

АНАЛИЗ И ПЕРСПЕКТИВЫ АДАПТАЦИИ ОПЫТА ПРИМЕНЕНИЯ МАШИННОГО ОБУЧЕНИЯ В СИСТЕМЕ ТЕХНИЧЕСКОГО ОБСЛУЖИВАНИЯ И РЕМОНТА ГОРОДСКИХ АВТОБУСОВ

А. Н. Стрелков¹, И. М. Блянкинштейн²

Санкт-Петербургский государственный архитектурно-строительный университет, Санкт-Петербург, Россия

¹ e-mail: tema.strelkoff2016@yandex.ru

² e-mail: blyankinshtein@mail.ru

Аннотация. В условиях ускоренной цифровизации автомобильного транспорта методы машинного обучения формируют основу для перехода от устаревших реактивных и планово-предупредительных стратегий технического обслуживания к современным предиктивным подходам. Целью данной работы является систематизация информации и анализ опыта применения методов машинного обучения в системе технического обслуживания и ремонта транспортных средств с последующим выявлением на этой основе направлений для адаптации данных методов к задачам городских автобусных парков. Методология исследования базируется на анализе научно-технической литературы с применением формализованных критериев отбора, сравнительном анализе метрик эффективности ML-архитектур, а также синтезе полученных данных в рамках оценки их применимости и разработке концептуальной схемы адаптации предиктивных моделей к условиям эксплуатации городских автобусов. В настоящей работе проведен систематический анализ научных публикаций и промышленных решений в области применения ML-моделей для диагностики и прогнозирования технического состояния автомобилей за период 2020–2025 гг. Особое внимание уделено сравнительной оценке эффективности классических алгоритмов (Random Forest, XGBoost, LightGBM) и глубоких архитектур (LSTM, CNN, гибридные модели) при обработке данных, получаемых от бортовых систем. Установлено, что гибридные CNN-LSTM модели демонстрируют наивысшую точность диагностики (до 99,02%) при прогнозировании отказов электродвигателей, превосходя как классические методы, так и отдельные глубокие архитектуры. Экономический эффект от внедрения предиктивных систем включает снижение эксплуатационных затрат на 10-40%, сокращение простоев транспортных средств до 50% и повышение общей надежности парка. Вместе с тем, анализ выявил ключевые ограничения практического применения ML-решений: несбалансированность обучающих выборок из-за редкости отказов, высокие погрешности датчиков (превышающие 40% для некоторых параметров), проблемы интерпретируемости «черных ящиков» глубокого обучения и сложности интеграции с существующими ERP/CMMS системами. В работе обоснована необходимость развития Explainable AI (XAI) методов для повышения доверия специалистов к прогнозам.

Научная новизна работы заключается в разработке концептуальной схемы адаптации ML-моделей под циклический режим эксплуатации автобусов, включающий учет геопространственных данных, дорожных условий и требований к интерпретируемости прогнозов. На основе этого предложены направления дальнейших исследований для повышения точности прогнозирования остаточного ресурса ключевых агрегатов автобусов.

Ключевые слова: машинное обучение, предиктивное обслуживание, техническое обслуживание и ремонт, диагностирование на основе данных, автомобильный транспорт.

Для цитирования: Стрелков А. Н., Блянкинштейн И. М. Анализ и перспективы адаптации опыта применения машинного обучения в системе технического обслуживания и ремонта городских автобусов // Интеллект. Инновации. Инвестиции. – 2026. – № 3. – С. 82–96. – <https://doi.org/10.25198/2077-7175-2026-3-82>.



Review article

ANALYSIS AND PROSPECTS OF ADAPTATION OF EXPERIENCE IN APPLYING MACHINE LEARNING IN THE SYSTEM OF TECHNICAL MAINTENANCE AND REPAIR OF CITY BUSES

A. N. Strelkov¹, I. M. Blyankinshtein²

Saint-Petersburg State University of Architecture and Civil Engineering, Saint-Petersburg, Russia

¹ e-mail: tema.strelkoff2016@yandex.ru

² e-mail: blyankinshtein@mail.ru

Abstract. In the context of accelerated digitalization of automotive transportation, machine learning methods are forming the foundation for transitioning from outdated reactive and preventive maintenance strategies to modern predictive approaches. The aim of this work is to systematize information and analyze the experience of applying machine learning methods in the maintenance and repair systems of vehicles, with the subsequent identification of directions for adapting these methods to the specific challenges of urban bus fleets. The research methodology is based on the analysis of scientific and technical literature using formalized selection criteria, a comparative analysis of the efficiency metrics of ML architectures, and the synthesis of the obtained data in order to assess their applicability and develop a conceptual framework for adapting predictive models to the operating conditions of city buses. A systematic review of scientific publications and industrial solutions on the application of ML models for diagnosing and forecasting the technical condition of vehicles during the 2020–2025 period has been conducted. Particular attention is paid to a comparative assessment of the effectiveness of classical algorithms (Random Forest, XGBoost, LightGBM) and deep architectures (LSTM, CNN, hybrid models) when processing data obtained from onboard systems. It has been established that hybrid CNN-LSTM models demonstrate the highest diagnostic accuracy (up to 99.02%) in predicting electric motor failures, outperforming both classical methods and individual deep architectures. The economic benefits of implementing predictive systems include a reduction in operational costs by 10–40%, a decrease in vehicle downtime by up to 50%, and an improvement in overall fleet reliability. However, the analysis has revealed key limitations to the practical application of ML solutions: imbalanced training datasets due to the rarity of failures, high sensor inaccuracies (exceeding 40% for certain parameters), interpretability issues associated with deep learning “black boxes,” and integration challenges with existing ERP/CMMS systems. The necessity of developing Explainable AI (XAI) methods to increase specialists’ trust in predictions is substantiated. The scientific novelty of the work lies in the development of a conceptual framework for adapting ML models to the cyclic operation mode of buses, which includes incorporating geospatial data, road conditions, and requirements for forecast interpretability. Based on this, directions for future research are proposed to enhance the accuracy of residual life prediction for critical bus components.

Key words: machine learning, predictive maintenance, maintenance and repair, data-driven diagnostics, automotive transport.

Cite as: Strelkov, A. N., Blyankinshtein, I. M. (2026) [Analysis and Prospects of Adaptation of Experience in Applying Machine Learning in the System of Technical Maintenance and Repair of City Buses]. *Intellect. Innovacii. Investicii* [Intellect. Innovations. Investments]. Vol. 3, pp. 82–96. – <https://doi.org/10.25198/2077-7175-2026-3-82>.

Введение

В условиях стремительной цифровизации транспортного сектора машинное обучение (ML) становится ключевым инструментом повышения эффективности систем технического обслуживания и ремонта (ТОиР) автомобилей. Современные подходы к обслуживанию эволюционируют от реактивных и планово-предупредительных стратегий к предиктивной аналитике, основанной на данных, поступающих от бортовых и внешних сенсоров.

Анализ литературы последних лет [1; 33; 22] показывает, что подавляющее большинство исследо-

ваний в области применения машинного обучения в системе ТОиР ориентированы на легковые автомобили, грузовой транспорт или промышленное оборудование. Вместе с тем, городской пассажирский транспорт, а в частности автобусы, обладает существенной спецификой, требующей адаптации универсальных ML-решений. В отличие от магистральных тягачей, работающих преимущественно в установившихся режимах движения или карьерной техники, где ключевым фактором является статическая нагрузка, эксплуатация городского автобуса характеризуется высокой динамикой переходных процессов.

Специфика режима работы городского автобуса обусловлена, прежде всего, значительным количеством циклов «разгон-торможение», что обусловлено частыми остановками для посадки и высадки пассажиров, остановками на светофорах и во время движения в условиях затора в периоды высокой интенсивности транспортного потока при отсутствии выделенной полосы движения для общественного транспорта. Как следствие высокой цикличности «разгон-торможение» в структуре рабочего цикла силового агрегата преобладают нестационарные режимы, а именно активный разгон, принудительное торможение двигателем и функционирование в режиме холостого хода во время остановок, что также влечет за собой высокую интенсивность изнашивания трансмиссии и тормозной системы. Дальнейшим развитием описанной картины выступает специфическое влияние внешней среды: перемещение в плотном транспортном потоке со средней технической скоростью в диапазоне 15–25 км/ч формирует характерные вибрационные и тепловые нагрузки на элементы конструкции и агрегаты, принципиально отличающиеся от нагрузок, типичных для установившихся высокоскоростных режимов магистрального сообщения.

Эта специфика определяет основные требования к системам предиктивного обслуживания, которые не всегда могут быть удовлетворены путем прямого переноса общих ML-моделей.

Таким образом, возникает научная проблема: несмотря на обилие исследований в области применения ML для диагностики автомобилей, отсутствует систематический анализ, оценивающий применимость существующих методов и выявляющий перспективные подходы, адаптируемые под специфические условия эксплуатации городского пассажирского транспорта.

Исходя из этого, цель данной работы заключается в систематизации информации и анализе опыта применения методов машинного обучения в системе технического обслуживания и ремонта транспортных средств с последующим выявлением на этой основе направлений для адаптации данных методов к задачам городских автобусных парков.

В рамках данной цели решаются следующие задачи:

- обзор различных подходов к техническому обслуживанию и ремонту подвижного состава;
- сравнительный анализ эффективности различных ML-моделей – от классических ансамблевых методов до архитектур глубокого обучения – в решении диагностических задач;
- выявление ключевых ограничений и вызовов, препятствующих практическому внедрению предик-

тивной аналитики, с акцентом на проблемы, критичные для городского общественного транспорта;

- определение перспективных направлений развития применения машинного обучения в системе ТОиР, ориентированных на специфику городских автобусов.

Работа ориентирована на специалистов в области эксплуатации автомобильного транспорта и призвана обобщить современные достижения в области интеллектуального технического обслуживания для формирования базы под последующие прикладные исследования.

Методология исследования

Для достижения поставленной цели и решения задач исследования применялся комплексный методологический подход, сочетающий методы систематического обзора, сравнительно-сопоставительного анализа и структурно-логического синтеза. Выбор методологического инструментария обусловлен необходимостью не только обобщения существующих данных, но и выявления адаптационного потенциала ML-архитектур применительно к специфике эксплуатации городского пассажирского транспорта.

Первичный сбор теоретической и эмпирической базы осуществлялся посредством систематического поиска в рецензируемых научных базах данных (ScienceDirect, eLibrary.ru, ResearchGate, Google Scholar) за период с января 2020 по декабрь 2025 года. Поисковая стратегия базировалась на использовании комбинаций ключевых терминов на русском и английском языках: машинное обучение / machine learning, предиктивное обслуживание / predictive maintenance, техническое обслуживание и ремонт / maintenance and repair, диагностика автомобилей / vehicle diagnostics, глубокое обучение / deep learning, городские автобусы / urban buses, прогнозирование отказов / failure prediction, OBD-II / CAN-шина / CAN bus.

Отбор источников проводился на основе формализованных критериев включения:

- наличие численных показателей эффективности ML-моделей;
- описание практических кейсов применения ML на автомобильном транспорте или оборудовании с аналогичными режимами работы (ДВС, электродвигатели, трансмиссии);
- использование данных, получаемых от бортовых систем или внешних сенсоров, применимых для автотранспорта;
- публикации в рецензируемых журналах или материалах авторитетных конференций.

В результате первичного скрининга и последую-

щей оценки полнотекстовых версий в итоговую аналитическую выборку вошло 39 источников, наиболее полно соответствующих заявленным требованиям. Для решения поставленных задач были применены следующие методы:

- метод систематического обзора и классификации использовался для решения первой и второй задач. Он позволил структурировать разрозненные данные о подходах к ТОиР и сгруппировать ML-модели по архитектурным признакам (классические ансамблевые алгоритмы, рекуррентные и сверточные сети, гибридные и трансформерные архитектуры);

- сравнительный анализ метрик эффективности применялся для оценки результатов диагностики и прогнозирования. На основе сопоставления количественных показателей точности, скорости обучения и вычислительной сложности было выявлено превосходство гибридных CNN-LSTM моделей над базовыми алгоритмами в задачах прогнозирования остаточного ресурса;

- метод критериальной оценки адаптационного потенциала был задействован для решения третьей и четвертой задач. В рамках данного метода каждый рассмотренный алгоритм оценивался по комплексу эксплуатационных критериев, специфичных для автобусных парков: чувствительность к циклическим нагрузкам («разгон–торможение»), требования к интерпретируемости для линейного персонала, возможность работы в распределённой архитектуре «борт–облако» и устойчивость к шумам и погрешностям данных CAN-шины;

- структурно-логический синтез и концептуальное моделирование позволили интегрировать полученные выводы в единую схему адаптации предиктивных систем. Данный метод обеспечил формализацию требований к предобработке данных, распределению вычислительной нагрузки и интеграции прогнозов с CMMS/ERP-системами управления парком.

Комплексное применение перечисленных методов позволило провести оценку их применимости в условиях городской маршрутной сети. Результатом методологической работы стала классификация методов с указанием приоритетов их внедрения и разработка концепции архитектуры гибридной системы предиктивного мониторинга технического состояния городского автобуса.

Трансформация стратегий обслуживания: от планово-предупредительного подхода к предиктивной аналитике

Эволюция обслуживания автотранспорта сместилась от реактивных и регламентных методов к стратегиям на основе данных, где ML фокусируется на управлении состоянием ТС, а не самими средствами [33; 22; 1]. Реактивное обслуживание ведет к простоям, дорожному ремонту и рискам¹ [1], планово-предупредительное – к неэффективной замене компонентов или пропуску отказов [3]. Две трети предприятий ежемесячно теряют до \$125 тыс./час из-за простоев².

Внедрение CBM (ремонт по данным датчиков) [25] и PdM (прогнозирование отказов и RUL через ML) заменяет традиционные методы. PdM анализирует исторические и текущие данные для точных прогнозов, реализуя концепцию «just in time»: сокращение простоев, затрат и рост надежности [1; 33]. ML-модели адаптируются к условиям эксплуатации, повышая точность [4].

Экономический эффект PdM: снижение затрат на обслуживание на 10–40%, простоев – до 50%. Системы Volvo Trucks и Mack Trucks сократили время диагностирования на 70%, ремонта и простоев – на 25%³. IoT/AI в логистике уменьшили поломки на 25% [2] и простои на 30% [9]. Рынок PdM вырастет с \$7,2 млрд (2024 г.) до \$28,2 млрд к 2030 г., а в автопроме ежегодный эффект – \$34 млрд [33].

Ключевые задачи PdM – обнаружение аномалий (One-Class SVM, ROCKET³) [1], классификация отказов и прогнозирование RUL [1; 23]. Для их решения используются Random Forest, SVM, LSTM и CNN. Выбор метода зависит от данных, меток и ресурсов. ML-аналитика формирует управление жизненным циклом ТС на основе данных, обеспечивая эффективность и надежность.

Сравнительный анализ машинно-обученных моделей: от классических алгоритмов до глубокого обучения

Классические ML-алгоритмы, особенно ансамблевые методы (RF, градиентный бустинг, XGBoost, LightGBM, CatBoost), остаются основой систем ТО автомобилей, благодаря скорости обучения и способности выявлять нелинейные зависимости без сложной инженерии признаков [39]. Improved Random Forest (IRF) для прогнозирования отказов литий-ион-

¹ The Impact of AI and ML on Predictive Maintenance in Car Manufacturing // Arshon Technology. – URL: <https://arshon.com/blog/the-impact-of-ai-and-ml-on-predictive-maintenance-in-car-manufacturing/> (accessed: 01.11.2025).

² Revolutionizing Automotive Industry with AI-Powered Predictive Maintenance // FPTsoftware. – URL: <https://fptsoftware.com/resource-center/blogs/revolutionizing-automotive-industry-with-ai-powered-predictive-maintenance> (accessed: 01.11.2025).

³ Component Failure Prediction Project Using Machine Learning | Learnbay // YouTube. – URL: <https://www.youtube.com/watch?v=VepPimLuwcl> (accessed: 01.11.2025).

ных аккумуляторов достиг $R^2 = 0.9995$ и точности 99.99% [18].

RF популярен в диагностировании электромобилей: 98.31% точности, 98.17% полноты и F1-меры 98.19% для 11 компонентов, превзойдя KNN и SVM [13]. На сложных данных он показал 99.50% и 88.73% точности, опередив MLP и Transformer [39; 5], но склонен к переобучению, как в исследовании Volvo Cars [16].

Градиентный бустинг (XGBoost, LightGBM) корректирует ошибки предыдущих моделей. XGBoost лидировал в прогнозировании посещений сервисов по F1-score и AUC [32], достиг 98% точности в диагностировании авиадвигателей [31]. LightGBM показал 99.16% точности при диагностировании батарей NEV [36].

Несбалансированность данных из-за редких отказов⁴ [13] решается через SMOTE [20; 11] и взвешивание классов [13]. В исследовании Mahiyudin et al. Gradient Booster после SMOTE превзошел другие модели, тогда как Decision Tree имел лучший recall на исходных данных, подтверждая приоритет полноты в PdM [20].

Оптимизация RF генетическими алгоритмами (GA) в диагностировании топливных элементов позволила обогнать XGBoost и Adaboost [28]. Классические модели обеспечивают интерпретируемость через SHAP, повышая доверие инженеров [13], в отличие от «черных ящиков» Deep Learning. Обобщенные сведения касаются области применения классических ML-моделей приведены в таблице 1.

Таблица 1. Области применения классических ML-моделей

Модель	Ключевые характеристики и преимущества	Примеры применения и производительность
Random Forest (RF)	Устойчивость к переобучению, работа с коррелированными признаками, высокая точность на табличных данных, относительная скорость обучения	Диагностирование неисправностей EV (98.31% precision, 98.19% F1-score); прогноз отказов батарей (99.50% accuracy, 99.50% recall); GA-оптимизация для диагностирования топливных элементов (97.67% accuracy)
XGBoost	Высокая точность за счет градиентного бустинга, эффективность на больших объемах данных, поддержка регуляризации	Прогноз визитов в сервис (лучшая F1-score и AUC); диагностирование неисправностей авиадвигателей (98% accuracy); прогноз отказов батарей (97.84% accuracy, 0.873 F1-score)
LightGBM	Очень высокая скорость обучения и эффективность памяти, хорошая производительность на табличных данных	Диагностирование неисправностей батарей NEV (99.16% accuracy, 1.0 recall)
Support Vector Machine (SVM)	Эффективность в задачах с высокой размерностью, способность находить сложные границы разделения классов	Диагностирование неисправностей EV (96.02% precision, 95.77% F1-score); использование TF-IDF для классификации отчетов
Логистическая регрессия	Быстрое обучение, высокая интерпретируемость, хорошая базовая производительность.	Лучшая точность среди TML моделей для классификации отчетов (LinearSVC); использование в качестве базовой модели для сравнения

Источник: разработано автором Стрелковым А. Н. на основе работ [11; 28; 31; 32; 35; 36; 39]

Представленные в таблице 1 данные демонстрируют высокую эффективность классических методов в задачах классификации и прогнозирования на структурированных данных. Однако для городских автобусов, где ключевую роль играет анализ временных рядов параметров (нагрузка, температура, вибрация и т. д.) в динамике, возможности классических моделей ограничены. Они требуют трудоемкой инже-

нерии признаков для учета временных зависимостей и могут уступать архитектурам глубокого обучения (DL-архитектуры) в точности прогнозирования остаточного ресурса.

DL-архитектуры, особенно LSTM и GRU, стали стандартом для анализа временных рядов с CAN-шин, выявляя долгосрочные зависимости в деградации компонентов благодаря механизмам «забывания» [34; 13;

⁴ Predictive Maintenance Machine Learning: A Practical Guide // NeuralConcept. – URL: <https://www.neuralconcept.com/post/how-ai-is-used-in-predictive-maintenance> (accessed: 05.11.2025).

30]. В диагностировании двигателей LSTM достигла 95,2% точности и 0,968 ROC-AUC, превзойдя XGBoost (89%), но обучалась дольше (8 ч. против 2 ч.) [13].

Гибридные CNN-LSTM объединяют извлечение локальных признаков (CNN) и анализ временных зависимостей (LSTM), достигая 99,02% точности в диагностировании электродвигателей, против 97,02% у CNN и 96,13% у LSTM [15]. CNN-BiLSTM применяют для прогнозирования обслуживания [12] и сроков поставок [7], а механизм внимания повышает точность за счет фокусировки на ключевых точках [15; 17].

TCN обеспечивают параллельную обработку и быстрое обучение: в диагностировании линий электро-

передач они достигли 99,6% точности, обучаясь вдвое быстрее BiLSTM (32 эпохи против 160) с инференсом 25 мс против 30 мс [35]. Для прогнозирования RUL CNN-LSTM показал RMSE 13,34, обогнав LSTM (15,93) [24].

Трансформеры с механизмом самовнимания эффективны для автоданных: CoMTM превзошла RNN и LSTM в прогнозировании обслуживания [12], а FGA Transformer, адаптированный для CAN-шины, достиг 3062 FPS, опередив Auto-Encoder и GNN в 6–170 раз [38]. Обобщенные данные касаются области применения DL и гибридных моделей приведены в таблице 2.

Таблица 2. Области применения DL и гибридных моделей

Архитектура	Преимущества	Недостатки	Примеры применения и производительность
LSTM / GRU	Хорошо улавливают долгосрочные временные зависимости, эффективны для анализа последовательных данных	Долгое время обучения, сложность интерпретации, риск «разрушения градиента»	Диагностирование двигателя (95.2% accuracy); прогнозирование RUL (RMSE 15.93); диагностирование неисправностей ICE по звуку (68.6% accuracy)
CNN-LSTM / CNN-BiLSTM	Комбинируют способность CNN извлекать локальные признаки и LSTM/BiLSTM моделировать временные зависимости	Более сложная архитектура и настройка.	Диагностирование неисправностей EV (99.02% accuracy); прогнозирование RUL (RMSE 13.34); прогнозирование потребности в обслуживании (w-F1 41.06%)
Temporal Convolutional Network (TCN)	Параллельные вычисления, быстрое обучение, стабильность градиентов, эффективность на длинных последовательностях	Может быть менее эффективен для данных с очень разной длиной временных окон	Классификация неисправностей в линиях электропередач (99.6% accuracy, почти в 2 раза быстрее BiLSTM)
Transformer	Механизм внимания позволяет моделировать глобальные зависимости, параллельные вычисления	Высокие требования к данным и вычислительным ресурсам, сложность интерпретации	Прогнозирование потребности в обслуживании (CoMTM model outperforms multiple baselines); анализ данных CAN-шины (FGA Transformer with up to 170x speedup)

Источник: разработано автором Стрелковым А. Н. на основе работ [13; 24; 29; 15; 12; 35; 38]

Гибридные архитектуры, в особенности CNN-LSTM, показывают наилучшие результаты (до 99,02%) точности, что делает их крайне привлекательным для точной диагностики. Однако их применение в реальном времени на борту автобуса сопряжено с высокими вычислительными затратами. Для городского транспорта, где критически важна оперативность выявления предотказных состояний, перспективным представляется разработка облегченных версий гибридных моделей или гибридная схема «борт-облако», где на борту выполняется первичный анализ (аномалии), а сложные вычисления переносятся в облако.

Выбор подхода зависит от наличия меток в данных. При наличии помеченных данных о неисправностях предпочтительны модели supervised learning (RF, XGBoost, LSTM, CNN) [14]. При недостатке помеченных данных применяют unsupervised методы (DBSCAN, One-Class SVM) для обнаружения аномалий [1]. Semi-supervised подходы комбинируют помеченные и непомеченные данные для повышения точности [37].

Ключевые ограничения и вызовы в практическом внедрении предиктивной аналитики

Внедрение ML-систем предиктивного обслуживания ограничено вызовами на всех этапах жизненного

цикла. Качество данных – ключевая проблема: автомобильные данные содержат пропуски, шум и неточности (погрешность датчиков > 40%) [33; 21; 8]. Дефицит публичных наборов [14] и данных об отказах [26] затрудняет воспроизводимость исследований и прогнозирование критических поломок.

Несбалансированность классов: данные нормальной работы преобладают над записями отказов [8; 10], что приводит к игнорированию редких поломок. Методы SMOTE и взвешивание классов [1; 19] решают проблему, но могут усиливать шум.

Проблема «черного ящика» в DL-моделях снижает доверие механиков. XAI-методы (SHAP, LIME) анализируют вклад признаков (RPM, температура ОЖ) [1; 6], повышая прозрачность и надежность диагностирования [6].

Вычислительные ограничения требуют гибридной архитектуры⁵: простые модели на борту для аномалий, сложные – в облаке. Легковесные модели создаются через pruning, квантование и knowledge distillation [21; 14].

Безопасность данных CAN-шины уязвима к DoS/spoofing-атакам [27]. Соблюдение GDPR при сборе данных требует TLS, federated learning и differential privacy [21]. Интеграция с ERP/CMMS затруднена техническими и организационными барьерами [33], что требует комплексного подхода к развитию алгоритмов, инфраструктур и политик управления рисками.

Специфика ограничений для городских автобусов: перечисленные вызовы приобретают особую остроту в контексте городских автобусных парков. Цикличность эксплуатации в условиях плотного транспортного потока и частых остановок приводит к высокому износу ключевых агрегатов транспортного средства,

которые недостаточно описаны в общих моделях, обученных на данных легковых и грузовых автомобилей. Погрешности датчиков могут накапливаться быстрее из-за специфических условий эксплуатации, а проблема интерпретируемости прогнозов критична для принятия решения персоналом, отвечающим за выпуск автобусов на линию.

В представленном обзоре было рассмотрено значительное количество методов машинного обучения, однако в итоговую оценку включены лишь представительные архитектуры. Это обусловлено необходимостью фокусировки на принципиальных различиях в обработке данных, что критично для специфики городских автобусных парков. Методы с идентичными принципами работы объединены в группы, так как для задачи прогнозирования остаточного ресурса ключевым является не конкретная реализация, а возможность учета временных зависимостей. Методы линейной классификации были исключены, поскольку показали низкую эффективность в задачах обработки нелинейных данных бортовых систем в современных исследованиях [37; 39]. Приоритет отдан архитектурам, способным обрабатывать циклы переходных процессов, характерных для городского маршрута с частыми остановками, что отличает их от методов, требующих агрегации данных в статистические признаки. Практическая реализуемость в условиях авто-транспортного предприятия и интерпретируемость для персонала ремонтных служб также повлияли на отбор, что объясняет включение методов обнаружения аномалий и ансамблевых методов, несмотря на их ограничения [1; 13]. Применимость рассмотренных ранее ML-моделей к задачам ТОиР городских автобусов описана в таблице 3.

Таблица 3. Оценка применимости ML-методов к задачам ТОиР городских автобусов

Метод	Приоритет применимости	Обоснование применимости	Необходимость адаптации
Ансамблевые методы: Random Forest / XGBoost	Средний	Эффективны для статических данных (пробеги, интервалы ТО), но слабо улавливают динамику циклов «разгон-торможение»	Требуется инженерия признаков для учета цикличности маршрута
Рекуррентные сети: LSTM / GRU	Высокий	Оптимальны для анализа временных рядов CAN-шины, учитывают историю предыдущих остановок и режимов работы двигателя	Требуется оптимизация для работы на бортовых устройствах с ограниченной памятью
Гибридные модели: CNN-LSTM	Высокий	Наилучшая точность для комплексной диагностики (вибрация + температура + режим движения)	Высокие вычислительные затраты. Рекомендуется схема «борт-облако»

⁵ Predictive Maintenance in the Fleet Management Industry // Micro.ai. – URL: <https://www.micro.ai/resources/case-studies/predictive-maintenance-in-the-fleet-management-industry> (accessed: 01.11.2025).

Продолжение таблицы 3

Метод	Приоритет применимости	Обоснование применимости	Необходимость адаптации
Методы обнаружения аномалий: One-Class SVM	Высокий	Критичен для обнаружения аномалий в условиях недостатка размеченных данных об отказах (что типично для новых парков)	Требуется настройка порогов чувствительности под конкретную модель автобуса
Трансформеры: Transformer	Средний	Перспективны для долгосрочного прогнозирования ресурса, но избыточны для оперативной диагностики	Требуется снижение размерности модели (distillation)

Источник: разработано автором Стрелковым А. Н.

Перспективы дальнейших исследований

Проведенный анализ подтверждает высокий потенциал применения машинного обучения в системе ТОиР. Ключевыми источниками данных выступают OBD-II, CAN-шина, внешние сенсоры и геопространственные источники, интегрируемые с архитектурами глубокого обучения. Однако, как показал обзор, применение этих методов для городских автобусов, эксплуатируемых в циклических режимах с высокими требованиями к надежности и критической чувствительностью к простоям, остается недостаточно изученным и требует адаптации. Существующие исследования не предлагают специализированных, адаптивных решений, учитывающих особенности городского пассажирского автобусного транспорта.

На основании выявленных ограничений и потенциала различных архитектур машинного обучения, а также с учетом специфики циклического режима эксплуатации городских автобусов, в работе предлагается концептуальная схема адаптации предиктивных моделей для автобусных парков, что представлено на рисунке 1.

Данная схема учитывает ключевые вызовы, выявленные в ходе обзора литературы. В части предобработки данных принят во внимание тот факт, что в отличие от стационарного оборудования или магистральных тягачей, данные с CAN-шины городского автобуса требуют обязательного этапа детектирования циклов «разгон-торможение». Такая необходимость обусловлена тем, что деградация узлов городского транспорта зависит преимущественно от количества циклов нагружения, а не просто от наработки, что требует принципиально иного подхода к формированию признаков.

Архитектурное решение системы построено по гибридной схеме «борт-облако». Такой выбор продиктован ограниченностью вычислительных ресурсов на борту подвижного состава: ресурсоёмкие гибридные модели (CNN-LSTM) целесообразно использовать для обучения в облачной инфраструктуре или на стационарных ПК, тогда как на борту автобуса (на базе

Edge-устройств типа Raspberry Pi или Jetson) должны развёртываться оптимизированные версии моделей (ONNX/TensorRT), обеспечивающие оперативную диагностику в реальном времени.

Критически важным аспектом является обеспечение интерпретируемости прогнозов. Для повышения доверия со стороны линейного персонала и механиков система должна включать блок интерпретации на базе методов SHAP/LIME, который позволяет не просто зафиксировать риск отказа, но и объяснить его причину через анализ вклада отдельных факторов (вибрации, температуры, режимов эксплуатации). Это становится необходимым условием для принятия обоснованных решений о выпуске автобусов на линию. Наконец, практическая ценность системы определяется не столько визуализацией данных, сколько возможностью автоматической корректировки графиков технического обслуживания непосредственно в системе управления парком, что обеспечивает замкнутый контур управления эксплуатацией подвижного состава.

Следует отметить, что предложенная архитектура носит концептуально-методологический характер и представляет собой предварительный структурный каркас, определяющий общие принципы построения предиктивной системы. На текущем этапе схема выступает в качестве методологического ориентира, который подлежит дальнейшей детализации и адаптации по мере перехода к практической апробации. Отдельные алгоритмические блоки и взаимосвязи между ними будут итеративно уточняться на основе результатов эмпирических испытаний, оценки реальной вычислительной нагрузки на бортовое оборудование и специфики интеграции с действующей телематической инфраструктурой автопарков. Исходя из этого, разработанная модель формирует базу для последующих экспериментальных исследований, результаты которых определяют окончательную конфигурацию системы и степень её технологической готовности к промышленному внедрению.




Рисунок 1. Концепция архитектуры гибридной системы предиктивного мониторинга технического состояния городского автобуса

Источник: разработано автором Стрелковым А. Н.

Предложенная концепция может быть реализована через:

- разработку методики обучения и валидации гибридных ML-моделей, адаптированных под высокочастотные данные CAN-шины городских автобусов;
- создание алгоритмов предобработки данных, обеспечивающих интеграцию геопространственных и метеорологических факторов для корректного детектирования циклов нагрузки автобуса;
- разработку архитектуры взаимодействия бортовых устройств и облачных вычислительных центров для обеспечения динамической корректировки графиков ТО.

Заключение

Резюмируя полученные результаты, можно утверждать, что трансформация парадигмы технического обслуживания от реактивных и планово-предупредительных стратегий к предиктивной аналитике является экономически и технологически обоснованной. Внедрение интеллектуальных систем диагностики позволяет прогнозировать отказы с высокой точностью, что подтверждается значимым экономическим эффектом: снижением эксплуатационных затрат на 10–40%, сокращением простоев подвижного состава до 50% и существенным повышением общей надежности автобусных парков.

Сравнительный анализ архитектур показал, что гибридные CNN-LSTM модели демонстрируют наилучшие результаты в задачах диагностики (с точностью до 99,02%), превосходя классические алгоритмы. Однако их прямое перенесение на городской транспорт сталкивается с рядом критических ограничений, среди которых несбалансированность данных о редких отказах, высокие погрешности датчиков (до 40%), проблема интерпретируемости решений «черных ящиков» и сложности интеграции с существующими ERP/CMMS системами.

Ключевым выводом работы является обоснование того, что подавляющее большинство существующих исследований ориентировано на легковой или магистральный грузовой транспорт. Специфика применения ML-моделей к городскому пассажирскому транспорту, работающему в жестком циклическом режиме «разгон-торможение», остается недостаточно изученной. В настоящей работе этот пробел заполнен посредством разработки концептуальной схемы адаптации ML-моделей, которая учитывает циклический характер нагрузок, распределение вычислений между бортом и облаком, а также требования к прозрачности прогнозов.

Для развития предложенной концепции дальнейшие исследования должны быть сфокусированы на практической реализации трех взаимосвязанных технических задач, решение которых позволит сформировать валидированную методику прогнозирования отказов и оценки остаточного ресурса ключевых агрегатов, что обеспечит плавный переход автопарков от регламентного обслуживания к точному управлению техническим состоянием. Интеграция геопространственных и метеорологических данных в алгоритмы предобработки повысит адаптивность диагностических моделей к реальным городским условиям, минимизируя влияние внешних факторов на точность прогнозов. Развёртывание распределённой архитектуры «борт–облако» откроет возможность автоматической синхронизации диагностических сигналов с системами управления предприятием (CMMS/ERP), обеспечивая динамическую оптимизацию графиков технического обслуживания и сокращение неплановых простоев. При этом внедрение методов объяснимого искусственного интеллекта (XAI) станет критическим условием операционной готовности системы, гарантируя прозрачность алгоритмических рекомендаций для линейного персонала и повышая общую безопасность выпуска подвижного состава на линию.

Литература

1. Модели и алгоритмы прогнозирования технического состояния транспортных средств на основе методов нечеткой логики / Р. Н. Сафиуллин [и др.] // Вестник НЦБЖД. – 2025. – № 2(64). – С. 138–152. – EDN: KLIFSW.
2. Попов А. В., Сафиуллин Р. Н. Исследование влияния параметров режимов заряда на энергетические показатели литий-ионных аккумуляторов транспортных средств // Известия Международной академии аграрного образования. – 2023. – № 67. – С. 98–103. – EDN: RQXPBV.
3. Системный анализ внедрения цифровых технологий для обеспечения безопасности и эффективности транспортных средств / В. В. Камлюк [и др.] // Транспорт. Взгляд в будущее - TFV-24: Сборник научных статей международной научно-практической конференции, Санкт-Петербург, 07–08 ноября 2024 года. – Санкт-Петербург: Санкт-Петербургский горный университет императрицы Екатерины II, 2024. – С. 23–29. – EDN: ESNZUY.
4. Федотов М. В., Грачев В. В. Предиктивная аналитика технического состояния систем тепловозов с использованием нейросетевых прогнозных моделей // Бюллетень результатов научных исследований. – 2021. – № 3. – С. 102–114. – <https://doi.org/10.20295/2223-9987-2021-3-102-114>. – EDN: IKENIN

5. A Comparative Analysis of Advanced Machine Learning Models for Predictive Maintenance in Modern Manufacturing // IoT Digital Twin PLM. – URL: <https://iotdigitaltwinplm.com/a-comparative-analysis-of-advanced-machine-learning-models-for-predictive-maintenance-in-modern-manufacturing/> (accessed: 01.11.2025).
6. Al-Zeyadi M., et al. (2020). Deep Learning Towards Intelligent Vehicle Fault Diagnosis. *2020 International Joint Conference on Neural Networks (IJCNN)*. – <https://doi.org/10.1109/IJCNN48605.2020.9206972>. (In Eng.).
7. Amellal A., et al. (2023). Improving Lead Time Forecasting and Anomaly Detection for Automotive Spare Parts with A Combined CNN-LSTM. *Approach. Operations and Supply Chain Management: An International Journal*. – Vol. 16. – No. 2, pp. 265–278. – <https://doi.org/10.31387/oscm0530388>. (In Eng.).
8. Aydın C., Evrentuğ B. (2025) Evaluation of predictive maintenance efficiency with the comparison of machine learning models in machining production process in brake industry. *PeerJ Computer Science*. – Vol. 11, e2999. – <https://doi.org/10.7717/peerj-cs.2999>. (In Eng.).
9. Benhanifia A., et al. (2025) Systematic review of predictive maintenance practices in the manufacturing sector. *Intelligent Systems with Applications*. – Vol. 26, 200501. – <https://doi.org/10.1016/j.iswa.2025.200501>. (In Eng.).
10. Bickelhaupt S., et al. (2023). Challenges and Opportunities of Future Vehicle Diagnostics in Software-Defined Vehicles. *SAE*. – <https://doi.org/10.4271/2023-01-0847>. (In Eng.).
11. Boucerredj L., Benalia N. (2025) A comparative study of machine learning classifiers for intelligent fault diagnosis of electric vehicles based on FMECA data. *Advances in Mechanical Engineering*. – <https://doi.org/10.1177/16878132251342413>. (In Eng.).
12. Chen F., et al. (2025) Collaborative multiview time series modeling for vehicle maintenance demand prediction. *Scientific Reports*. – Vol. 15, 13058. – <https://doi.org/10.1038/s41598-025-96720-1>. (In Eng.).
13. Etukudoh E.A. (2024). Theoretical frameworks of eopfm predictive maintenance (ecopfm) predictive maintenance system. *Engineering Science & Technology Journal*. – Vol. 5. – No. 3, pp. 913–923. – <https://doi.org/10.51594/estj.v5i3.946>. (In Eng.).
14. Gong C-S. A., et al. (2022) How to Implement Automotive Fault Diagnosis Using Artificial Intelligence Scheme. *Micromachines*. – Vol. 13. – No. 9, 1380. – <https://doi.org/10.3390/mi13091380>. (In Eng.).
15. Guo C. (2023) Fault diagnosis of automobile drive based on a novel deep neural network. *Energy Harvesting and Systems*. – Vol. 11. – No. 1, pp. 20230049. – <https://doi.org/10.1515/ehs-2023-0049>. (In Eng.).
16. Hazem A., Alaa Y., Solayman, M. (2025) Offline Predictive Maintenance for Automotive Engines Using Machine Learning. *2025 Intelligent Methods, Systems, and Applications (IMSA)*, Giza, Egypt, pp. 610–615. – <https://doi.org/10.1109/IMSA65733.2025.11167090>. (In Eng.).
17. Huang K., Wang J. (2023) Short-term auto parts demand forecasting based on EEMD–CNN–BiLSTM–Attention–combination model. *Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology*. – Vol. 45. – No. 4, pp. 5449–5465. – <https://doi.org/10.3233/JIFS-224222>. (In Eng.).
18. Kumar R. S., et al. (2025) Hybrid machine learning framework for predictive maintenance and anomaly detection in lithium-ion batteries using enhanced random forest. *Scientific Reports*. – Vol. 15, 6243. – <https://doi.org/10.1038/s41598-025-90810-w>. (In Eng.).
19. Li P., et al. (2020). A Deep Learning Approach to Detect Real-Time Vehicle Maneuvers Based on Smartphone Sensors. *IEEE Transactions on Intelligent Transportation Systems*. – Vol. 23. – No. 4. – <https://doi.org/10.1109/TITS.2020.3032055>. (In Eng.).
20. Mahiyudin G., Hussain M., Dewi D. D. (2025). A Comprehensive Study on Predicting the Need for Vehicle Maintenance Using Machine Learning. *Engineering Proceedings*. – Vol. 107. – No. 1, p. 89. – <https://doi.org/10.3390/engproc2025107089>. (In Eng.).
21. Meenakshi M., Rainu N. (2023) A framework on driving behavior and pattern using On-Board diagnostics (OBD-II) tool. *Materials Today: Proceedings*. – Vol. 80. – No. 3, pp. 3762–3768. – <https://doi.org/10.1016/j.matpr.2021.07.376>. (In Eng.).
22. Melnik Yu. Machine failure prediction using machine learning: Why it is beneficial // InData Labs. – URL: <https://indatalabs.com/blog/machine-failure-prediction-machine-learning> (accessed: 01.11.2025).
23. Mishra D., et al. (2024). Fault detection and diagnosis of electric vehicles using artificial intelligence. *International Journal of Applied Power Engineering (IJAPE)*. – Vol. 13. – No. 3, p. 653. – <https://doi.org/10.11591/ijape.v13.i3.pp653-660>. (In Eng.).
24. Muthukumar G., Jyosna P. (2024). CNN-LSTM Hybrid Deep Learning Model for Remaining Useful Life Estimation. – <https://doi.org/10.48550/arXiv.2412.15998>. (In Eng.).
25. National Academies of Sciences, Engineering, and Medicine (2024) Implementing and Leveraging

Machine Learning at State Departments of Transportation. Washington, DC: The National Academies Press. – <https://doi.org/10.17226/27902>. (In Eng.).

26. Pavlopoulos J., et al. (2023) Automotive fault nowcasting with machine learning and natural language processing. – Vol. 113, pp. 843–861. – <https://doi.org/10.1007/s10994-023-06398-7>. (In Eng.).

27. Purohit Sh., Govindarasu M. (2022). ML-based Anomaly Detection for Intra-Vehicular CAN-bus Networks. *IEEE International Conference on Cyber Security and Resilience*. – pp. 233–238. – <https://doi.org/10.1109/CSR54599.2022.9850292>. (In Eng.).

28. Quan R., Zhang J., Feng Z. (2024) Remote Fault Diagnosis for the Powertrain System of Fuel Cell Vehicles Based on Random Forest Optimized with a Genetic Algorithm. *Sensors*. – Vol. 24. – No. 4, pp. 1138. – <https://doi.org/10.3390/s24041138>. (In Eng.).

29. Sánchez Torres N. N., et al. (2025). Fault Diagnosis in Internal Combustion Engines Using Artificial Intelligence Predictive Models. *Applied System Innovation*. – Vol. 8. – No. 5, pp. 147. – <https://doi.org/10.3390/asi8050147>. (In Eng.).

30. Saraswat A., et al. Predictive Maintenance of Automotive Engines Using Machine Learning and Deep Learning Techniques. *IJIRT*. – Vol. 12. – No. 1, pp. 446–455.

31. Sekar M. (2025) Machine learning based fault detection and classification for predictive maintenance of gas turbine engines: a comprehensive benchmarking analysis on various models. *Aircraft Engineering and Aerospace Technology: An International Journal*. – <https://doi.org/10.1108/AEAT-04-2025-0160>. (In Eng.).

32. Shah Ch. (2024). Machine Learning Algorithms for Predictive Maintenance in Autonomous Vehicles. *International Journal of Engineering and Computer Science*. – Vol. 13. – No. 1, pp. 26015–26032. – <https://doi.org/10.18535/ijecs/v13i01.4786>. (In Eng.).

33. Stewart A. (2024) Predictive Vehicle Maintenance: Complete 2025 Guide to AI Car Care // dialzara. – URL: <https://dialzara.com/blog/ai-predictive-maintenance-in-automotive-guide> (accessed: 01.11.2025).

34. Taheri-Garavand A., et al. (2022). Application of artificial neural networks for the prediction of performance and exhaust emissions in IC engine using biodiesel-diesel blends containing quantum dot based on carbon doped. *Energy Conversion and Management: X*. – Vol. 16, pp. 100304. – <https://doi.org/10.1016/j.ecmx.2022.100304>. (In Eng.).

35. Tunio N. A., et al. (2025). Performance Comparison Between Deep Learning Models for Fault Classification in Transmission Lines Using Time Series Data. *Energy Science & Engineering*. – Vol. 13. – No. 5, pp. 2330–2351. – <https://doi.org/10.1002/ese3.70033>. (In Eng.).

36. Wang J., Chen J. (2024) Rapid diagnosis of power battery faults in new energy vehicles based on improved boosting algorithm and big data. *Energy Informatics*. – Vol. 7, pp. 139. – <https://doi.org/10.1186/s42162-024-00439-8>. (In Eng.).

37. Xin Yu., et al. (2024). Machine learning based mechanical fault diagnosis and detection methods: a systematic review. *Measurement Science and Technology*. – Vol. 36, pp. 012004. – <https://doi.org/10.1088/1361-6501/ad8cf6>. (In Eng.).

38. Yang D., et al. (2024). A Multivariate Time Series Prediction Method for Automotive Controller Area Network Bus Data. *Electronics*. – Vol. 13. – No. 14, pp. 2707. – <https://doi.org/10.3390/electronics13142707>. (In Eng.).

39. Yang Y., Wang H. (2025). Random Forest-Based Machine Failure Prediction: A Performance Comparison. *Applied Sciences*. – Vol. 15. – No. 16, pp. 8841. – <https://doi.org/10.3390/app15168841>. (In Eng.).

References

1. Safiullin, R. N., et al. (2025) [Models and algorithms for predicting the technical condition of vehicles based on fuzzy logic methods]. *Vestnik NCBZhD* [Bulletin of the National Centralized Railway Transport]. Vol. 2 (64), pp. 138–152. (In Russ.).

2. Popov, A. V., Safiullin, R. N. (2023) [Study of the influence of charging mode parameters on the energy performance of lithium-ion batteries of vehicles]. *Izvestiya Mezhdunarodnoj akademii agrarnogo obrazovaniya* [Bulletin of the International Academy of Agrarian Education]. Vol. 67, pp. 98–103. (In Russ.).

3. Kamlyuk, V. V., et al. (2024) [Systems analysis of the implementation of digital technologies to ensure the safety and efficiency of vehicles]. *Transport. Vzglyad v budushchee – TFV-24: Sbornik nauchnykh statej mezhdunarodnoj nauchno-prakticheskoy konferencii, Sankt-Peterburg, 07–08 noyabrya 2024 goda. – Sankt-Peterburg: Sankt-Peterburgskij gornyj universitet imperatricy Ekateriny II* [Transport. Future Vision – TFV-24: Collection of scientific articles from the international scientific and practical conference, St. Petersburg, November 7–8, 2024. St. Petersburg: Empress Catherine II Saint-Petersburg Mining University], pp. 23–29. (In Russ.).

4. Fedotov, M. V., Grachev, V. V. (2021) [Predictive analytics of the technical condition of diesel locomotive systems using neural network forecast models]. *Byulleten' rezul'tatov nauchnyh issledovanij* [Bulletin of scientific research results]. Vol. 3, pp. 102–114. – <https://doi.org/10.20295/2223-9987-2021-3-102-114>. (In Russ.).
5. A Comparative Analysis of Advanced Machine Learning Models for Predictive Maintenance in Modern Manufacturing. IoT Digital Twin PLM. Available at: <https://iotdigitaltwinplm.com/a-comparative-analysis-of-advanced-machine-learning-models-for-predictive-maintenance-in-modern-manufacturing/> (accessed: 01.11.2025).
6. Al-Zeyadi, M., et al. (2020) Deep Learning Towards Intelligent Vehicle Fault Diagnosis. *2020 International Joint Conference on Neural Networks (IJCNN)*. – <https://doi.org/10.1109/IJCNN48605.2020.9206972>. (In Eng.).
7. Amellal, A., et al. (2023) Improving Lead Time Forecasting and Anomaly Detection for Automotive Spare Parts with A Combined CNN-LSTM. *Approach. Operations and Supply Chain Management: An International Journal*. – Vol. 16. No. 2, pp. 265–278. – <https://doi.org/10.31387/oscm0530388>. (In Eng.).
8. Aydın, C., Evcen, B. (2025) Evaluation of predictive maintenance efficiency with the comparison of machine learning models in machining production process in brake industry. *PeerJ Computer Science*. Vol. 11, e2999. – <https://doi.org/10.7717/peerj-cs.2999>. (In Eng.).
9. Benhanifa, A., et al. (2025) Systematic review of predictive maintenance practices in the manufacturing sector. *Intelligent Systems with Applications*. Vol. 26, 200501. – <https://doi.org/10.1016/j.iswa.2025.200501>. (In Eng.).
10. Bickelhaupt, S., et al. (2023) Challenges and Opportunities of Future Vehicle Diagnostics in Software-Defined Vehicles. *SAE*. – <https://doi.org/10.4271/2023-01-0847>. (In Eng.).
11. Boucerredj, L., Benalia, N. (2025) A comparative study of machine learning classifiers for intelligent fault diagnosis of electric vehicles based on FMECA data. *Advances in Mechanical Engineering*. – <https://doi.org/10.1177/16878132251342413>. (In Eng.).
12. Chen, F., et al. (2025) Collaborative multiview time series modeling for vehicle maintenance demand prediction. *Scientific Reports*. Vol. 15, 13058. – <https://doi.org/10.1038/s41598-025-96720-1>. (In Eng.).
13. Etukudoh, E. A. (2024) Theoretical frameworks of eopfm predictive maintenance (ecopfm) predictive maintenance system. *Engineering Science & Technology Journal*. Vol. 5. No. 3, pp. 913–923. – <https://doi.org/10.51594/estj.v5i3.946>. (In Eng.).
14. Gong, C-S. A., et al. (2022) How to Implement Automotive Fault Diagnosis Using Artificial Intelligence Scheme. *Micromachines*. Vol. 13. No. 9, 1380. – <https://doi.org/10.3390/mi13091380>. (In Eng.).
15. Guo, C. (2023) Fault diagnosis of automobile drive based on a novel deep neural network. *Energy Harvesting and Systems*. Vol. 11. No. 1, pp. 20230049. – <https://doi.org/10.1515/ehs-2023-0049>. (In Eng.).
16. Hazem, A., Alaa, Y., Solayman, M. (2025) Offline Predictive Maintenance for Automotive Engines Using Machine Learning. *2025 Intelligent Methods, Systems, and Applications (IMSA)*, Giza, Egypt, pp. 610–615. – <https://doi.org/10.1109/IMSA65733.2025.11167090>. (In Eng.).
17. Huang, K., Wang, J. (2023) Short-term auto parts demand forecasting based on EEMD–CNN–BiLSTM–Attention–combination model. *Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology*. Vol. 45. No. 4, pp. 5449–5465. – <https://doi.org/10.3233/JIFS-224222>. (In Eng.).
18. Kumar, R. S., et al. (2025) Hybrid machine learning framework for predictive maintenance and anomaly detection in lithium-ion batteries using enhanced random forest. *Scientific Reports*. Vol. 15, 6243. – <https://doi.org/10.1038/s41598-025-90810-w>. (In Eng.).
19. Li, P., et al. (2020) A Deep Learning Approach to Detect Real-Time Vehicle Maneuvers Based on Smartphone Sensors. *IEEE Transactions on Intelligent Transportation Systems*. Vol. 23. No. 4. – <https://doi.org/10.1109/TITS.2020.3032055>. (In Eng.).
20. Mahiyudin, G., Hussain, M., Dewi, D. D. (2025) A Comprehensive Study on Predicting the Need for Vehicle Maintenance Using Machine Learning. *Engineering Proceedings*. Vol. 107. No. 1, p. 89. – <https://doi.org/10.3390/engproc2025107089>. (In Eng.).
21. Meenakshi, M., Rainu, N. (2023) A framework on driving behavior and pattern using On-Board diagnostics (OBD-II) tool. *Materials Today: Proceedings*. Vol. 80. No. 3, pp. 3762–3768. – <https://doi.org/10.1016/j.matpr.2021.07.376>. (In Eng.).
22. Melnik, Yu. Machine failure prediction using machine learning: Why it is beneficial. *InData Labs*. Available at: <https://indatalabs.com/blog/machine-failure-prediction-machine-learning> (accessed: 01.11.2025).
23. Mishra, D., et al. (2024) Fault detection and diagnosis of electric vehicles using artificial intelligence. *International Journal of Applied Power Engineering (IJAPE)*. Vol. 13. No. 3, p. 653. – <https://doi.org/10.11591/ijape.v13.i3.pp653-660>. (In Eng.).

24. Muthukumar, G., Jyosna, P. (2024) CNN-LSTM Hybrid Deep Learning Model for Remaining Useful Life Estimation. – <https://doi.org/10.48550/arXiv.2412.15998>. (In Eng.).
25. National Academies of Sciences, Engineering, and Medicine (2024) Implementing and Leveraging Machine Learning at State Departments of Transportation. Washington, DC: The National Academies Press. – <https://doi.org/10.17226/27902>. (In Eng.).
26. Pavlopoulos, J., et al. (2023) Automotive fault nowcasting with machine learning and natural language processing. Vol. 113, pp. 843–861. – <https://doi.org/10.1007/s10994-023-06398-7>. (In Eng.).
27. Purohit, Sh., Govindarasu, M. (2022). ML-based Anomaly Detection for Intra-Vehicular CAN-bus Networks. *IEEE International Conference on Cyber Security and Resilience*, pp. 233–238. – <https://doi.org/10.1109/CSR54599.2022.9850292>. (In Eng.).
28. Quan, R., Zhang, J., Feng, Z. (2024) Remote Fault Diagnosis for the Powertrain System of Fuel Cell Vehicles Based on Random Forest Optimized with a Genetic Algorithm. *Sensors*. Vol. 24. No. 4, pp. 1138. – <https://doi.org/10.3390/s24041138>. (In Eng.).
29. Sánchez Torres, N. N., et al. (2025) Fault Diagnosis in Internal Combustion Engines Using Artificial Intelligence Predictive Models. *Applied System Innovation*. Vol. 8. No. 5, pp. 147. – <https://doi.org/10.3390/asi8050147>. (In Eng.).
30. Saraswat, A., et al. Predictive Maintenance of Automotive Engines Using Machine Learning and Deep Learning Techniques. *IJIRT*. Vol. 12. No. 1, pp. 446–455.
31. Sekar, M. (2025) Machine learning based fault detection and classification for predictive maintenance of gas turbine engines: a comprehensive benchmarking analysis on various models. *Aircraft Engineering and Aerospace Technology: An International Journal*. – <https://doi.org/10.1108/AEAT-04-2025-0160>. (In Eng.).
32. Shah, Ch. (2024) Machine Learning Algorithms for Predictive Maintenance in Autonomous Vehicles. *International Journal of Engineering and Computer Science*. Vol. 13. No. 1, pp. 26015–26032. – <https://doi.org/10.18535/ijecs/v13i01.4786>. (In Eng.).
33. Stewart, A. (2024) Predictive Vehicle Maintenance: Complete 2025 Guide to AI Car Care // dialzara. Available at: <https://dialzara.com/blog/ai-predictive-maintenance-in-automotive-guide> (accessed: 01.11.2025).
34. Taheri-Garavand, A., et al. (2022) Application of artificial neural networks for the prediction of performance and exhaust emissions in IC engine using biodiesel-diesel blends containing quantum dot based on carbon doped. *Energy Conversion and Management: X*. Vol. 16, pp. 100304. – <https://doi.org/10.1016/j.ecmx.2022.100304>. (In Eng.).
35. Tunio, N. A., et al. (2025) Performance Comparison Between Deep Learning Models for Fault Classification in Transmission Lines Using Time Series Data. *Energy Science & Engineering*. Vol. 13. No. 5, pp. 2330–2351. – <https://doi.org/10.1002/ese3.70033>. (In Eng.).
36. Wang, J., Chen, J. (2024) Rapid diagnosis of power battery faults in new energy vehicles based on improved boosting algorithm and big data. *Energy Informatics*. Vol. 7, pp. 139. – <https://doi.org/10.1186/s42162-024-00439-8>. (In Eng.).
37. Xin, Yu., et al. (2024) Machine learning based mechanical fault diagnosis and detection methods: a systematic review. *Measurement Science and Technology*. Vol. 36, pp. 012004. – <https://doi.org/10.1088/1361-6501/ad8cf6>. (In Eng.).
38. Yang, D., et al. (2024) A Multivariate Time Series Prediction Method for Automotive Controller Area Network Bus Data. *Electronics*. Vol. 13. No. 14, pp. 2707. – <https://doi.org/10.3390/electronics13142707>. (In Eng.).
39. Yang, Y., Wang, H. (2025). Random Forest-Based Machine Failure Prediction: A Performance Comparison. *Applied Sciences*. Vol. 15. No. 16, pp. 8841. – <https://doi.org/10.3390/app15168841>. (In Eng.).

Информация об авторах:

Артемий Николаевич Стрелков, аспирант, научная специальность 2.9.5. Эксплуатация автомобильного транспорта, Санкт-Петербургский государственный архитектурно-строительный университет, Санкт-Петербург, Россия

ORCID iD: 0009-0003-9404-6543, **ResearcherID:** OHV-1343-2025

e-mail: tema.strelkoff2016@yandex.ru

Игорь Михайлович Блянкинштейн, доктор технических наук, профессор, профессор кафедры технической эксплуатации транспортных средств, Санкт-Петербургский государственный архитектурно-строительный университет, Санкт-Петербург, Россия

ORCID iD: 0000-0001-7630-5810, **Scopus Author ID:** 57191164023

e-mail: blyankinshtein@mail.ru

Вклад соавторов:

Все авторы внесли эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

Статья поступила в редакцию: 15.01.2026; принята в печать: 22.05.2026.

Авторы прочитали и одобрили окончательный вариант рукописи.

Information about the authors:

Artemiy Nikolayevich Strelkov, postgraduate student, scientific specialty 2.9.5. Operation of road transport, Saint-Petersburg State University of Architecture and Civil Engineering, Saint-Petersburg, Russia

ORCID iD: 0009-0003-9404-6543, **ResearcherID:** OHV-1343-2025

e-mail: tema.strelkoff2016@yandex.ru

Igor Mikhailovich Blyankinshtein, Doctor of Technical Sciences, Professor, Professor of the Department of Technical Operation of Vehicles, Saint-Petersburg State University of Architecture and Civil Engineering, Saint-Petersburg, Russia

ORCID iD: 0000-0001-7630-5810, **Scopus Author ID:** 57191164023

e-mail: blyankinshtein@mail.ru

Contribution of the authors:

All authors contributed equivalently to the preparation of the publication. The authors declare no conflict of interest.

The paper was submitted: 15.01.2026.

Accepted for publication: 22.05.2026.

The authors have read and approved the final manuscript.