

УДК 004.89

EDN [JRZNIK](#)



<https://www.doi.org/10.47813/mip.5.2023.9.58-68>

Разработка метода оценки технического состояния оборудования при использовании методов машинного обучения

Д.В. Колесникова*, Р.А. Юрьева

Университет ИТМО, пр. Кронверкский, 49, Санкт-Петербург, 197101, Россия

*E-mail: kolesnikova_d@itmo.ru

Аннотация. В ходе исследования разработан метод оценки состояния оборудования, который основывается на использовании средств искусственного интеллекта и методах машинного обучения. Представлено поэтапное описание действий для получения общей оценки, составными частями которой является техническое состояние и занятость оборудования. В основе метода лежит использование текущих фактических значений параметров, которые фиксируются с помощью датчиков, в процессе работы. Полученные данные проходят предварительную обработку и анализ для дальнейшей работы со средствами искусственного интеллекта. В работе рассмотрены методы: дерево решений (Decision Tree), метод случайного леса (Random Forest), градиентный бустинг (XGboost), которые позволяют определить значимые параметры, влияющие на определение износа или поломки оборудования. Для прогнозирования последующего ряда значений используется нейронная сеть LSTM. Полученные результаты используются в математической модели для получения количественной оценки, а после нормируются относительно предложенной в работе шкале. Кроме того, в методе предлагается вести учет занятости оборудования, так как данный параметр позволит точнее определять состояние оборудования в текущий момент, например, для разработки технологических процессов. В результатах работы также описаны ограничения метода.

Ключевые слова: оценка состояния оборудования, диагностика, нормирование, искусственный интеллект.

Development of method for assessing the equipment technical condition using machine learning

D.V. Kolesnikova*, R.A. Iureva

ITMO University, 49 Kronverksky pr., Saint-Petersburg, 197101, Russia

*E-mail: kolesnikova_d@itmo.ru

Abstract. The method for equipment condition assessing was developed in the study. It is based on the use of artificial intelligence and machine learning methods. A step-by-step description of actions is presented to obtain a general assessment, the components of which are the technical condition and equipment occupancy. The method is based on the use of current actual parameter values, which are recorded using sensors during operation. The received data undergoes preliminary processing and analysis for further work with artificial intelligence tools. The paper discusses methods: Random Forest, Decision Tree, gradient boosting (XGboost), which allow to determine significant parameters that influence the wear or equipment failure determination. LSTM neural network is used to predict the next series of values. The obtained results are used in a mathematical model to obtain a quantitative assessment, and then normalized relative to the scale proposed in the work. In addition, the method proposes to keep records of equipment occupancy, since this parameter will make it possible to determine the state of the equipment more accurately at the current moment, for example, for the development of technological processes. The results of the work also describe the limitations of the method.

Keywords: equipment condition assessment, diagnostics, standardization, artificial intelligence.

1. Введение

В современном мире, где промышленные процессы становятся все более сложными и интенсивными, задача обслуживания и поддержания технического состояния оборудования приобретает особую актуальность. Производства в области машиностроения, электроники, или приборостроения сталкиваются с необходимостью эффективного мониторинга и прогнозирования состояния оборудования. Это не только способствует минимизации простоев и экономии ресурсов, но и повышает общую безопасность и надежность производственных процессов [1].

Внедрение современных средств искусственного интеллекта (ИИ) в области оценки технического состояния оборудования представляет собой важный этап в развитии технической диагностики и обслуживания промышленных систем. В эпоху индустрии 4.0, где автоматизация и оптимизация производства становятся ключевыми факторами конкурентоспособности, эффективное прогнозирование и контроль состояния оборудования приобретают повышенное значение [2]. В данном исследовании рассматривается использование методов машинного обучения (МО) для оценки технического состояния оборудования. Машинное обучение, а именно алгоритмы классификации, регрессии и кластеризации, зарекомендовало себя как эффективный инструмент для анализа больших объемов данных и выявления сложных зависимостей.

Следуя тенденциям промышленной революции, современные предприятия сталкиваются с постоянным ростом сложности и объемов производства. Одновременно с этим, клиенты становятся более требовательными к качеству продукции и срокам поставок. В таких условиях несвоевременные отказы оборудования или их ремонт могут привести к серьезным простоям и финансовым потерям. Для эффективного управления и поддержания технической готовности оборудования, на смену традиционным методам диагностики приходят методы ИИ, которые позволяют прогнозировать возможные отказы и, соответственно, проводить профилактическое обслуживание.

Таким образом можно выделить следующие преимущества диагностики оборудования [3]:

- Ранее выявление и устранение потенциальных проблем и неисправностей (например, износ инструментов), которые могут привести к снижению производительности, что влияет на сохранение рабочих процессов и выполнение производственных планов.

- Предотвращение сбоев и внеплановых остановок оборудования.
- Повышение безопасности работы машин.
- Оптимизация расходов на техническое обслуживание и ремонт.
- Продление срока службы оборудования путем своевременного обслуживания и регулярной оценки состояния.
- Улучшение качества продукции (поддержание высоких стандартов качества).
- Разработка рациональных технологических процессов, что позволяет эффективно использовать текущие ресурсы, учитывая их состояние и нагрузку.
- Снижение экологического воздействия, снижение выбросов и потребления ресурсов, что положительно сказывается на экологии и соответствует современным требованиям к устойчивости.

Однако, в ходе оценки можно столкнуться со сложностями, которые связаны во многом с данными, которые мы получаем с датчиков. Они являются неоднородными, варьируются по качеству, достоверностью, полноте. Таким образом необходимо нанимать людей, которые будут анализировать и приводить данные к общему виду для дальнейшей работы с ними. Кроме того, промышленные предприятия могут использовать разнообразное оборудование, начиная от станков и электронных устройств до больших производственных линий и транспортных систем. Оценка состояния каждого типа оборудования требует специализированных подходов и знаний.

2. Постановка задачи (Цель исследования)

На основе проведенного анализа текущих способов оценки состояния оборудования, была поставлена гипотеза о возможности разработки метода оценки, который будет использовать средства искусственного интеллекта для предварительного прогнозирования значений параметров оборудования.

Цель работы является разработка метода оценки состояния оборудования, который будет использовать текущие значения параметров и прогнозировать данные. На основе полученных результатов будет определяться фактическое техническое состояние оборудования.

В ходе работы были поставлены следующие задачи:

- Анализ текущего состояния проблемы.
- Разработка метода оценки состояния, при использовании средств ИИ и МО.
- Нормирование оценки и определение технического состояния.

Научная новизна работы заключается в разработке метода, позволяющего определить фактическое состояние оборудования с помощью прогнозирования его параметров, а также использование подхода к нормированию предложенной оценки.

3. Методы и материалы исследования

В рамках разработки технологических процессов технологю необходимо определять, какое оборудование будет выполнять те или иные операции. В рамках срочных заказов оборудование должно быть работоспособно и исправно для выполнения своих функций. Для обеспечения понимания технологом, какие машины могут выполнить поставленные задачи вовремя и качественно, требуется предварительно определять их состояние.

В рамках исследования использовались технологии системного анализа, имитационного моделирования систем, объектно-ориентированного программирования, средства машинного обучения и искусственного интеллекта, в частности рассматривались методы: дерево решений (Decision Tree), метод случайного леса (Random Forest), нейронная сеть LSTM.

Также в работе использовался ГОСТ 20911–89 [4] для разработки шкалы фактического технического состояния оборудования.

В рамках выполнения первой задачи был проведен анализ литературы.

В статьях [5-6] проведены исследования, в которых использовали нейросетевое моделирование для прогнозирования изменений в состоянии ключевых производственных объектов. Авторы анализировали, как методы машинного обучения могут быть эффективно применены к различным видам оборудования, таким как насосы, компрессоры и двигатели. Они исследовали разнообразные методики обучения, включая глубокое обучение, и сравнили их результаты. Результаты исследования подтвердили, что нейросетевое моделирование успешно используется для прогнозирования изменения состояния, помогает эффективно планировать техническое обслуживание и предотвращать потенциальные сбои.

В работе [7] представлен аналитический обзор и критическая оценка применения ИИ в мониторинге состояния режущего инструмента при обработке материалов. Исследуются существующие методы мониторинга, используемые в процессах обработки, таких как фрезерование или токарная обработка. Они также оценивают эффективность этих методов и выявляют их преимущества и недостатки. Цель работы

обобщить текущее состояние исследований в данной области и выявить тенденции развития.

Также рассмотрена работа [4], являющаяся обзором исследований и практических приложений методов предиктивного обслуживания (технической диагностики) в промышленности. Главной целью работы является проведение системного обзора методов, основанных на данных, которые применяются для предсказания и предотвращения отказов и неисправностей промышленного оборудования. В данной работе авторы анализируют разнообразные методики и техники, использующие данные и информацию о состоянии оборудования для создания моделей предсказания технических отказов.

4. Полученные результаты

В ходе исследования был разработан метод оценки состояния оборудования в режиме реального времени. Основная идея заключается в получении данных с датчиков, установленных на оборудовании. Предварительно данные собираются для обучения модели нейронные сети типа LSTM: предварительно проводится анализ с использованием методов машинного обучения, а также обработка (очистка от выбросов, заполнение пустых данных). Далее в рамках работы оборудования собираются текущие значения, из которых прогнозируется дальнейшее поведение. Однако, чтобы получить интерпретируемую количественную оценку состояния оборудования, важным этапом является применение алгоритма нормировки. Этот алгоритм позволяет связать числовую оценку с фактическим техническим состоянием оборудования, делая эту оценку более информативной и полезной. Укрупненная схема метода приведена на рисунке 1.




Рисунок 1. Процесс оценки состояния оборудования.

Метод состоит из нескольких последовательных шагов. Шаги 1–3 являются подготовительной частью, шаги 4–8 – основной. Все шаги могут выполняться экспертом: аналитиком данных, специалистом по обслуживанию оборудования.

Шаг 1: сбор данных

1. Настройка датчиков для сбора данных с оборудования, подлежащего оценке. Главная задача установки датчиков заключается в том, чтобы получать статистическую и параметрическую информацию об оборудовании в ходе его функционирования.

2. Полученные данные должны непрерывно записываться и архивироваться на протяжении минимум 6 месяцев. Процесс можно автоматизировать с помощью систем SCADA, которые способны обеспечивать непрерывный мониторинг, обработку данных, их визуализацию и сохранение информации о мониторинге и управлении в реальном времени.

Сбор данных с датчиков оборудования на производстве требует индивидуального планирования и настройки в зависимости от различных факторов, таких как вид оборудования, наличие ресурсов и особенности технических характеристик датчиков.

Шаг 2: работа с данными (разметка, обработка)

1. Эксперт присваивает определенные метки, значения набору данных с целью использования их как эталонных для прогнозной модели. Данный шаг может осуществляться вручную или с помощью специализированных автоматизированных средств, например краудсорсинговые платформы для разметки (Amazon Mechanical Turk). Важно выделить такие параметры данных, как текущее состояние оборудования, завершение программы обработки заготовки, а также другие значимые параметры оборудования, которые могут быть определены экспертом.

Для более точной и эффективной разметки данных могут использоваться различные методы анализа, такие как статистический анализ, спектральный анализ, анализ вейвлет-преобразования и другие.

2. Эксперту необходимо привести входные данные к удобному формату для их использования с методами машинного обучения. В рамках этого процесса выполняются следующие задачи: форматирование данных, их очистка от шума и ошибок, а также выборка значимых параметров.

- Форматирование данных: эксперт приводит записи к стандартному формату и также необходимо убедиться, что переменные, представляющие каждый параметр, записываются одинаково.
- Очистка данных: устранение шумов и исправления ошибок в данных. В рамках этой задачи происходит: заполнение недостающих данных, например, использование средних значений; выявляются и удаляются выбросы (данные,

которые сильно выбиваются из общего распределения или представляют собой экстремальные значения); удаление неполных или дублирующих записей.

- Выделение значимых параметров и уменьшение объема данных: с помощью методов МО (Random Forest, Decision Tree и XGboost) эксперт может определить, какие параметры оборудования являются значимыми для прогнозирования, что позволяет сократить репрезентативную выборку данных. В свою очередь данный процесс ускоряет процесс обучения и прогнозирования, сохраняя при этом точность результатов.

Шаг 3: обучение нейронной сети

1. Разделение полученных данных на три набора: обучающий, проверочный и тестовый. Рекомендуется разделить обучающий и проверочный наборы в соотношении 70% к 30% соответственно. Затем проверочный набор разделяется на два поднабора: проверочный и тестовый, в соотношении 80% к 20%.

2. Эксперт определяет архитектуру нейронной сети LSTM.: количество слоев, количество нейронов в каждом слое и функции активации, которые будут использоваться в сети.

3. Запуск процесса обучения сети на обучающем наборе данных. Также эксперт настраивает параметры обучения: скорость обучения и количество эпох (итераций обучения).

4. Проведение оценки успешности обучения, прогнозируя результаты на проверочных и тестовых наборах данных. Это может включать в себя использование различных метрик для оценки качества модели, таких как точность, F1-мера и анализ матрицы ошибок. Эти метрики позволяют оценить, насколько хорошо модель справляется с задачей идентификации и прогнозирования.

Шаг 4: сбор и обработка данных в режиме реального времени

1. Информация, получаемая с датчиков, записывается в специальные лог-файлы.
2. Эксперт проводит очистку данных, если это необходимо (шаг 2).

Шаг 5: прогнозирование значений

1. Для каждого устройства выполняется прогнозирование значений на основе текущих данных с использованием нейронной сети LSTM. Прогнозирование осуществляется только для значимых параметров, определенных на шаге 2.

2. Результатом этой операции является последовательность значений для каждого параметра.

Шаг 6: количественная оценка состояния оборудования

Для каждого параметра (1...i) берем некоторое количество значений (1...n): текущих фактических ($a_1, a_2, \dots a_n$) и прогнозных ($b_1, b_2, \dots b_n$). Далее считаем скользящее среднее значение для каждого признака (уравнение 1). Для каждого оборудования (1 ... j) считаем скользящую среднюю оценку *present value*, *predict value* текущих и прогнозируемых значений параметров. Средняя оценка представляет собой скользящее среднее для каждого признака (1...n) в рамках всех значимых признаков оборудования (1...N). В итоге получаем количественную оценку оборудования $eq_evaluation_j$.

$$\begin{cases} present\ value_j = \frac{\sum_1^N (\sum_1^n a_n)_N}{N \times n} \\ predict\ value_j = \frac{\sum_1^N (\sum_1^n b_n)_N}{N \times n} \\ eq_evaluation_j = |present\ value_j - predict\ value_j| \end{cases}$$

На рисунке 2 приведен пример расчета оценки состояния оборудования.

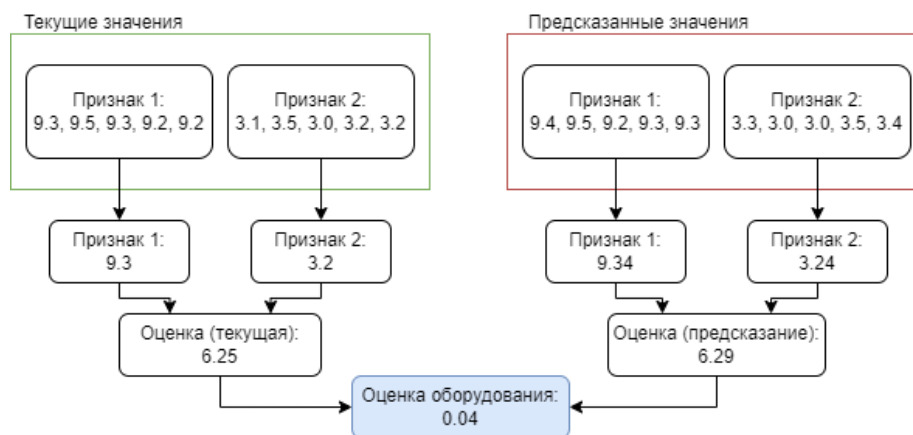


Рисунок 2. Пример расчета оценки оборудования. Здесь рассматриваются текущие и прогнозные значений и в итоге получаем количественную оценку оборудования $eq_evaluation_j$.

Далее необходимо произвести нормирование полученного знания для каждого оборудования, согласно уравнению 2.

Полученное значение входит в рамки распределение значений от 1 до 5. Распределительная шкала соответствует следующих техническим состояниям оборудования, представленным в таблице 1.

Таблица 1. Нормирование значение оценки относительно его состояния.

1	2	3	4	5
Исправное	Работоспособное	Условно- работоспособное	Неработоспособное	Предельное

1. Исправное состояние – объект соответствует всем требованиям, установленным в нормативно-технической документации.

2. Работоспособное состояние – объект способен выполнять свои функции и значения его основных параметров находятся в пределах, установленных в нормативно-технической документации.

3. Условно-работоспособное (неисправное, но работоспособное состояние) – объект не соответствует хотя бы одному из требований технической документации.

4. Неработоспособное состояние – объект не может выполнить свои заданные функции, поскольку хотя бы один из параметров, определяющих его способность функционировать, не соответствует требованиям, установленным в нормативно-технической документации.

5. Предельное состояние – применение объекта по назначению становится неприемлемым или нецелесообразным.

Шаг 7: определение занятости оборудования

Далее производится оценка занятости каждого оборудования. Эксперт вводит данные о текущей загруженности: вводит, свободно оно или занято, в случае занятости, также требуется указать предполагаемое время завершения программы.

Данные состояния были выбраны на основе анализа ГОСТ 20911–89 и литературы:

Алгоритм нормировки занятости оборудования оценивает и классифицирует значения по следующей шкале:

- 1 – свободно;
- 2 – освободится в течение 1 суток;
- 3 – занято, освободится в течение 5 суток;
- 4 – занято, освободится более чем через 5 суток.

Шаг 8: объединение данных в единую модель

Для каждого оборудования определяется количественная оценка его общего состояния. Она зависит от двух показателей – состояния и занятости (уравнение 2). Для определения обобщенной оценки и ее использования на практике используется произведение его составных показателей.

$$eq_assessment_j = [eq_evaluation_j; eq_busy_j]$$

Произведение составных частей используется для удобства применения оценки в дальнейшем.

5. Выводы

Оценка состояния оборудования для производств играет ключевую роль в обеспечении эффективной и безопасной работы. В ходе данного исследования был разработан метод оценки технического состояния оборудования с использованием методов машинного обучения и средств ИИ. В основе метода лежит использование данных, получаемых в процессе работы оборудования с датчиков. Анализ и использование средств нейронных сетей позволяет прогнозировать значения параметров оборудования, а в дальнейшем оценивать полученные результаты. В итоге получаем нормированную оценку фактического технического состояния оборудования.

Однако, также можно выделить некоторые ограничения метода:

- Для обучения нейронной сети необходим большой объем данных, а также работа эксперта. Большие объемы информации, которые передают датчики, требуют специального хранения и обработки, для этого необходимы дополнительные ресурсы и затраты.
- Необходимо обеспечивать точные и качественные данные, иначе при появлении отсутствия значений, шумов и выбросов, могут возникать ошибки или другие отклонения при прогнозировании значений. Это может быть не связано с реальным техническим состоянием оборудования, но привести к ошибкам при обучении нейронной сети.

Список 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. – Казань: Вестник Казанского государственного энергетического университета, 2022 (Тип. Изд-ва). – Т. 14.3 (55). – с. 99-113.
2. Колоденкова А.Е. Интеллектуальный метод прогнозирования технического состояния электротехнического оборудования в условиях нечеткости исходных данных / А.Е. Колоденкова, С.С. Верещагина. – Вестник Ростовского государственного университета путей сообщения, 2019 (Тип. Изд-ва). – Т. 1. – с. 76-81.
 3. Pimenov D.Yu. Artificial intelligence systems for tool condition monitoring in machining: Analysis and critical review / D.Yu. Pimenov // Journal of Intelligent Manufacturing. – 2023. – V.34.5. – P. 2079-2121.
 4. ГОСТ 20911–89. Техническая диагностика. Термины и определения. 2015
 5. Yemelyanov V. Application of neural networks to forecast changes in the technical condition of critical production facilities / V. Yemelyanov // Computers & Electrical Engineering. – 2021. – V.93. –P. 107225.
 6. Горева Т.И. Нейросетевые модели диагностики технических систем / Т.И. Горева, Портнягин Н.Н., Пюкке Г.А. – Вестник КРАУНЦ. Физико-математические науки. – 2012 (Тип. Изд-ва). – Т.4(1). – С. 31-43.
 7. Zhang W. Data-driven methods for predictive maintenance of industrial equipment: A survey / W. Zhang, Dong Y., Hongchao W. – IEEE systems journal. – 2019. – V.13(3). – P. 2213-2227.