

УДК 004.896

DOI 10.62595/1819-5245-2025-4-130-141

СОВРЕМЕННЫЕ МЕТОДЫ ИНТЕЛЛЕКТУАЛЬНОГО МОНИТОРИНГА ПРОМЫШЛЕННОГО ОБОРУДОВАНИЯ

ЧЖАН ЛИФАН

*Учреждение образования «Гомельский государственный
технический университет имени П. О. Сухого»,
Республика Беларусь*

*Шаньдунский технологический институт Хуаюй,
Китайская Народная Республика*

Рассматриваются инновационные подходы к интеллектуальному мониторингу промышленного оборудования, акцентируя внимание на их важности для повышения эффективности и надежности производственных процессов. Основные методы мониторинга, такие как предиктивная аналитика, машинное обучение и Интернет вещей (IoT), описываются в контексте их применения для диагностики состояния оборудования и предотвращения аварий. Обсуждены примеры успешного внедрения данных технологий на различных предприятиях, что иллюстрирует их практическую ценность.

Ключевые слова: интеллектуальный мониторинг, промышленное оборудование, предиктивная аналитика, машинное обучение, Интернет вещей, диагностика состояния, системы мониторинга, граничный искусственный интеллект.

Для цитирования. Чжан, Л. Современные методы интеллектуального мониторинга промышленного оборудования / Л. Чжан // Вестник Гомельского государственного технического университета имени П. О. Сухого. – 2025. – № 4 (103). – С. 130–141. – DOI 10.62595/1819-5245-2025-4-130-141

MODERN METHODS OF INDUSTRIAL EQUIPMENT INTELLIGENT MONITORING

ZHANG LIFAN

*Sukhoi State Technical University of Gomel,
the Republic of Belarus*

*Shandong Huayu University of Technology,
People's Republic of China*

This article explores innovative approaches to intelligent monitoring of industrial equipment, emphasizing their importance for improving the efficiency and reliability of production processes. Key monitoring methods, such as predictive analytics, machine learning, and the Internet of Things (IoT), are described in the context of their application for equipment condition diagnostics and accident prevention. Examples of successful implementation of these technologies at various enterprises are discussed, illustrating their practical value.

Keywords: intelligent monitoring, industrial equipment, predictive analytics, machine learning, Internet of Things, condition diagnostics, monitoring systems, edge artificial intelligence.

For citation. Zhang L. Modern methods of industrial equipment intelligent monitoring. *Vestnik Gomel'skogo gosudarstvennogo tekhnicheskogo universiteta imeni P. O. Sukhogo*, 2025, no. 4 (103), pp. 130–141 (in Russian). DOI 10.62595/1819-5245-2025-4-130-141

Введение

Мониторинг промышленного оборудования основан на интеллектуальных сенсорных технологиях и осуществляется посредством сбора, передачи, анализа и при-

нятия решений на основе параметров состояния работы оборудования для оценки его технического состояния и прогнозирования возникновения неисправностей. В эпоху четвертой промышленной революции (Индустрия 4.0) и умного производства концепция мониторинга промышленного оборудования уже не ограничивается традиционными единичными точками сбора данных, а формирует замкнутую экосистему, основанную на цикле «восприятие – анализ – контроль – оптимизация». Например, современные системы мониторинга станков с ЧПУ способны в реальном времени собирать разнообразные параметры, такие как параметры вибрации шпинделя, электрический ток двигателей, скорость подачи, температура резания и т. п. Системы мониторинга способны создавать виртуальные модели (цифровые двойники) физических объектов, процессов или систем, которые используют полученные данные для симуляции работы оборудования посредством совместных вычислений на периферии и в облаке [1].

Архитектура мониторинга промышленного оборудования включает три уровня:

1) уровень восприятия, где происходит цифровое преобразование физических сигналов с помощью акселерометров, трансформаторов тока, инфракрасных пирометров и других устройств;

2) уровень анализа, состоящий в применении алгоритмов машинного обучения (таких как трансформер, графовые нейронные сети) для объединения признаков и распознавания шаблонов в многоканальных данных;

3) прикладной уровень, где осуществляется реализация предупреждения о неисправностях, принятие решений по техническому обслуживанию и оптимизации технологических процессов через визуальные интерфейсы и системы управления [2].

В области умного производства значение мониторинга промышленного оборудования заключается в повышении надежности и предотвращении отказов, оптимизации затрат на техническое обслуживание, оптимизации производственных процессов и повышении производственной эффективности.

Так, неисправности подшипников шпинделя станков с ЧПУ составляют более 30 % от всех отказов [3]. Благодаря мониторингу вибрации и раннему обнаружению признаков неисправности можно снизить уровень незапланированных простоев на 30 %. Одна из компаний по производству авиационных двигателей способна обнаруживать трещины лопаток турбины на протяжении всего жизненного цикла, обеспечивая предварительное предупреждение за более чем 72 часа [4].

При использовании ранее применявшегося метода периодического технического обслуживания средние затраты на обслуживание одного комплекта станков с ЧПУ составляли до 25 % от общих расходов, тогда как применение предиктивного обслуживания на основе данных в реальном времени позволяет сэкономить около 35 % затрат на ремонт, а оборачиваемость запасов запасных частей может увеличиться примерно на 20 % [5].

Данные мониторинга в сочетании с технологическими параметрами используются для анализа с целью оптимизации процесса обработки. Например, применение мониторинга вибрации инструмента в зависимости от силы резания при производстве пресс-форм позволяет повысить эффективность фрезерной обработки на 15 % и снизить шероховатость поверхности на 40 % [6].

Целью статьи является проведение всестороннего обзора современных методов интеллектуального мониторинга, диагностики и прогнозирования технического состояния промышленного оборудования, включая анализ подходов, основанных на искусственном интеллекте, машинном обучении, технологии цифровых двойников, а также анализ основных тенденций развития интеллектуальной диагностики.

Основная часть

Современные методы диагностики и мониторинга промышленного оборудования эволюционировали от традиционного опыта специалистов к интеллектуальным системам, основанным на триаде «модель – знание – данные». В соответствии с используемыми техническими подходами методы можно разделить на три основные категории: методы, основанные на аналитических моделях; методы, основанные на знаниях; методы, основанные на данных [1]. В контексте диагностики станков с ЧПУ техническая эволюция и особенности применения этих трех категорий представлены на рис. 1.




Рис. 1. Техническая эволюция методов диагностики и мониторинга промышленного оборудования

Методы, основанные на аналитической модели, подразумевают выполнение диагностики неисправностей посредством построения физико-механической модели оборудования, ключевым аспектом которой является математическое описание закономерностей работы оборудования и выявление неисправностей на основе анализа расхождений между выходными данными модели и фактическими измерениями.

Одним из таких методов является метод оценки состояния. На основе динамической модели числового программного управления станком (например, уравнения движения шпинделя) с использованием фильтра Калмана оцениваются переменные состояния системы. При превышении ошибки оценки состояния порогового значения инициируется предупреждение о неисправности. Применение данного метода на примере пятиосевого обрабатывающего центра показало, что точность обнаружения износа направляющих достигает 89 %, однако требуется очень точное определение динамических параметров [2].

Метод оценки параметров – это онлайн-идентификация нескольких основных параметров числового программного управления станком (жесткость шпинделя, коэффициенты силы резания режущего инструмента и др.) и определение наличия неисправностей на основе изменений этих параметров. Например, в процессе фрезерования осуществляется вычисление коэффициента силы резания режущего инструмента с помощью рекурсивного метода наименьших квадратов. При изменении коэффициента на 15 % возникает сигнализация износа режущего инструмента [7].

Метод эквивалентного пространства – это подход, который активно применяется в диагностике и обнаружении неисправностей в сложных системах, таких как авиационные, энергетические и промышленные установки. Суть метода состоит в формировании эквивалентного пространства путем построения избыточных уравнений и использовании выходных остатков для обнаружения неисправностей. Выходные остатки представляют собой разницу между ожидаемыми и фактическими выходными значениями системы. Анализ остатков позволяет выявить отклонения, указывающие на возможные неисправности. Применительно к системе подачи станков с ЧПУ данный метод может, например, эффективно выявлять неисправности зазора в винтовой паре. При установке порога остатка на уровне 3-кратного стандартного отклонения уровень пропусков (ошибочных срабатываний) составляет менее 5 % [8].

Описанные методы имеют недостатки, связанные с нелинейностью и временной нестабильностью параметров оборудования (например, износ режущего инструмента вызывает изменение параметров во времени), поэтому точное моделирование затруднено, а несоответствие модели может привести к уровню ложных срабатываний в 10–15 % [9].

Методы, основанные на знаниях, опираются на кодирование экспертного опыта или базы знаний о неисправностях для реализации диагностики и применяются в случаях с достаточно сложным механизмом, который невозможно смоделировать.

Экспертные системы предполагают построение системы «база правил + механизм вывода». Например, если в спектре вибрации шпинделя присутствует компонент с частотой, равной частоте вращения шпинделя, и его значение превышает $2g$, и имеется аномальный шум, то диагностируется неисправность динамической балансировки. Экспертная система для отдельного токарного станка с ЧПУ может содержать более 500 правил. Для распространенных неисправностей точность диагностики достигает 90 %, однако для редких неисправностей точность недостаточна [10].

Анализ дерева отказов (*Fault Tree Analysis, FTA*) – это метод, позволяющий систематически анализировать потенциальные отказы и их взаимосвязи, что делает его ценным инструментом для обеспечения безопасности и надежности. Дерево отказов – это графическое представление, в котором верхний уровень представляет собой основной отказ или событие, а нижние уровни содержат причины этого отказа, разбитые на более мелкие события. Построение дерева отказов для обрабатывающего центра с «перегревом шпинделя» в качестве верхнего события, «отказом системы охлаждения», «недостаточной смазкой подшипников» и другими событиями в качестве промежуточных, и с использованием минимальных разрезов для выражения различных путей передачи аварий в дереве отказов, позволяет оценить вероятность перегрева шпинделя из-за недостаточной смазки подшипников, которая составляет 38 % [3].

Нечеткий вывод – это метод, используемый в нечеткой логике для принятия решений, когда данные не могут быть четко определены или находятся в неопределенности. Нечеткий вывод использует нечеткие множества для описания неопределенных понятий, таких как «сильная вибрация», «повышенная температура», с помощью базы нечетких правил для классификации отказов. В диагностике износа режущего инструмента станка с ЧПУ в качестве входных параметров используются амплитуда вибрации, сила резания и другие показатели, которые затем нечетко классифицируются в категории «легкий износ», «тяжелый износ» и т. д. На этой основе точность прогноза превышает точность, основанную на точных пороговых значениях, примерно, на 12 % [4].

Методы диагностики, основанные на знаниях, имеют высокую стоимость получения экспертных знаний и трудности с адаптацией к новым режимам отказов чи-

слового программного управления станка (например, высокочастотные вибрационные отказы, вызванные высокоскоростной обработкой) [11].

С увеличением плотности датчиков на станках с ЧПУ (обычно более 20-ти датчиков) актуальной темой исследований становятся методы, управляемые данными, поскольку их независимость от точных моделей лучше адаптируется к сложным промышленным условиям [5]. К этим методам можно отнести методы обработки сигналов, многомерного статистического анализа, а также машинного и глубокого обучения.

Мониторинг промышленного оборудования с использованием методов обработки сигналов позволяет эффективно выявлять аномалии, предотвращать неполадки и оптимизировать процессы.

При частотно-временном анализе применение кратковременного преобразования Фурье (*Short-Time Fourier Transform, STFT*) к сигналу вибрации шпинделя станка с ЧПУ позволяет получить частотно-временную диаграмму (спектрограмму), на которой при износе режущего инструмента наблюдается концентрация энергии в диапазоне 500–800 Гц [6].

Вейвлет-преобразование (*Wavelet Transform*) основано на использовании вейвлетов – малых волн, которые могут быть масштабированы и смещены. В отличие от традиционного преобразования Фурье, вейвлет-преобразование предоставляет как частотную, так и временную информацию, что делает его особенно полезным для анализа нестационарных сигналов. Использование вейвлета *DB4* в качестве инструмента для анализа вибрационных сигналов на обрабатывающем центре демонстрирует высокую эффективность в диагностике неисправностей, в частности, для выявления проблем с наружным кольцом подшипника. Точность диагностики неисправности наружного кольца подшипника достигает 97 % [12].

Методы многомерного статистического анализа – это набор методов (главных компонент, частичных наименьших квадратов и др.), используемых для анализа данных, содержащих более одной переменной. Он позволяет исследовать взаимосвязи между переменными, выявлять структуры и паттерны в данных, а также делать предсказания.

Метод главных компонент (*Principal Component Analysis, PCA*) позволяет уменьшить размерность данных, сохраняя при этом важные характеристики. На основе снижения размерности 10-мерных параметров вибрации, электрического тока, температуры и других параметров станков с ЧПУ был разработан статистический показатель T^2 для обнаружения состояния неисправности шпинделя. В [1] применение данного метода повысило разделимость нормального и аварийного состояний на 23 %.

Метод частичных наименьших квадратов (*Partial Least Squares, PLS*) – это статистический метод, используемый для моделирования отношений между наборами переменных, особенно когда данные имеют высокую размерность и много независимых переменных, которые имеют высокую степень корреляции друг с другом (коллинеарных предикторов). Этот метод сочетает элементы регрессионного анализа и факторного анализа. В [2] на основе параметров резания (частота вращения, скорость подачи) и степени износа режущего инструмента построена регрессионная модель с коэффициентом корреляции 0,92, позволяющая заблаговременно за 2 часа предупреждать о необходимости замены инструмента.

Методы машинного обучения (*Machine Learning, ML*) и глубокого обучения (*Deep Learning, DL*) представляют собой мощные инструменты для анализа данных и решения различных задач. Машинное обучение – это подмножество искусственного интеллекта, сосредоточенное на разработке алгоритмов, которые позволяют компьютерам обучаться на данных и делать предсказания или принимать решения

без явного программирования. Глубокое обучение – это подмножество машинного обучения, использующее искусственные нейронные сети с множеством слоев для анализа данных.

В [7] сверточная нейронная сеть (*Convolutional Neural Network, CNN*) использует частотно-временное представление вибрационного сигнала в качестве входных данных. При диагностике неисправностей подшипников станков с ЧПУ точность модели на архитектуре *ResNet-18 (Residual Network)* достигает 99,2 %, что на 15 % выше по сравнению с традиционным методом опорных векторов (*Support Vector Machine, SVM*).

Сети с долгосрочной и краткосрочной памятью (*Long Short-Term Memory, LSTM*) – это тип рекуррентных нейронных сетей, разработанных для обработки и предсказания последовательных данных. Использование такой сети для обработки временных данных станков с ЧПУ, таких как последовательность позиционных ошибок системы подачи, позволяет с помощью механизма управления захватывать долгосрочные зависимости. Например, прогноз износа винтовой передачи осуществляется с опережением на 10 часов [8].

Архитектура глубоких нейронных сетей Трансформер (*Transformer*), использующая механизм самовнимания (*Self-Attention*) для обработки многоканальной информации, в сценарии слияния данных вибрации шпинделя и тока режущего инструмента достигает точности локализации неисправностей 95 %, что на 8 % выше, чем у *LSTM* [9].

В табл. 1 приведена сводная информация по эффективности различных методов диагностики, управляемых данными, применительно к станкам с ЧПУ.

Таблица 1

**Сравнение эффективности типовых управляемых данными
методов диагностики станков с ЧПУ**

Наименование метода	Типичные алгоритмы	Размерность признаков	Точность диагностики, %	Время вычислений (1000 образцов), с
Обработка сигналов	Декомпозиция вейвлет-пакетов	10–20 измерений	85–90	< 0,1
Многомерный статистический анализ	<i>PCA, SVM</i>	5–10 измерений	90–93	< 0,5
Машинное обучение	<i>XGBoost</i>	20–50 измерений	92–95	1–2
Глубокое обучение	<i>CNN, LSTM</i>	Исходный сигнал	95–98	5–10
Мультимодальное слияние	<i>Transformer</i>	Многоканальные последовательности	97–99	8–15

В настоящее время в исследованиях мониторинга промышленного оборудования прослеживаются три основные тенденции: мультимодальное слияние данных, адаптивное обучение и граничный искусственный интеллект.

В процессе мультимодального слияния данных происходит интеграция механических (вибрационных), электрических (электрический ток) и визуальных (износ режущего инструмента) данных. Например, построение топологической карты

«шпиндель – режущий инструмент – сервомотор» с помощью *GNN* для анализа взаимосвязанных характеристик многоканальных сигналов [10].

Адаптивное обучение в случае станков с ЧПУ позволяет динамически подстраивать модели диагностики под изменяющиеся рабочие условия. Это особенно важно, поскольку рабочие параметры, такие как частота вращения, нагрузка и вибрации, могут значительно варьироваться. Использование стохастического градиентного спуска позволяет обновлять параметры модели в реальном времени по мере поступления новых данных. Это делает модель более адаптивной к изменениям в рабочих условиях и позволяет достигнуть точности диагностики, равной 92 % [3].

Интернет вещей (*Internet of Things, IoT*) обеспечивает универсальные возможности сбора данных для мониторинга промышленного оборудования через трехуровневую архитектуру «восприятие – соединение – обработка». В случае с мониторингом станков с ЧПУ эта возможность проявляется в непрерывном получении и передаче многоканальных гетерогенных данных (рис. 2).




Рис. 2. Сетевая архитектура системы мониторинга станков с ЧПУ с использованием Интернета вещей

На уровне восприятия Интернета вещей для станков с ЧПУ обычно можно выделить три группы датчиков, которые работают совместно для захвата многомерного состояния работы оборудования. На уровне восприятия механического состояния трехосевые акселерометры с частотой выборки 10–20 кГц в реальном времени фиксируют вибрационный сигнал шпинделя с чувствительностью до 0,01g, что позволяет выявлять механические аномалии микронного масштаба. В области мониторинга электрических параметров датчики Холла с точностью $\pm 0,5\%$ регистрируют электрический ток сервомотора и его гармонические составляющие, обеспечивая глубокий анализ гармоник 2–10-го порядка и предоставляя электрические признаки для диагностики неисправностей двигателей. Запись технологического процесса опирается на линейные и угловые энкодеры и волоконно-оптические датчики: первые

обеспечивают обратную связь по положению вала с разрешением 1 мкм, вторые формируют временную корреляцию с параметрами резания, совместно создавая карту технологических параметров процесса обработки [1].

Что касается коммуникационной архитектуры, в настоящее время мониторинг станков с ЧПУ использует гибридный режим проводной и беспроводной связи, и применяет стандартные протоколы для обеспечения своевременного и надежного обмена и передачи данных. Среди последних можно выделить протокол передачи данных в промышленных сетях *OPC Unified Architecture*, который позволяет осуществлять обмен данными с низкой задержкой между системой ЧПУ и граничными узлами, достигая времени отклика менее 100 мс в системе *Fanuc 0i-MF*. Интеграция технологий 5G и *TSN (Time-Sensitive Networking)* позволяет решить проблему мониторинга подвижных частей. Использование технологии *5G-TSN* обеспечивает задержки передачи данных вибрационного мониторинга таких движущихся компонентов, как магазин инструментов, в пределах 50 мкс, что гарантирует согласованность временных последовательностей динамических данных [2]. Новая коммуникационная архитектура поддерживает вычислительную концепцию «граничное – облачное»: граничные узлы, такие как комплект разработки *NVIDIA Jetson AGX Orin*, выполняют предварительную обработку данных в реальном времени и с помощью алгоритмов, например, вейвлет-шумоподавления, сжимают вибрационный сигнал до 20 % от исходного объема данных, передавая в облачную платформу только наиболее значимую информацию, что, с одной стороны, снижает нагрузку на сеть, а с другой – сохраняет достаточный объем ценных данных для глубокого анализа в облаке [7].

Глубокая интеграция искусственного интеллекта (ИИ) и Интернета вещей породила новое поколение моделей мониторинга, характеризующихся «интеллектуальным восприятием — анализом в реальном времени — автономным управлением». В этом контексте существующие технологии мониторинга станков с ЧПУ претерпели существенные изменения, что постепенно привело к формированию совершенно новой системы промышленного мониторинга.

Граничный (периферийный) искусственный интеллект (*Edge AI*) подразумевает развертывание облегченных моделей, таких как *MobileNet*, на граничных узлах, т. е. на устройствах, которые находятся ближе к источнику данных, для обработки данных в реальном времени. Использование *MobileNet V3* обеспечивает распознавание признаков на частотно-временных диаграммах вибрации при времени обработки в пределах 10 мс, что полностью соответствует требованиям оперативного предупреждения. При этом применение целочисленного (*INT8*) квантования снижает энергопотребление вычислений модели на 75 %, что делает возможным онлайн-обнаружение аномалий шпинделя на легковесных граничных устройствах, таких как *Raspberry Pi 4* [4].

Модели глубокого обучения, такие как *ResNet-50*, могут достигать 99 % точности диагностики, однако их вычислительная сложность резко контрастирует с ограниченной вычислительной мощностью граничных узлов (например, процессоров на ядре *ARM Cortex-A72*). Для решения этого противоречия используется технология дистилляции знаний, которая переносит знания *ResNet-50* в *MobileNet*, снижая требования к вычислительной мощности на 80 % при потере точности менее 2 % [6]. Технология динамического вывода адаптивно регулирует вычислительную сложность модели в зависимости от степени аномалии данных, что позволяет снизить потребление вычислительной мощности на 50 % в нормальных рабочих условиях. Такая стратегия интеллектуального управления вычислительными ресурсами эффективно смягчает противоречие между точностью и эффективностью.

В табл. 2 приведено сравнение типичных случаев применения технологий искусственного интеллекта вещей (*AIoT*) в мониторинге станков с ЧПУ.

Таблица 2

Сравнительный анализ применения технологий *AIoT* в мониторинге станков с ЧПУ

Случаи применения	Ограничения традиционных решений	Инновационные решения на основе <i>AIoT</i>	Результат применения технологий <i>AIoT</i>
Обнаружение аномалий вибрации	Высокий уровень ложных срабатываний (20–30 %)	Распознавание шаблонов признаков с использованием <i>CNN</i> и механизма внимания	Уровень ложных срабатываний < 5 %, заблаговременность обнаружения ≥ 2 часов
Прогнозирование остаточного ресурса режущего инструмента	На основе эмпирических формул, ошибка > 20 %	Интеграция параметров резания и характеристик вибрации с помощью <i>Transformer</i>	Погрешность < 10 %, оптимизация плана замены инструмента на 30 %
Предупреждение о качестве обработки	Зависимость от выборочного контроля вручную, значительная задержка	Модель влияния вибрации на шероховатость с выводом в реальном времени	Время предупреждения о нарушении качества ≥ 30 минут
Оптимизация энергопотребления	Статическая настройка параметров, значительные колебания энергопотребления	Динамическая настройка параметров резания с использованием обучения с подкреплением (<i>reinforcement learning</i>)	Снижение удельного энергопотребления на 15–20 %

Технология цифровых двойников в сочетании с алгоритмами ИИ представляет собой инновационное решение для реализации условно-предиктивного обслуживания в области обработки деталей. Цифровой двойник представляет собой виртуальную модель физического объекта, которая обеспечивает отображение состояния объекта и его динамики в реальном времени. Цифровой двойник станка ЧПУ моделирует взаимодействие между шпинделем, режущим инструментом и направляющей, что позволяет проводить анализ их взаимосвязей и поведения в различных условиях обработки.

Использование системы моделирования *ANSYS* для создания модели многотельной динамики «шпиндель – режущий инструмент – направляющая» позволяет анализировать вибрации, механические нагрузки и другие факторы, оказывающие влияние на точность и качество обработки.

Для анализа закономерностей и предсказания дрейфа параметров процесса обработки используется сеть долгосрочной краткосрочной памяти (*LSTM*). Данная архитектура рекуррентной нейронной сети демонстрирует высокую эффективность при работе с временными рядами. Обучение модели на данных, собранных в процессе обработки, позволяет выявлять закономерности, что способствует точному прогнозированию сроков службы режущего инструмента.

Применение цифровых двойников заключается во взаимодействии виртуального и реального объектов, представляющем собой непрерывный процесс итераций. В процессе обработки данные, собранные с помощью датчиков, постоянно возвращаются в виртуальную модель для корректировки параметров. Виртуальная модель на основе результатов симуляции определяет соответствующие технологические параметры обработки, которые затем внедряются в реальное производство. В соответствии с [10] на заводе по производству пресс-форм применение данного метода для прогнозирования влияния различных параметров резания на срок службы шпинделя, позволило снизить частоту вращения на этапе чистовой обработки с 8000 об/мин до 6500 об/мин при сохранении точности обработки, при этом средний срок службы подшипников шпинделя увеличился на 40 %.

Гибридный подход, сочетающий виртуальное и реальное, не только моделирует реальное состояние работы оборудования, но и с помощью ИИ прогнозирует возникновение неисправностей, реализуя переход от пассивного мониторинга к активному предотвращению. Одним из типичных случаев применения технологии *AIoT* в мониторинге станков с ЧПУ является обнаружение аномалий вибрации. При использовании традиционного порогового метода уровень ложных срабатываний при аномальной вибрации составляет примерно 20–30 %, тогда как *AIoT*-решение на основе *CNN* и механизма внимания позволяет снизить уровень ложных срабатываний до 5 % и обеспечить заблаговременное обнаружение более чем за 2 часа. На основе модели слияния Трансформер ошибка прогноза остаточного ресурса режущего инструмента поддерживается в пределах 10 %, а оптимизация плана замены режущего инструмента повышается на 30 % [5].

Заключение

Несмотря на существенные достижения в области интеллектуального мониторинга промышленного оборудования, в то же время возникают проблемы, требующие решения.

В условиях ограниченного объема данных о неисправностях новых станков с ЧПУ традиционные алгоритмы теряют точность на 30 % при объеме выборки менее 100 образцов [11]. Это делает обучение моделей менее эффективным и затрудняет их обобщение на новые данные. Решение проблемы видится в использовании обучения с малым количеством данных (*Few-Shot Learning*), которое позволяет моделям адаптироваться на основе небольшого количества примеров.

Модели глубокого обучения часто работают как «черные ящики», что затрудняет анализ корневых причин неисправностей. Около 40 % промышленных предприятий отказываются от использования «необъяснимых» моделей [5]. Решением проблемы может стать разработка интерпретируемых моделей, которые могут предоставлять объяснения своих предсказаний, а также использование методов локального объяснения интерпретируемой моделью (*Local Interpretable Model-agnostic Explanations, LIME*) или аддитивного объяснения Шепли (*Shapley Additive Explanations, SHAP*), которые помогают понять, какие факторы влияют на принятие решений моделью.

Еще одна проблема состоит в противоречии между реальным временем и вычислительной мощностью. Глубокий анализ вибрационных сигналов с частотой 10 кГц подразумевает обработку больших объемов данных. Для получения точных результатов необходимо обрабатывать данные с высокой разрешающей способностью, что требует значительных вычислительных ресурсов. Графические процессоры могут значительно ускорить обработку данных благодаря своей архитектуре, оптимизированной для параллельных вычислений. Промышленные же граничные узлы, такие

как *Raspberry Pi 4*, обладают ограниченной вычислительной мощностью. Это создает проблему для выполнения задач, требующих интенсивной обработки данных. Даже если такие устройства могут собирать данные, их возможности по обработке в реальном времени часто недостаточны [6].

Хотя *AIoT* способен решать задачи промышленного мониторинга, его применение в станках с ЧПУ сталкивается с тройственным противоречием между эффективностью обработки ИИ, точностью и стоимостью, что стимулирует исследования и технологические инновации в соответствующих областях. Проблема баланса между точностью и эффективностью всегда является ключевой применительно к промышленному ИИ.

Литература

1. Spatio-temporal information analytics based performance-driven industrial process monitoring framework with cloud-edge-device collaboration / Chi Zhang, Jie Dong, Kaixiang Peng, Hanwen Zhang // *Journal of Manufacturing Processes*. – 2024. – Vol. 110. – P. 224–237.
2. Qingzong Li. Remote Monitoring and Maintenance for Equipment and Production Lines on Industrial Internet: A Literature Review / Qingzong Li, Yuqian Yang, Pingyu Jiang // *Machines*. – 2022. – Vol. 11, N 1. – P. 12–12.
3. Dong Ming Xu. Research on General Remote Monitoring System for Industrial Equipment / Dong Ming Xu, Li Sheng Shu // *Applied Mechanics and Materials*. – 2012. – Vol. 1968, N 201–202. – P. 678–681.
4. BHiveSense: An integrated information system architecture for sustainable remote monitoring and management of apiaries based on IoT and microservices / D. Cota, J. Martins, H. Mamede, F. Branco // *Journal of Open Innovation: Technology, Market, and Complexity*. – 2023. – Vol. 9, N 3.
5. Zheng Lei. Remote monitoring method of unmanned substation based on wireless communication network / Zheng Lei, Wang Nan, Chen Jun // *Electrical Technology and Economy*. – 2024. – N 04. – P. 193–195.
6. Wang Weiwei. Real-time analysis and optimization of PAL video surveillance system / Wang Weiwei, Xiang Shizhen, Dong Shengpeng // *Journal of Computer Applications*. – 2021. – Vol. 41, N S2. – P. 330–334.
7. Mourtzis, D. Design and development of an IoT enabled platform for remote monitoring and predictive maintenance of industrial equipment / D. Mourtzis, J. Angelopoulos, N. Panopoulos // *Procedia Manufacturing*. – 2021. – Vol. 54. – P. 166–171.
8. A Cloud-based Architecture for the Internet of Things targeting Industrial Devices Remote Monitoring and Control / A. F. da Silva, R. L. Ohta, M. N. dos Santos, A. P. D. Binotto // *IFAC PapersOnLine*. – 2016. – Vol. 49, N 30. – P. 108–113.
9. Kozovsky, M. Remote Programming and Monitoring of Industrial Devices Using NAT Traversal and USB Over IP / M. Kozovsky // *IFAC PapersOnLine*. – 2016. – Vol. 49, N 25. – P. 254–259.
10. Lutovac, M. Remote Monitoring and Control of Industrial Robot based on Android Device and Wi-Fi Communication / M. Lutovac // *Automatika*. – 2015. – Vol. 56, N 3. – P. 281–291.
11. Power marketing and distribution network remote visual control system based on big data architecture / Xueqin Zhang, Xudong Wang, Jing Duan, Xiaojun Sun, Guohua Zhang, Bo Zhang // *Journal of Physics: Conference Series*. – 2021. – Vol. 2030, N 1.
12. Tele-Monitoring System for Chronic Diseases Management: Requirements and Architecture / L. Mucchi, S. Jayousil, A. Gant [et al.] // *International Journal of Environmental Research and Public Health*. – 2021. – Vol. 18, N 14. – P. 7459–7459.

References

1. Zhang C., Dong J., Peng K., Zhang H. Spatio-temporal information analytics based performance-driven industrial process monitoring framework with cloud-edge-device collaboration. *Journal of Manufacturing Processes*, 2024, vol. 110, pp. 224–237.
2. Li Q., Yang Y., Jiang P. Remote Monitoring and Maintenance for Equipment and Production Lines on Industrial Internet: A Literature Review. *Machines*, 2022, vol. 11, no. 1, pp. 12–12.
3. Xu D. M., Shu L. Sh. Research on General Remote Monitoring System for Industrial Equipment. *Applied Mechanics and Materials*, 2012, vol. 1968, no. 201–202, pp. 678–681.
4. Cota D., Martins J., Mamede H., Branco F. BHiveSense: An integrated information system architecture for sustainable remote monitoring and management of apiaries based on IoT and microservices. *Journal of Open Innovation: Technology, Market, and Complexity*, 2023, vol. 9, no. 3.
5. Lei Z., Nan W., Jun Ch. Remote monitoring method of unmanned substation based on wireless communication network. *Electrical Technology and Economy*, 2024, no. 04, pp. 193–195.
6. Weiwei W., Shizhen X., Shengpeng D. Real-time analysis and optimization of PAL video surveillance system. *Journal of Computer Applications*, 2021, vol. 41, no. S2, pp. 330–334.
7. Mourtzis D., Angelopoulos J., Panopoulos N. Design and development of an IoT enabled platform for remote monitoring and predictive maintenance of industrial equipment. *Procedia Manufacturing*, 2021, vol. 54, pp. 166–171.
8. da Silva A. F., Ohta R. L., dos Santos M. N., Binotto A. P. D. A Cloud-based Architecture for the Internet of Things targeting Industrial Devices Remote Monitoring and Control. *IFAC PapersOnLine*, 2016, vol. 49, no. 30, pp. 108–113.
9. Kozovsky M. Remote Programming and Monitoring of Industrial Devices Using NAT Traversal and USB Over IP. *IFAC PapersOnLine*, 2016, vol. 49, no. 25, pp. 254–259.
10. Lutovac M. Remote Monitoring and Control of Industrial Robot based on Android Device and Wi-Fi Communication. *Automatika*, 2015, vol. 56, no. 3, pp. 281–291.
11. Zhang X., Wang X., Duan J., Sun X., Zhang Guohua, Zhang B. Power marketing and distribution network remote visual control system based on big data architecture. *Journal of Physics: Conference Series*, 2021, vol. 2030, no. 1.
12. Mucchi L., Jayousil S., Gant A., Paoletti E., Zoppi P. Tele-Monitoring System for Chronic Diseases Management: Requirements and Architecture. *International Journal of Environmental Research and Public Health*, 2021, vol. 18, no. 14, pp. 7459–7459.

Поступила 13.10.2025 г.