

Цапко Кирилл Владимирович

студент

Буханцев Александр Владимирович

студент

Дрогачёв Артем Павлович

студент

Научный руководитель

Михалева Ульяна Николаевна

старший преподаватель

ФГБОУ ВО «Донской государственный технический университет»
г. Ростов-на-Дону, Ростовская область

**РАЗРАБОТКА И ИССЛЕДОВАНИЕ СЕРВИСА ПРЕДИКТИВНОЙ
АНАЛИТИКИ ПРОМЫШЛЕННОГО ОБОРУДОВАНИЯ НА ОСНОВЕ
КОНВЕРГЕНЦИИ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА
И ПРОМЫШЛЕННОГО ИНТЕРНЕТА ВЕЩЕЙ**

Аннотация: в статье исследуется архитектура, алгоритмы и экономическая эффективность облачного сервиса для предиктивного обслуживания (*Predictive Maintenance, PdM*) промышленного оборудования, основанного на конвергенции *Industrial Internet of Things (IoT)* и методов искусственного интеллекта (*AI*). Рассмотрены ключевые технологические компоненты: сенсорные сети для сбора данных, облачные платформы для их обработки и хранения, а также машинное обучение (*ML*) для построения предиктивных моделей остаточного ресурса (*Remaining Useful Life, RUL*) и классификации аномалий. Анализируются преимущества подхода по сравнению с реактивным и планово-предупредительным обслуживанием, включая сокращение незапланированных простоев, оптимизацию запасов запчастей и повышение общей эффективности оборудования (*OEE*). Работа основана на систематизации данных из рецензируемых научных публикаций, отчетов *Gartner* и *McKinsey*, а также на анализе

успешных кейсов внедрения в таких отраслях, как энергетика, авиаация и обрабатывающая промышленность.

Ключевые слова: предиктивная аналитика, предиктивное обслуживание (PdM), промышленный интернет вещей (ПоТ), искусственный интеллект (AI), машинное обучение (ML), остаточный ресурс (RUL), общая эффективность оборудования (OEE), цифровой двойник (Digital Twin).

Современная промышленность сталкивается с растущим давлением, требующим повышения эффективности, надежности и безопасности при одновременном снижении эксплуатационных расходов. Традиционные стратегии обслуживания оборудования – реактивная (ремонт после отказа) и профилактическая (плановый ремонт по расписанию) – обладают существенными недостатками: высокие затраты на незапланированные простоя, избыточное обслуживание или, наоборот, неспособность предотвратить внезапный отказ [1]. Согласно отчету McKinsey, внедрение предиктивной аналитики может сократить время простоя оборудования на 30–50% и увеличить срок его службы на 20–40% [2].

Целью данной работы является разработка концептуальной модели и анализ ключевых компонентов AI/ПоТ-сервиса для предиктивной аналитики, способного.

1. В режиме реального времени собирать и передавать многопараметрические данные о состоянии оборудования.
2. С использованием методов AI выявлять скрытые аномалии и деградационные тренды.
3. Прогнозировать остаточный ресурс (RUL) критических узлов.
4. Формировать рекомендации для обслуживающего персонала.

Исследование проведено методом системного анализа существующих научных публикаций, отраслевых стандартов (ISO 13374, ISO 55000) и коммерческих платформ (PTC ThingWorx, Siemens MindSphere, GE Predix). Практическая часть основана на анализе открытых датасетов, таких как NASA Turbofan Engine Degradation Simulation Dataset [3], широко используемого для валидации PdM-алгоритмов.

Архитектура AI/ПоТ-сервиса предиктивной аналитики

Предлагаемая многоуровневая архитектура сервиса включает следующие уровни.

Уровень оборудования и сенсоров (Physical Layer).

1. Датчики: Вибрационные акселерометры, датчики температуры, давления, тока, ультразвука, акустической эмиссии. Ключевое требование – достаточная частота дискретизации для **捕捉** высокочастотных признаков износа [4].

2. Шлюзы (Gateways): обеспечивают предобработку данных (фильтрация, агрегация), протокольную трансляцию и безопасную передачу в облако через MQTT, OPC UA или аналогичные промышленные протоколы.

Уровень передачи данных и облачной платформы (Cloud/Platform Layer).

1. Платформа ПоТ: Облачная или гибридная среда (напр., на основе Apache Kafka, Kubernetes), обеспечивающая прием, долгосрочное хранение (data lake) и управление потоками данных (stream processing). Цифровой двойник (Digital Twin): Виртуальная динамическая модель оборудования, синхронизированная с физическим объектом через данные датчиков. Служит средой для симуляции и анализа [5].

Уровень аналитики и искусственного интеллекта (AI/Analytics Layer).

1. Предобработка данных: Очистка от шумов, обработка пропусков, нормализация.

2. Инжиниринг признаков (Feature Engineering): Выделение значимых признаков из временных рядов (среднеквадратичное значение, амплитуды на характерных частотах Фурье-спектра, кепстральные коэффициенты и т. д.).

Модели машинного обучения.

1. Контролируемое обучение (Supervised Learning): регрессионные модели (Random Forest, Gradient Boosting, SVR) и глубокие нейронные сети (LSTM, 1D-CNN) для прямого прогнозирования RUL [3].

2. Неконтролируемое обучение (Unsupervised Learning): алгоритмы кластеризации (k-means) и обнаружения аномалий (Isolation Forest, Autoencoders) для выявления неизвестных отклонений в режиме без учителя [6].

3. Обучение с подкреплением (Reinforcement Learning): перспективное направление для оптимизации политик обслуживания в динамической среде.

Уровень представления и интеграции (Application/Integration Layer).

1. Панели мониторинга (Dashboards): визуализация состояния парка оборудования, прогнозов RUL, приоритизированных оповещений.

2. Интеграция с CMMS-системами: автоматическое создание заявок в системы управления техническим обслуживанием (например, SAP PM, IBM Maximo).

3. Алгоритмическое ядро сервиса: подходы на основе AI/ML

Прогнозирование остаточного ресурса (RUL).

Наиболее эффективным подходом для прогнозирования RUL является комбинация методов.

1. Выделение признаков деградации: из сырых данных вибрации и температуры выделяются индикаторы состояния (Health Indicators, HI), монотонно изменяющиеся со временем.

2. Построение прогнозной модели: рекуррентные нейронные сети (LSTM) демонстрируют высокую точность в работе с последовательными временными рядами, так как способны улавливать долгосрочные временные зависимости в данных о деградации [7].

Обнаружение аномалий и диагностика.

Сверточные нейронные сети (1D-CNN) успешно применяются для автоматического выделения признаков из вибросигналов и классификации типов неисправностей (например, повреждение подшипника, дисбаланс ротора) без сложного ручного инжиниринга признаков [8].

Экономическое обоснование и оценка эффективности.

Внедрение сервиса оценивается по следующим ключевым показателям (KPI).

1. Сокращение незапланированных простоев (Unplanned Downtime): основной источник экономии.

2. Рост общей эффективности оборудования (OEE): за счет увеличения коэффициента доступности и производительности.

3. Оптимизация затрат на обслуживание: сокращение затрат на плановое обслуживание и запасы запчастей.

4. Увеличение срока службы оборудования: более щадящий режим эксплуатации и своевременное вмешательство.

Исследование, проведенное на предприятии нефтегазовой отрасли, показало, что внедрение подобной системы позволило снизить количество внеплановых остановок на 25% и затраты на техническое обслуживание на 15% в течение первого года эксплуатации [9].

Вызовы и ограничения.

Качество и объем данных: для обучения сложных ML-моделей необходимы большие объемы размеченных данных, включая данные об отказах, которые зачастую редки.

Интерпретируемость моделей (Explainable AI, XAI): «Черный ящик» глубокого обучения может вызывать недоверие у инженеров. Необходимо внедрение методов XAI.

Кибербезопасность: ПоТ-системы становятся целью для атак, требуется сквозное шифрование и защита периметра.

Интеграция с legacy-оборудованием: модернизация старых станков требует установки дополнительных датчиков и шлюзов.

Заключение и перспективы.

Разработанная концепция сервиса предиктивной аналитики на основе AI/ПоТ демонстрирует значительный потенциал для трансформации стратегий технического обслуживания в промышленности. Ключевыми факторами успеха являются надежная сенсорная инфраструктура, мощные алгоритмы машинного обучения для прогнозирования RUL и глубокая интеграция с бизнес-процессами предприятия. Перспективные направления дальнейших исследований:

Развитие федеративного обучения (Federated Learning) для построения моделей на распределенных данных без нарушения их конфиденциальности.

Использование графовых нейронных сетей (GNN) для анализа сложных взаимосвязей в системах оборудования.

Создание самообучающихся (self-adaptive) цифровых двойников, способных непрерывно обновлять свои модели по новым данным [10].

Список литературы

1. Мобли Р.К. Введение в профилактическое обслуживание / Р.К. Мобли. – Баттерворт-Хайнemann, 2002.
2. Интернет вещей: использование растущих возможностей // McKinsey & Company. – 2020.
3. Моделирование распространения повреждений для моделирования работы авиационного двигателя до отказа / А. Саксена, К. Гебель, Д. Саймон [и др.] // Международная конференция по прогнозированию и управлению здравоохранением. – 2008. – С. 1–9.
4. Джардин А.К. Обзор по диагностике и прогнозированию оборудования, основанному на техническом обслуживании / А.К. Джардин, Д. Лин, Д. Баневич // Механические системы и обработка сигналов. – 2006. – С. 1483–1510.
5. Цифровой двойник в промышленности: современное состояние / Ф. Тао, Х. Чжан, А. Лю [и др.] // Transactions on Industrial Informatics. – 2018. – Т. 15. №4. – С. 2405–2415.
6. Глубокое обучение и его применение для мониторинга работоспособности машин / Р. Чжао, Р. Янь, З. Чен [и др.] // Механические системы и обработка сигналов. – 2019. – №115. – С. 213–237.
7. Ли Х. Оценка оставшегося срока полезного использования в прогностике с использованием нейронных сетей с глубокой сверткой / Х. Ли, К. Дин, Дж.К. Сан // Проектирование надежности и безопасность систем. – 2018. – №1–11. – С. 172.
8. Новый метод диагностики неисправностей на основе сверточных нейронных сетей, основанный на данных / Л. Вэнь, Х. Ли, Л. Гао [и др.] // IEEE Transactions по промышленной электронике. – 2017. – Т. 7. №65. – С 5990–5998.
9. Профилактическое обслуживание: используйте IoT для перехода от реактивного обслуживания к проактивному. – 2021.

10. Мониторинг состояния и диагностика машин – обработка, передача и представление данных.