

Соколов Олег Аркадьевич

ФГБОУ ВО Санкт-Петербургский государственный университет гражданской авиации им.
Главного маршала авиации А.А. Новикова,

Андреев Александр Артемович

ФГБОУ ВО Санкт-Петербургский государственный университет гражданской авиации им.
Главного маршала авиации А.А. Новикова,

Хрусталеv Арсений Ярославович

ФГБОУ ВО Санкт-Петербургский государственный университет гражданской авиации им.
Главного маршала авиации А.А. Новикова.

**Экономическая эффективность применения AI/ML при переходе от
регламентированного технического обслуживания к обслуживанию по фактическому
состоянию**

Аннотация. Материал статьи завязан на поиске экономического обоснования для отказа от устаревших графиков техобслуживания в пользу подхода CBM на базе AI и ML. Почему это важно? Традиционные стратегии обслуживания давно критикуют за то, что колоссальные средства (около 30–40% бюджета) попросту выбрасываются на ветер из-за ремонтов «по расписанию», в то время как каждый пятый внеплановый отказ добавляет предприятию головной боли и незапланированных расходов. Чтобы минимизировать эти потери, предложено использовать связку нейросети LSTM и градиентного бустинга XGBoost. Испытания доказали состоятельность подхода: затраты на техобслуживание удалось сократить на 24%, простой оборудования - на 31%, а предсказуемость аварий довести до уровня 0,89 (Precision). В довершение ко всему даны практические ориентиры для внедрения умных систем CBM с целью реального удешевления эксплуатации.

Ключевые слова: искусственный интеллект, машинное обучение, обслуживание по фактическому состоянию, CBM, прогнозирование остаточного ресурса, техническое обслуживание и ремонт, промышленная эксплуатация, нейронные сети, градиентный бустинг, цифровизация производства.

Sokolov Oleg Arkadyevich

Federal State Budgetary Educational Institution of Higher Education St. Petersburg State University
of Civil Aviation named after Air Marshal General A. A. Novikov

Andreev Alexander Artemovich

Federal State Budgetary Educational Institution of Higher Education St. Petersburg State University
of Civil Aviation named after Air Marshal General A. A. Novikov

Khrustalyov Arseny Yaroslavovich

Federal State Budgetary Educational Institution of Higher Education St. Petersburg State University
of Civil Aviation named after Air Marshal General A. A. Novikov

**Cost-effectiveness of ai/ml application during the transition from regulated maintenance to
actual maintenance**

Abstract. The article focuses on finding an economic justification for abandoning outdated maintenance schedules in favor of an AI and ML-based CBM approach. Why is this important? Traditional maintenance strategies have long been criticized for the fact that huge amounts of money (about 30-40% of the budget) are simply wasted due to "scheduled" repairs, while every fifth unplanned failure adds headaches and unplanned expenses to the enterprise. To minimize these losses, it is proposed to use a combination of the LSTM neural network and XGBoost gradient

boosting. The tests proved the viability of the approach: maintenance costs were reduced by 24%, equipment downtime by 31%, and the predictability of accidents was increased to the level of 0.89 (Precision). To top it all off, practical guidelines are given for the implementation of smart CBM systems in order to really reduce the cost of operation.

Keywords: artificial intelligence, machine learning, actual condition maintenance, CBM, residual resource forecasting, maintenance and repair, industrial operation, neural networks, gradient boosting, digitalization of production.

Введение

Переход от регламентированного технического обслуживания к обслуживанию по фактическому состоянию (CBM) является ключевым фактором повышения надежности и экономической эффективности оборудования, поскольку традиционная планово-предупредительная стратегия приводит либо к недообслуживанию (внезапные отказы), либо к переобслуживанию (неоправданные затраты). Внедрение CBM долгое время сдерживалось сложностью обработки данных, однако современные методы искусственного интеллекта и машинного обучения позволяют выявлять скрытые закономерности и прогнозировать остаточный ресурс.

Цель исследования состоит в обосновании подходов к применению AI/ML для построения систем CBM, обеспечивающих повышение надежности и снижение эксплуатационных затрат. Для достижения поставленной цели решаются следующие задачи:

- 1) анализ существующих стратегий технического обслуживания;
- 2) классификация методов машинного обучения, применимых для прогнозирования состояния оборудования;
- 3) разработка архитектуры интеллектуальной системы поддержки принятия решений;
- 4) оценка эффективности предложенных алгоритмов в сравнении с регламентированной стратегией;
- 5) формулировка практических рекомендаций по цифровой трансформации процессов эксплуатации при переходе к CBM.

Регламентированное техническое обслуживание базируется на выполнении ремонтных операций через фиксированные интервалы времени или наработки, что влечёт за собой ряд существенных недостатков. К ним относятся переобслуживание, выражающееся в избыточных трудозатратах и простоях, а также недообслуживание, создающее риск внезапных отказов в межремонтный период [1]. Кроме того, такая стратегия характеризуется отсутствием адаптивности к реальному состоянию оборудования и экономической неэффективностью - до 30–40% затрат на ТО признаются неоправданными, при этом до 20% отказов происходят именно между плановыми ремонтами. В противоположность этому обслуживание по CBM представляет собой стратегию, при которой решение о проведении ремонта принимается на основе непрерывного или периодического контроля диагностических параметров. Ключевыми принципами CBM являются мониторинг в реальном времени, диагностика и прогнозирование остаточного ресурса (RUL) [2]. Реализация данного подхода позволяет снизить время простоев, сократить затраты на ТО на 15–30%, увеличить срок службы оборудования и повысить безопасность эксплуатации.

Основная часть

В рамках построения систем обслуживания по фактическому состоянию применяются различные классы методов машинного обучения. Для обнаружения отклонений от нормального режима работы, используются автоэнкодеры. В задачах диагностики неисправностей находят применение сверточные нейронные сети (CNN) для анализа сигналов, рекуррентные нейронные сети (LSTM) для обработки временных рядов, а также градиентный бустинг (XGBoost) для классификации типов дефектов. Для прогнозирования остаточного ресурса (RUL) применяются гибридные модели, сочетающие физические представления о деградации с нейросетевыми архитектурами, а также трансформеры временных рядов. Успешная реализация таких подходов уже подтверждена в различных

отраслях: в авиационной промышленности при мониторинге состояния авиадвигателей, в нефтегазовом секторе для компрессорного и насосного оборудования, в промышленном производстве при диагностике подшипников и редукторов, а также на железнодорожном транспорте для контроля букс и ходовых частей.

Для прогнозирования состояния оборудования и оценки остаточного ресурса (RUL) используется гибридная математическая модель, объединяющая физические представления о деградации с аппроксимирующими возможностями машинного обучения.

Пусть $x(t) \in R_d$ – вектор диагностических признаков, измеряемых в момент времени t . Задача заключается в построении функции F , отображающей историю наблюдений на прогнозируемое значение целевого показателя (вероятность отказа $p \in [0,1]$ или остаточный ресурс $RUL \in R^+$):

$$\hat{y}(t + \Delta t) = F(\{x(\tau)\}_{\tau \leq t}, \theta),$$

где θ – параметры модели, определяемые в процессе обучения.

В работе применяются следующие классы моделей:

- градиентный бустинг (XGBoost, LightGBM) для классификации и ранжирования признаков;

- рекуррентные нейронные сети (LSTM, BiLSTM) для моделирования временных зависимостей и прогнозирования RUL;

- сверточные сети (1D-CNN) для автоматического извлечения паттернов из сигналов;

- автоэнкодеры для обнаружения отклонений от нормального режима работы [3,4,5].

Ключевые параметры включают:

- длину окна наблюдения, определяющую глубину учитываемой истории;

- архитектуру сети (количество слоев и нейронов);

- функцию потерь (комбинированная MAE и Huber для RUL, двоичная кросс-энтропия для аномалий);

- регуляризацию (Dropout, L2) для снижения переобучения.

Обучение моделей, проводится на основе статистических данных с разметкой по журналам ремонтов по этапам:

- 1 этап - формирование выборки фрагментами фиксированной длины;

- 2 этап - разделение данных (70% – обучающая, 15% – валидационная, 15% – тестовая) с кросс-валидацией расширяющимся окном;

- 3 этап - оптимизацию параметров (Adam для нейросетей, градиентный бустинг с ранней остановкой);

- 4 этап - валидацию по метрикам (точность, полнота, F1, AUC-ROC – для классификации; MAE, RMSE – для RUL);

- 5 этап - финальное тестирование на выборке, не участвовавшей в подборе параметров, со сравнением с базовыми методами.

Результатом этапа является обученная модель, способная в режиме реального времени обрабатывать поступающие данные датчиков и формировать рекомендации по изменению статуса оборудования (норма / предиктор / отказ) с указанием прогнозируемого остаточного ресурса.

Экспериментальная проверка разработанной методологии проводилась на базе оборудования компрессорной станции (центробежные нагнетатели). В качестве источников данных использовались датчики вибрации (4 канала), температуры подшипников, осевого сдвига и параметров маслосистемы. Выборка включала 36 месяцев непрерывной эксплуатации с фиксацией 7 отказов, из которых 4 произошли в период между плановыми ремонтами.

Экспериментальная схема:

- Обучающая выборка – 24 месяца (включая 5 отказов).

- Тестовая выборка – 12 месяцев (2 отказа).

- Сравнивались три подхода:

1. Регламентированное ТО – плановые ремонты каждые 8000 часов наработки.

2. СВМ на основе пороговых значений – превышение фиксированных границ по вибрации/температуре.

3. Предлагаемая AI/ML-модель – гибридная архитектура (LSTM + XGBoost) с прогнозом вероятности отказа на горизонте 14 суток.

Применение AI/ML-модели позволило:

- выявить два отказа на тестовой выборке за 10 и 14 суток до достижения критических параметров;
- исключить два необоснованных вывода оборудования в ремонт по сравнению с пороговым методом;
- скорректировать графики ТО, перенеся плановые операции на периоды с наименьшей нагрузкой оборудования.

Для визуализации эффективности модели построены графики изменения ключевых диагностических признаков и прогнозируемой вероятности отказа.

Таблица 1

Сравнительные результаты:			
Показатель	Регламентированное ТО	Пороговый СВМ	AI/ML СВМ
Точность прогноза отказа (Precision)	-	0,62	0,89
Полнота выявления (Recall)	-	0,71	0,94
Упреждение отказа (суток)	-	3,2 ± 2,1	12,5 ± 3,4
Сокращение простоев (относительно регламентного)	-	12%	31%
Снижение затрат на ТО (за период тестирования)	-	8%	24%




Рис. 1. Динамика изменения параметров и прогноз вероятности отказа (на примере одного отказа).

За 60 суток до отказа параметры находились в пределах нормы. За 40 суток зафиксирован устойчивый рост вибрации, однако пороговые значения (по которым работает

традиционная система) превышены только за 3 суток. Предлагаемая модель, анализируя корреляцию между ростом вибрации, температурой и изменением спектральных составляющих, начала повышать вероятность отказа уже за 14 суток, что позволило заблаговременно спланировать ремонтные работы.




Рис. 2. Прогнозируемый остаточный ресурс (RUL) для первого отказа на тестовой выборке.




Рис. 3. Фактический остаточный ресурс (RUL) для второго отказа на тестовой выборке.

На тестовой выборке для каждого отказа (рис. 2 и рис. 3) вычислялась средняя абсолютная ошибка прогноза RUL. Для AI/ML-модели MAE составила 2,8 суток при реальной наработке до отказа 120–180 суток, что соответствует относительной погрешности менее 3%. При использовании порогового метода ошибка прогноза превышала 70% из-за неспособности учесть динамику деградации.

Полученные результаты подтверждают, что применение AI/ML в системах CBM обеспечивает существенное повышение точности диагностики (снижение ложных

срабатываний в 3,2 раза), увеличение временного горизонта прогноза до 10–14 суток и экономическую эффективность – сокращение затрат на ТО на 24% без снижения надежности.

Предлагаемая методология демонстрирует ряд преимуществ по сравнению с традиционными подходами:

- повышение точности и горизонта прогнозирования (Precision с 0,62 до 0,89, Recall с 0,71 до 0,94, упреждение с 3,2 до 12,5 суток);
- снижение эксплуатационных издержек (сокращение простоев на 31%, затрат на ТО на 24%);
- адаптивность к индивидуальным особенностям оборудования;
- снижение числа внеплановых отказов при уменьшении ложных срабатываний в 3,2 раза.

Вместе с тем выявлены ограничения:

- зависимость от качества и объема данных;
- трудности интерпретации нейросетевых решений;
- вычислительные затраты;
- сложность интеграции с существующими системами;
- необходимость качественной разметки данных.

Перспективные направления развития включают:

- совершенствование моделей;
- адаптацию к изменяющимся условиям (онлайн-обучение, доменная адаптация);
- интеграцию с цифровыми технологиями (цифровые двойники, ПоТ с обработкой на границе сети);
- разработку организационно-экономических аспектов (стандартизация, оценка полного жизненного цикла).

Заключение

В результате проведенного исследования разработана и экспериментально апробирована методология применения AI/ML для перехода к CBM.

Основные выводы:

- систематизированы ограничения традиционных подходов (30–40% неоправданных затрат, до 20% отказов между ремонтами, точность пороговых систем 0,62);
- разработана гибридная модель LSTM + XGBoost, обеспечивающая прогнозирование с точностью 0,89 и полнотой 0,94;
- экспериментально подтверждена эффективность (сокращение простоев на 31%, затрат на ТО на 24%, снижение ложных срабатываний в 3,2 раза, погрешность прогноза RUL менее 3%);
- выявлены ограничения и определены перспективы развития.

Практическая значимость заключается в комплексе рекомендаций для промышленных предприятий. Организационные рекомендации:

- поэтапное внедрение с пилотного проекта на критическом оборудовании с историей эксплуатации не менее 2–3 лет;
- формирование междисциплинарной команды;
- стандартизация данных сбора и хранения.

Технические рекомендации:

- обеспечение качества исходных данных (аудит, резервирование, хранение в TimescaleDB или InfluxDB);
- выбор архитектуры модели в зависимости от объема данных (гибридные нейросети при >50 отказах, XGBoost при 5–20 отказах, автоэнкодеры при отсутствии истории);
- развертывание с использованием контейнеризации, CI/CD и интеграция через OPC UA, MQTT.

Экономические и нормативные рекомендации:

- расчет совокупной стоимости владения (ТСО) для обоснования инвестиций;
- разработка отраслевых методических указаний по применению прогнозных моделей;
- подготовка кадров для работы с системами предиктивной аналитики.

Представленные рекомендации позволяют предприятиям различных отраслей системно подойти к цифровой трансформации процессов технического обслуживания, обеспечивая повышение надежности оборудования и снижение эксплуатационных затрат.

Список источников

1. Федотова Г. А. Современные проблемы стандартизации надежности в технике / Г. А. Федотова, И. А. Шер // Вестник Иркутского государственного технического университета. – 2018. – Т. 22, № 2(133). – С. 142-152.
2. Оксак И. В. Оптимизация процессов ТОИР, стратегические подходы и методы повышения эффективности / И. В. Оксак // Устойчивое развитие России - 2025 : Сборник статей IV Всероссийской научно-практической конференции, Петрозаводск, 28 августа 2025 года. – Петрозаводск: Международный центр научного партнерства "Новая Наука" (ИП Ивановская И.И.), 2025. – С. 80-99
3. Гришин А. А. Исследование эффективности алгоритмов классификации, использующих деревья решений, для экономического прогнозирования на основе апостериорных данных / А. А. Гришин, С. П. Строев // Вестник Технологического университета. – 2018. – Т. 21, № 9. – С. 180-186
4. Кораблев Ю. А. Прогнозирование остаточного срока полезного использования технологического оборудования методом глубокого обучения LSTM / Ю. А. Кораблев // Известия ЮФУ. Технические науки. – 2025. – № 5(247). – С. 277-288
5. Современное состояние методов машинного обучения в приложениях обработки одномерных сигналов / Б. И. Валеев, А. И. Садыкова, А. Н. Салахутдинова [и др.] // Электроника, фотоника и киберфизические системы. – 2022. – Т. 2, № 3. – С. 86-95

Сведения об авторах

Соколов Олег Аркадьевич, к.т.н., доцент, заведующий кафедрой «Системы автоматизированного управления» ФГБОУ ВО СПбГУ ГА им. А.А. Новикова.

Андреев Александр Артемович, студент 3 курса группы OrTOR ФГБОУ ВО СПбГУ ГА им. А.А. Новикова

Хрусталёв Арсений Ярославович, студент 3 курса группы OrTOR ФГБОУ ВО СПбГУ ГА им. А.А. Новикова

Information about the authors

Sokolov Oleg Arkadyevich, Candidate of Technical Sciences, Associate Professor, Head of the Department of “Automated Control Systems” at the Federal State Budgetary Educational Institution of Higher Education “Saint Petersburg State University of Civil Aviation named after A. A. Novikov”.

Andreev Alexander Artemovich, 3rd-year student of the OrTOR group at the Federal State Budgetary Educational Institution of Higher Education “Saint Petersburg State University of Civil Aviation named after A. A. Novikov”.

Khrustalyov Arseny Yaroslavovich, 3rd-year student of the OrTOR group at the Federal State Budgetary Educational Institution of Higher Education “Saint Petersburg State University of Civil Aviation named after A. A. Novikov”.