

**ЛУБАШЕВСКИЙ Е. М., НИКИТИН К. А.**  
**АЛГОРИТМИЧЕСКОЕ ОБЕСПЕЧЕНИЕ СИСТЕМ ПРЕДИКТИВНОЙ**  
**АНАЛИТИКИ ПРОМЫШЛЕННОГО ОБОРУДОВАНИЯ:**  
**СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ В**  
**УСЛОВИЯХ ЦИФРОВОЙ ТРАНСФОРМАЦИИ**

УДК 004.85, ГРНТИ 28.23.25

*Статья поступила в редакцию 18.12.2025*

Алгоритмическое обеспечение систем предиктивной аналитики промышленного оборудования: сравнительный анализ методов машинного обучения в условиях цифровой трансформации

Algorithmic Support for Predictive Analytics Systems of Industrial Equipment: A Comparative Analysis of Machine Learning Methods in the Context of Digital Transformation

**Е. М. Лубашевский, К. А. Никитин**

**E. M. Lubashevsky, K. A. Nikitin**

Поволжский государственный университет телекоммуникаций и информатики, г. Самара

Povolzhskiy State University of Telecommunications and Informatics, Samara

*В статье представлен обзор современных подходов к реализации предиктивной аналитики (Predictive Analytics) и обнаружению аномалий в телеметрических данных промышленного оборудования. Рассматривается эволюция стратегий технического обслуживания: от планово-предупредительных ремонтов (ППР) к обслуживанию по состоянию (СВМ) и проактивному сервису. Проведен сравнительный анализ методов машинного обучения – от статистического анализа временных рядов до глубоких нейронных сетей, с учетом специфики их внедрения на российских предприятиях. Особое внимание уделено проблемам работы с гетерогенным парком оборудования, дефицита размеченных данных об отказах и задачам импортозамещения программного обеспечения для инженерного анализа.*

*The article presents an overview of modern approaches to implementing Predictive Analytics and anomaly detection in telemetry data of industrial equipment. The evolution of maintenance strategies is considered: from scheduled preventive maintenance to Condition-Based Maintenance (CBM) and proactive service. A comparative analysis of machine learning methods is performed – from statistical time series analysis to deep neural networks, considering the specifics of their implementation at Russian enterprises. Special attention is paid to the challenges of dealing with a heterogeneous equipment fleet, the scarcity of labeled failure data, and the tasks of software import substitution for engineering analysis.*

**Ключевые слова:** предиктивная аналитика, обнаружение аномалий, машинное обучение, техническое обслуживание и ремонт (ТОиР), цифровой двойник, временные ряды, импортозамещение, Industry 4.0

**Keywords:** predictive analytics, anomaly detection, machine learning, maintenance and repair (MRO), digital twin, time series, import substitution, Industry 4.0

## Введение

Современный этап развития промышленного сектора Российской Федерации характеризуется переходом от экстенсивной автоматизации к глубокой цифровизации технологических процессов в парадигме «Индустрии 4.0». Однако, в отличие от общемировых трендов, отечественная промышленность сталкивается с уникальным набором вызовов. Ключевой задачей становится не просто повышение эффективности, а обеспечение технологического суверенитета и устойчивости производств в условиях ограниченного доступа к зарубежным компонентам и сервисным технологиям. Как отмечают в своем исследовании Сухомлин В.А. и коллеги, создание отечественных цифровых двойников и аналитических платформ является необходимым условием для снижения зависимости от иностранных вендоров и перехода к индустриальным киберфизическим системам нового поколения [Сухомлин, Намиот, Гапанович, 2023].

Одной из наиболее острых проблем остается старение основных фондов. Эксплуатация парка оборудования, имеющего высокую степень износа, в условиях усложнения логистики поставок запасных частей, делает экономически неприемлемыми классические стратегии технического обслуживания и ремонта (ТОиР). Традиционная система планово-предупредительных ремонтов (ППР), основанная на статистических нормах наработки на отказ, часто приводит либо к избыточному обслуживанию («over-maintenance»), либо к аварийным простоям, стоимость которых для непрерывных производств критически высока. Примером сложности диагностики высоковольтного оборудования, где цена отказа исчисляется миллионами рублей, служат силовые трансформаторы, для которых методы цифрового двойникования становятся безальтернативным способом продления ресурса [Хальясмаа, Ревенков, Сидорова, 2022].

Существующие на большинстве предприятий системы диспетчеризации (SCADA) и автоматизированные системы управления (АСУ ТП) успешно справляются с задачами оперативного управления, но оказываются неэффективными для раннего обнаружения дефектов. Традиционный подход, базирующийся на пороговых значениях (уставках), реагирует только на уже развившуюся аварию, когда параметры (вибрация, температура, ток) выходят за пределы допустимых диапазонов. В то же время, зарождающийся дефект проявляет себя в виде слабых аномалий и корреляционных сдвигов в многомерных временных рядах, которые невозможно зафиксировать простыми правилами «if-then».

Для решения этой задачи необходим переход к интеллектуальному анализу данных (Predictive Maintenance – PdM). Согласно международным обзорам, внедрение предиктивных моделей позволяет сократить затраты на ТОиР на 25–30% и уменьшить время простоев на 35–45% [Zonta et al., 2020]. Тем не менее, прямое заимствование западных методологий невозможно без адаптации к российским реалиям: низкому качеству исторических данных, разнородности датчиков и отсутствию единых стандартов сбора телеметрии.

В отечественной научной практике активно развиваются методы, позволяющие работать с зашумленными данными и выявлять аномалии без наличия обширной базы примеров поломок. В частности, подходы, основанные на статистическом анализе и прогнозировании временных рядов, демонстрируют высокую эффективность при минимальных требованиях к вычислительным ресурсам [Раюшкин, Щербаков, Казаков, 2021; Девришев, Петросян, 2021]. Целью данной работы является систематизация и сравнительный анализ алгоритмов машинного обучения, применимых для задач диагностики промышленного оборудования в условиях текущих технологических и экономических ограничений.

### **Углубленный анализ методов диагностики и поиска аномалий**

Выбор математического аппарата для систем предиктивной аналитики (PdM) определяется балансом между интерпретируемостью модели, требованиями к вычислительным ресурсам и природой входных данных. Рассмотрим три ключевых класса методов, детализируя принципы их работы.

### **Статистический анализ и методы контроля процессов (SPC)**

Этот класс методов исторически первым нашел применение в АСУ ТП. В их основе лежит гипотеза о стационарности нормального режима работы оборудования.

- **Алгоритмическая суть.** Классические методы, такие как карты Шухарта или правило  $3\sigma$ , анализируют мгновенные значения сигнала. Если значение выходит за границы  $\mu \pm 3\sigma$ , фиксируется аномалия. Однако для задач предиктивной диагностики (раннего обнаружения) эти методы малоэффективны, так как они пропускают медленные тренды деградации внутри допустимого диапазона. Более совершенным инструментом является алгоритм кумулятивных сумм CUSUM (Cumulative Sum Control Chart), исследованный в работах Раюшкина Э.С. [4]. Метод накапливает разности между текущим значением и целевым средним. Даже микроскопический сдвиг среднего (drift), незаметный на графике амплитуд, приводит к быстрому росту кумулятивной суммы, что позволяет детектировать зарождающийся износ подшипника или дрейф датчика задолго до аварийной уставки.

- **Специфика применения.** Идеально подходят для одномерных временных рядов (температура, давление) в системах с ограниченными ресурсами (ПЛК).

## Классическое машинное обучение (Classical ML)

Когда физика процесса сложна и зависимость между параметрами нелинейна, применяются методы машинного обучения. Здесь ключевую роль играет этап конструирования признаков (Feature Engineering). «Сырой» сигнал (например, виброускорение) преобразуется экспертом в набор информативных признаков: RMS, эксцесс, пик-фактор или спектральные гармоники (через быстрое преобразование Фурье).

- **Случайный лес (Random Forest) и Градиентный бустинг.** Как показано в исследовании Киракосяна А.А. [6], ансамблевые методы демонстрируют наилучшую устойчивость на промышленных данных. Суть метода: Алгоритм строит множество решающих деревьев. Каждое дерево обучается на подвыборке данных и голосует за класс состояния («Норма», «Дефект А», «Дефект Б»). Почему это работает: Одиночное решающее дерево склонно к переобучению (запоминанию шума), но ансамбль из сотен деревьев усредняет ошибки, выделяя значимый сигнал. Это позволяет работать с данными, где соотношение «сигнал/шум» низкое, что типично для цеховых условий.

- **Метод опорных векторов (SVM).** Используется для задач классификации при малом объеме выборки. Алгоритм ищет гиперплоскость, которая максимально широко разделяет классы состояний в многомерном пространстве признаков. Это эффективно для задач диагностики конкретных узлов (например, классификация типа дефекта обмотки трансформатора [2]), где количество примеров с дефектами исчисляется единицами.

## Глубокое обучение (Deep Learning) и работа с «сырыми» данными

Данный класс методов позволяет исключить ручной этап выделения признаков, переложив эту задачу на нейросеть. Это критически важно для сложных сигналов (акустика, высокочастотная вибрация), где человек может не знать, какой именно паттерн является признаком поломки.

- **Рекуррентные нейронные сети (LSTM/GRU).** В отличие от классических методов, считающих измерения независимыми, сети LSTM (Long Short-Term Memory) обладают «памятью». Алгоритмическая суть: Архитектура сети содержит специальные ячейки памяти и вентили (gates), которые решают, какую информацию из прошлого шага времени нужно сохранить, а какую забыть. Применение: Прогнозирование временных рядов (RUL – Remaining Useful Life). Сеть обучается на истории работы турбины и предсказывает значение вибрации на шаг вперед. Если реальное значение начинает систематически отклоняться от предсказания сети (рост ошибки невязки), фиксируется аномалия [5].

- **Автоэнкодеры (Autoencoders)** – путь к обучению без учителя: Это наиболее перспективная архитектура для условий дефицита данных об авариях. Алгоритмическая суть: Нейросеть состоит из двух частей: Энкодера, который сжимает входной сигнал в компактное векторное представление (латентное пространство), и Декодера, который пытается восстановить

исходный сигнал из этого сжатого кода. Механика поиска аномалий: Сеть обучается только на исправном состоянии оборудования. Она учится идеально сжимать и восстанавливать «нормальные» паттерны. Если на вход подать сигнал с дефектом (которого сеть никогда не видела), она не сможет его корректно восстановить, и ошибка реконструкции (Reconstruction Error) резко возрастает. Это позволяет создать универсальный детектор неисправностей без сбора библиотеки поломок [7, 9].

### Комплексный сравнительный анализ

В Таблице 1 представлен расширенный анализ применимости рассмотренных методов с учетом критериев интерпретируемости (Explainability) и требований к инфраструктуре, что является определяющим фактором при импортозамещении ПО.

Таблица 1. Сравнительный анализ алгоритмического обеспечения систем предиктивной аналитики

Критерий сравнения	Статистические методы (SPC/CUSUM)	Классическое ML (Random Forest, SVM)	Глубокое обучение (Deep Learning: LSTM, AE)
Входные данные	Одномерные ряды, низкая частота дискретизации (SCADA теги).	Структурированные таблицы. Требуется экспертное выделение признаков (спектры, статистики).	«Сырые» высокочастотные сигналы (акустика, токи), изображения, видеопоток.
Зависимость от разметки	Не требуется (работа по уставкам или трендам).	Высокая. Требуется размеченной выборки («Норма»/«Отказ») для обучения с учителем.	Низкая (для Автоэнкодеров). Обучается на «нормальных» режимах (Unsupervised).
Способность к обобщению	Низкая. Не видит корреляций между разными датчиками.	Средняя. Хорошо находит нелинейные связи в рамках обучающей выборки.	Высокая. Автоматически извлекает сложные латентные признаки и паттерны.
Интерпретируемость (XAI)	«Белый ящик». Результат очевиден и прозрачен для инженера.	«Серый ящик». Можно оценить важность признаков (Feature Importance).	«Черный ящик». Требуется надстроек (LIME, SHAP) для объяснения причин решения.
Вычислительная сложность	Низкая (CPU). Реализуемо на контроллерах (Edge).	Средняя (CPU). Требуется ресурсов на обучение, инференс быстрый.	Высокая (GPU). Требуется серверов для обучения, возможен тяжелый инференс.
Тип выявляемых дефектов	Выход параметров за границы, резкие	Известные типы дефектов, присутствовавшие в обучающей выборке.	Скрытые, зарождающиеся аномалии, новые типы дефектов (через

Критерий сравнения	Статистические методы (SPC/CUSUM)	Классическое ML (Random Forest, SVM)	Глубокое обучение (Deep Learning: LSTM, AE)
	скачки, явный дрейф.		ошибку реконструкции).
Перспектива в РФ	Базовая автоматизация устаревшего парка станков.	Массовое внедрение в ERP/EAM системах отечественных вендоров.	Создание Цифровых двойников критического оборудования (турбины, реакторы).

## Выводы

Проведенный анализ позволяет сделать вывод, что универсального алгоритма ("Silver Bullet") для задач предиктивной аналитики не существует. В условиях российской промышленности, характеризующейся высокой гетерогенностью оборудования, наиболее жизнеспособной стратегией является гибридный подход.

1. Для массового вспомогательного оборудования целесообразно применение классических ML-моделей (Random Forest) поверх существующей SCADA-инфраструктуры, что обеспечивает быстрый экономический эффект без капитальных затрат на «железо».

2. Для критически важных агрегатов безальтернативным вектором развития является внедрение методов глубокого обучения (Автоэнкодеры), реализующих концепцию «Цифрового двойника». Способность этих моделей обучаться в режиме Unsupervised Learning решает ключевую проблему отечественных предприятий – отсутствие качественных исторических баз данных об отказах.

Таким образом, вектор развития отечественного промышленного ПО смещается от простых статистических инструментов к сложным нейросетевым архитектурам, способным выявлять скрытые закономерности в работе оборудования.

## Список использованных источников и литературы

1. Хальясмаа, А. И. Применение технологии цифрового двойника для анализа и прогнозирования состояния трансформаторного оборудования / А. И. Хальясмаа, И. С. Ревенков, А. В. Сидорова // Вестник Казанского государственного энергетического университета. – 2022. – Т. 14, № 3(55). – С. 125–136. – URL: <https://cyberleninka.ru/article/n/primenenie-tehnologii-tsifrovogo-dvoynika-dlya-analiza-i-prognozirovaniya-sostoyaniya-transformatornogo-oborudovaniya>

2. Алюнов, А. Н. Диагностика электрических частей силовых трансформаторов с применением методов машинного обучения / А. Н. Алюнов // Нейрокомпьютеры: разработка, применение. – 2023. – Т. 25, № 5. – URL: <https://radiotec.ru/ru/journal/Neurocomputers/article/23075>

3. Сухомлин, В. А. Анализ тенденций развития цифровых двойников нового поколения / В. А. Сухомлин, Д. Е. Намиот, Д. А. Гапанович // International

Journal of Open Information Technologies. – 2023. – Т. 11, № 10. – URL: <https://cyberleninka.ru/article/n/analiz-tendentsiy-razvitiya-tsifrovyyh-dvoynikov-novogo-pokoleniya>

4. Раюшкин, Э. С. Выявление аномалий в многомерных временных рядах с помощью пакета на языке R / Э. С. Раюшкин, М. В. Щербаков, И. Д. Казаков // Моделирование, оптимизация и информационные технологии. – 2021. – Т. 9, № 3. – URL: <https://moitvivot.ru/ru/journal/pdf?id=948>

5. Девришев, Н. Э. Обнаружение аномалий во временных рядах с помощью методов прогнозирования / Н. Э. Девришев, О. Л. Петросян // Труды СПИИРАН (Proceedings of SPIIRAS). – 2021. – URL: <https://dspace.spbu.ru/handle/11701/32573>

6. Киракосян, А. А. Сравнительный анализ алгоритмов машинного обучения для прогнозирования отказов в механических системах / А. А. Киракосян // Вестник современных исследований. – 2023. – (Электронный ресурс).

7. Cummins, L. Explainable Predictive Maintenance: A Survey of Current Methods, Challenges and Opportunities / L. Cummins [et al.] // IEEE Access. – 2024. – Vol. 12. – URL: <https://ieeexplore.ieee.org/document/10506646>

8. Zonta, T. Predictive Maintenance in the Industry 4.0: A Systematic Literature Review / T. Zonta [et al.] // Computers & Industrial Engineering. – 2020. – Vol. 150. – URL: <https://doi.org/10.1016/j.cie.2020.106889>

9. Maher, H. Survey on Deep Learning applied to predictive maintenance / H. Maher // International Journal of Electrical and Computer Engineering (IJECE). – 2020. – Vol. 10. – URL: <http://ijece.iaescore.com/index.php/IJECE/article/view/22606>

### List of references

1. A. I. Khalyasmaa, I. S. Revenkov, and A. V. Sidorova, "Application of digital twin technology for analysis and forecasting of transformer equipment condition," *Bulletin of the Kazan State Power Engineering University*, vol. 14, no. 3(55), pp. 125-136, 2022. [Online].

Available: <https://cyberleninka.ru/article/n/primeneniye-tehnologii-tsifrovogo-dvoynika-dlya-analiza-i-prognozirovaniya-sostoyaniya-transformatornogo-oborudovaniya>. [Accessed: 14-Mar-2026]. (In Russian).

2. A. N. Alyunov, "Diagnostics of electrical parts of power transformers using machine learning methods," *Neurocomputers: Development, Application*, vol. 25, no. 5, 2023. [Online].

Available: <https://radiotec.ru/ru/journal/Neurocomputers/article/23075>. [Accessed: 14-Mar-2026]. (In Russian).

3. V. A. Sukhomlin, D. E. Namiot, and D. A. Gapanovich, "Analysis of development trends of new generation digital twins," *International Journal of Open Information Technologies*, vol. 11, no. 10, 2023. [Online].

Available: <https://cyberleninka.ru/article/n/analiz-tendentsiy-razvitiya-tsifrovyyh-dvoynikov-novogo-pokoleniya>. [Accessed: 14-Mar-2026]. (In Russian).

4. E. S. Rayushkin, M. V. Shcherbakov, and I. D. Kazakov, "Anomaly detection in multivariate time series using a package in the R language," *Modeling, Optimization*

*and Information Technology*, vol. 9, no. 3, 2021. [Online]. Available: <https://moitvvt.ru/ru/journal/pdf?id=948>. [Accessed: 14-Mar-2026]. (In Russian).

5. N. E. Devrishev and O. L. Petrosyan, "Anomaly detection in time series using forecasting methods," *Proceedings of SPIIRAS*, 2021. [Online]. Available: <https://dspace.spbu.ru/handle/11701/32573>. [Accessed: 14-Mar-2026]. (In Russian).

6. A. A. Kirakosyan, "Comparative analysis of machine learning algorithms for failure prediction in mechanical systems," *Bulletin of Modern Research*, 2023. (In Russian). [Online]. Available: [electronic resource].

7. L. Cummins et al., "Explainable Predictive Maintenance: A Survey of Current Methods, Challenges and Opportunities," *IEEE Access*, vol. 12, 2024. [Online]. Available: <https://ieeexplore.ieee.org/document/10506646>. [Accessed: 14-Mar-2026]. (In English).

8. T. Zonta et al., "Predictive Maintenance in the Industry 4.0: A Systematic Literature Review," *Computers & Industrial Engineering*, vol. 150, 2020. [Online]. Available: <https://doi.org/10.1016/j.cie.2020.106889>. [Accessed: 14-Mar-2026]. (In English).

9. H. Maher, "Survey on Deep Learning applied to predictive maintenance," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 10, 2020. [Online]. Available: <http://ijece.iaescore.com/index.php/IJECE/article/view/22606>. [Accessed: 14-Mar-2026]. (In English).