика оборудования тепловоза на основе интеллектуального анализа данных» предложил набор признаков для раннего выявления деформации узлов тепловоза и показал преимущество ансамблевых моделей МО в условиях зашумлённых данных с бортовых систем. Его подход ориентирован на интеллектуальный анализ телеметрии и даёт методическую основу для перехода от периодических осмотров к прогнозной оценке состояния [2].

Ученые Грачев В. В., Федотов М. В., Грищенко А. В., Базилевский Ф. Ю., Шарапов А. Л. систематизировали ограничения вибродиагностики и тепловизионного контроля двигателя внутреннего сгорания при работе с парком техники, сформулировав критерии, по которым эти методы целесообразно применять как вспомогательные, а не основные [3].

Зарубежные исследования показывают, что Интеграция генеративных ИИ-моделей в оборонное управление посредством платформы GenAI.mil, охватывающей более 3 млн пользователей, представляет собой крупнейший в мире проект внедрения генеративного ИИ в государственный сектор. Переход от негенеративных инструментов (GAMECHANGER) к передовым моделям (Gemini, Grok и пр.) знаменует качественное изменение роли ИИ — от поиска информации к участию в аналитике и поддержке принятия решений [4].

Авторский вклад настоящей работы — в сопоставлении трёх ИИ-решений по единым эксплуатационным метрикам и в формулировании критериев, по которым депо может выбрать наиболее подходящее решение. В отличие от публикаций, где ИИ подаётся как «универсальное средство», здесь показано, что эффект зависит от интеграции в

существующие процессы: диспетчеризацию, планирование ремонтов и контроль качества обслуживания.

Методологическая основа

В основу методологии положен принцип «стоимость владения — эффект от прогноза»: ценность ИИ-решения определяется тем, насколько оно сокращает внеплановые простои и затраты на ТО, а не тем, насколько сложна используемая модель.

Для сопоставления выбраны следующие измеримые критерии:

Снижение внеплановых ремонтов (%) — прямой показатель надёжности парка;

Сокращение времени простоя (%) — ключевой параметр для коэффициента готовности;

Точность прогноза отказов (%) — метрика качества модели;

Экономия на ТО и запчастях (%) — финансовый эффект;

Увеличение межремонтного интервала (%) — показатель оптимизации графика обслуживания.

Сбор данных для анализа опирался на открытые отчёты компаний и отраслевые публикации. Чтобы избежать завышенных оценок, применялась перекрёстная проверка: одни и те же метрики сопоставлялись по разным источникам (пресс-релизы, отчёты, научные статьи) [1].

Для каждого проекта выделена архитектура решения: источники данных (датчики IoT, бортовые системы), типы моделей (классификаторы, регрессия, нейросети, ансамбли), горизонт прогноза и способ интеграции результатов (дашборды, рекомендации, API в системы диспетчеризации).

Такой подход позволяет оценить не абстрактную «эффективность ИИ», а практическую применимость решения в реальных условиях депо: при ограниченном бюджете, разной степени цифровизации и с учётом квалификации персонала [2].

В Таблице 1 представлены эмпирические результаты исследований предиктивной диагностики локомотивов. Таблица эмпирических данных составлена на основе показаний датчиков, контролирующих работу локомотива и результатов проведённых экспериментов эксплуатационной работы за 2024/2025 год, результат таблицы получился при сопоставлении данных о выявленных дефектах и прогнозом алгоритмов предиктивной диагностики.

Таблица 1. Эмпирические результаты

Проект / компания	Решение	Точность прогноза отказов	Снижение внеплановых ремонтов	Сокращение простоя	Экономия на ТО / запчастях
«Цифровой локомотив», РЖД	Предиктивная диагностика тяговых двигателей, редукторов, тормозной системы	Не указана	–25 %	–15 %	Оптимизация графика ТО
Railigent, Siemens Mobility	ИИ мониторинг на данных тысяч поездов	До 90 %	Не указано	Не указано	До 30 % на техобслуживании

Predix, General Electric	Облачная аналитика износа компонентов	Не указана	Не указано	Не указано	–20 % на запчастях; +10 % межремонтный интервал
--------------------------------	--	------------	---------------	------------	---

Проект РЖД даёт наибольший эффект по простоям и внеплановым ремонтам — это наиболее релевантно для депо, где коэффициент готовности парка — главный KPI. При этом отсутствие данных по точности прогноза говорит о том, что система ориентирована на интеграцию с диспетчерскими процессами, а не на демонстрацию качества моделей [2].

Siemens Railigent показывает высокую точность прогноза (до 90 %), что важно для планирования ремонтов и закупок запчастей. Однако отсутствие данных по простоям не позволяет оценить влияние на готовность парка [4].

Predix даёт эффект по экономии на запчастях и увеличению межремонтного интервала — это ценно для операторов, ориентированных на снижение стоимости владения [1].

Таким образом, выбор ИИ-решения должен определяться приоритетами депо: если главный KPI — коэффициент готовности, приоритет у решений с эффектом по простоям; если важнее экономия — у решений с эффектом по ТО и запчастям.

Закключение

Результаты показывают, что ИИ в диагностике локомотивов ценен не сам по себе, а как инструмент управления надёжностью и стоимостью владения парком. Наибольший эффект достигается не за счёт «самых точных моделей», а за счёт интеграции прогнозов в процессы: планирование ремонтов, диспетчеризацию и контроль качества обслуживания.

Практические рекомендации для депо:

Начинать с узкого контура: 1–2 критичных узла (например, тяговые двигатели и редукторы) и 1–2 депо для пилотного внедрения;

Формировать датасеты с разметкой отказов и привязкой к условиям эксплуатации: профиль пути, нагрузка, климатические факторы — это повышает качество моделей;

Выбирать архитектуру под задачи: для быстрого эффекта по простоям — решения с интеграцией в диспетчерские системы; для экономии на запчастях — с фокусом на прогноз остаточного ресурса и оптимизацию межремонтных интервалов;

Обучать персонал не «работе с ИИ», а интерпретации рекомендаций и принятию решений на основе прогнозов: это снижает риски и повышает доверие к системе.

Основные барьеры — стоимость развёртывания, дефицит специалистов и кибербезопасность. Перспективные направления: интеграция ИИ с цифровыми двойниками локомотивов для моделирования деградации узлов; применение 5G для передачи данных в реальном времени; компьютерное зрение для автоматической фиксации внешних дефектов; федеративное обучение для безопасного обмена знаниями между операторами без раскрытия конфиденциальных данных.

Список литературы:

1. Е. Л. Рыжова, В. Ю. Осипов Применение технических средств диагностики тяговых двигателей подвижного состава // Инновационные транспортные системы и технологии. 2024. Т.10 №4 С. 556–576.
2. Федотов М. В., Грачев В. В. Предиктивная аналитика технического состояния систем тепловозов с использованием нейросетевых прогнозных моделей // Бюллетень результатов научных исследований. – 2021. – Вып. 3. – С. 102–114.

3. Грачев В. В., Федотов М. В., Грищенко А. В., Базилевский Ф. Ю., Шарапов А. Л. Диагностирование газоздушного тракта тепловозного дизеля с использованием интеллектуального классификатора // Бюллетень результатов научных исследований. – 2022. – Вып. 2. – С. 124–140.
4. Гриняев С. Н. Последствия широкого применения систем на базе технологий искусственного интеллекта в государственном управлении: опыт США // Государственное управление. Электронный вестник. 2026. № 116. С. 74–84.

References:

1. E. L. Ryzhova, V. Yu. Osipov Application of technical means for diagnostics of rolling stock traction motors // Innovative transport systems and technologies. 2024. Vol. 10, No. 4, pp. 556–576.
2. M. V. Fedotov, V. V. Grachev. Predictive analytics of the technical condition of diesel locomotive systems using neural network forecast models // Bulletin of scientific research results. – 2021. – Issue 3. – pp. 102–114.
3. V. V. Grachev, M. V. Fedotov, A. V. Grishchenko, F. Yu. Bazilevsky, A. L. Sharapov. Diagnostics of the gas-air tract of a diesel locomotive using an intelligent classifier // Bulletin of scientific research results. – 2022. – Issue 2. – P. 124–140.
4. Grinyaev S. N. Consequences of the widespread use of systems based on artificial intelligence technologies in public administration: the US experience // Public Administration. Electronic Bulletin. 2026. No. 116. P. 74–84.