

УДК 004.89; 615.47

Михаил Юрьевич Семаков

ООО «ДжейЭмСай», руководитель сектора инноваций, Россия, Иваново, e-mail: mikhail.semakoff@gmail.com

Юлия Вадимовна Вылгина

ФГБОУ ВО «Ивановский государственный энергетический университет имени В.И. Ленина», кандидат экономических наук, доцент кафедры менеджмента и маркетинга, Россия, Иваново, e-mail: jvilgina@mail.ru

Евгений Олегович Грубов

ФГБОУ ВО «Ивановский государственный энергетический университет имени В.И. Ленина», кандидат экономических наук, заведующий кафедрой менеджмента и маркетинга, Россия, Иваново, e-mail: egrubov@yandex.ru

Артем Игоревич Бандюк

ООО «Нейрософт», руководитель отдела развития международных продаж, Россия, Иваново, e-mail: bandjuk.artem@gmail.com

Антон Леонидович Плетнев

ООО «Нейрософт», руководитель сервисного центра, Россия, Иваново, e-mail: Pletnev@neurosoft.com

Метод прогнозирования отказов медицинского оборудования без телеметрии на основе событийных данных эксплуатации

Авторское резюме

Состояние вопроса. Предиктивное техническое обслуживание – одно из ключевых направлений применения машинного обучения в управлении жизненным циклом оборудования. Телеметрические методы обеспечивают высокую точность и требовательны к инфраструктуре и модификации оборудования, ограничивая их применимость для медицинской техники, работающей без телеметрии. Классические статистические методы анализа и оценки надежности (Вейбулл, Кокс) не учитывают динамику событийной последовательности, подходы процессной аналитики не адаптированы к редким сервисным записям. Ни одно из рассмотренных направлений применения методов предиктивного обслуживания не удовлетворяет одновременно трем ключевым требованиям: независимости от телеметрической инфраструктуры, учета динамики дискретных эксплуатационных событий и возможности прямого применения к стандартным сервисным журналам медицинского оборудования. В связи с этим целью настоящего исследования является разработка и верификация метода прогнозирования отказов медицинского оборудования на основе дискретных событийных данных эксплуатации, не требующего телеметрии и использующего только стандартные журналы сервисного обслуживания.

Материалы и методы. Для бинарной классификации отказов применены логистическая регрессия с балансировкой классов и градиентный бустинг XGBoost с учетом требований интерпретируемости и дисбаланса классов (14 %). Валидация выполнена с разбиением по объектам и стратифицированной кросс-валидацией (5 фолдов); основная метрика – ROC-AUC. Метод верифицирован на данных эксплуатации электроэнцефалографического оборудования ООО «Нейрософт» (г. Иваново).

Результаты. Разработан и верифицирован метод прогнозирования отказов медицинского оборудования по дискретным событийным данным без телеметрии. Разработан метод формирования признакового пространства из дискретных событийных данных с агрегацией на горизонтах 30, 90 и 180 дней, применимый к стандартным журналам сервисных заявок. Установлено, что модель XGBoost достигает значения ROC-AUC = 0,82 на горизонте 90 дней, против 0,60 у логистической регрессии. По данным SHAP, сокращение интервалов между ремонтами менее ~281 дня – значимый индикатор роста вероятности отказа.

Выводы. Значение ROC-AUC = 0,82 свидетельствует о хорошем качестве модели при дисбалансе классов, а стандартное отклонение 0,13 указывает на достаточную устойчивость результата. Модель позволяет ранжировать парк по риску отказа на горизонте 90 дней, планировать внеплановое обслуживание и оптимизировать запасы комплектующих. Перспективы дальнейших исследований связаны с валидацией предложенного метода на расширенных выборках, включением признаков фактической нагрузки оборудования и адаптацией модели к дополнительным горизонтам прогнозирования (30 и 180 дней).

Ключевые слова: предиктивное техническое обслуживание, методы машинного обучения, логистическая регрессия, градиентный бустинг, телеметрические методы, стратифицированная кросс-валидация

Mikhail Yurievich Semakov

JMSay LTD, Head of the Innovation Sector, Russia, Ivanovo, e-mail: mikhail.semakoff@gmail.com

Yulia Vadimovna Vylgina

Ivanovo State Power Engineering University, Candidate of Economics Sciences, (PhD), Associate Professor of Management and Marketing Department, Russia, Ivanovo, e-mail: jvilgina@mail.ru

Evgeniy Olegovich Grubov

Ivanovo State Power Engineering University, Candidate of Economics Sciences, (PhD), Head of Management and Marketing Department, Russia, Ivanovo, e-mail: egrubov@yandex.ru

Artem Igorevich Bandyuk

Neurosoft Ltd., Head of International Sales Development Department, Russia, Ivanovo, e-mail: bandjuk.artem@gmail.com

Anton Leonidovich Pletnev

Neurosoft Ltd., Head of Service Center, Russia, Ivanovo, e-mail: Pletnev@neurosoft.com

A telemetry-free method for predicting failures of medical equipment based on operational event data

Abstract

Background. Predictive maintenance is one of the key applications of machine learning in management of equipment lifecycle. Telemetry-based methods provide high accuracy but require substantial infrastructure and equipment modification, limiting their applicability to medical devices without built-in sensors. Classical statistical methods of analysis and reliability assessment (Weibull, Cox) do not capture the dynamics of event sequences, while process-mining approaches are not adapted to sparse service records. None of the considered areas of predictive maintenance methods simultaneously meets three key requirements of independence from telemetry, accounting for event dynamics, and operating on standard service logs. Thus, the aim of this study is to develop and verify a method to predict medical equipment failures based on discrete event data of operation, which does not require telemetry and uses only standard service logs.

Materials and methods. Binary failure classification has been performed using logistic regression with class balancing and gradient boosting (XGBoost) taking into account interpretability requirements and class imbalance (14 %). Validation has been carried out using object-wise splitting and stratified 5-fold cross-validation; the primary metric is ROC-AUC. The method has been verified on operational data from electroencephalographic equipment of Neurosoft LLC (Ivanovo).

Results. A method to predict medical equipment failures based on discrete event data without telemetry has been developed and verified. A method for constructing a feature space from discrete event data with aggregation over 30-, 90-, and 180-day horizons has been developed. It is applicable to standard service-request logs. It has been established that the XGBoost model achieved a ROC-AUC of 0,82 at the 90-day horizon, compared to 0,60 for logistic regression. SHAP analysis has revealed that a reduction in the interval between repairs to below approximately 281 days is a significant indicator of increasing failure probability.

Conclusions. The ROC AUC value of 0,82 indicates good quality of the model under class imbalance, and the standard deviation of 0,13 indicates sufficient stability of the result. The model enables ranking the equipment fleet by failure risk over a 90-day horizon, planning unscheduled maintenance, and optimizing spare parts inventory. Further research includes validation of the proposed method on expanded samples, incorporation of workload features, and adaptation of the model to additional to 30- and 180-day prediction horizons.

Key words: predictive maintenance, machine learning methods, logistic regression, gradient boosting, telemetry-based methods, stratified cross-validation

DOI: 10.17588/2072-2672.2026.4.086-094

Введение. Предиктивное техническое обслуживание (Predictive Maintenance, PdM) является одним из ключевых направлений применения методов машинного обучения в управлении жизненным циклом технического оборудования [1, 2, 3, 4]. Большинство существующих подходов к PdM основано на непрерывном мониторинге параметров состояния оборудования – вибрации, температуры, электрических характеристик – с использованием встроенных или внешних датчиков [3, 5, 6]. Коммерческие решения реализуют данную парадигму, предполагая наличие телеметрической инфраструктуры как базового условия применения.

В то же время значительная часть оборудования в реальной эксплуатации не оснащена средствами непрерывного мониторинга. Это особенно характерно для медицинской техники, где использование дополнительных датчиков

ограничено регуляторными требованиями, экономическими факторами и неоднородностью установленного парка. В результате телеметрические подходы оказываются ограниченно применимыми в широком классе практических задач. При этом в процессе эксплуатации оборудования формируются дискретные событийные данные – записи о техническом обслуживании, ремонтах, отказах и восстановлении работоспособности. Эти данные возникают в рамках стандартных эксплуатационных процессов и не требуют дополнительной инструментализации оборудования. Однако вопрос о возможности их использования для прогнозирования отказов остается ограниченно изученным.

Существующие методы анализа событийных данных, включая модели выживаемости и статистические модели надежности, позволяют оценивать вероятность отказа на основе

агрегированных характеристик, однако ограничены в учете динамики изменений состояния оборудования [7, 8, 9]. Подходы к анализу журналов событий, применяемые в процессной аналитике, ориентированы на последовательности операций и не направлены на моделирование процессов деградации технических систем [7, 8, 10].

Ниже предлагается метод формирования признаков пространства на основе дискретных событийных данных эксплуатации с использованием агрегации по скользящим временным окнам и последующего построения интерпретируемых моделей машинного обучения для прогнозирования отказов. Метод не требует телеметрии, модификации оборудования или установки дополнительных датчиков. Таким образом, в отличие от существующих исследований, сфокусированных на агрегированных показателях надежности и доступных телеметрических данных, ниже рассматривается задача построения прогностической модели на непосредственно сформированных дискретных событийных логах сервисного обслуживания. Научная новизна исследования заключается в формализованном подходе к построению признаков пространства по редким событийным данным и экспериментальном обосновании применимости таких моделей к медицинскому оборудованию без телеметрии.

Методы исследования. Современные методы предиктивного технического обслуживания в значительной степени опираются на анализ телеметрических данных, получаемых в режиме реального времени. В [1, 2] показана эффективность применения методов машинного обучения для обработки вибрационных и акустических сигналов в целях прогнозирования отказов и оценки остаточного ресурса оборудования. Аналогичные подходы применяются для анализа электрических и температурных параметров в различных отраслях [5, 6]. Несмотря на высокую точность, телеметрические методы требуют наличия развитой инфраструктуры сбора и передачи данных. Ограничения их применения для оборудования, не оснащенного датчиками состояния, отмечаются в ряде исследований [10], что формирует запрос на альтернативные подходы.

Классические методы анализа надежности, включая модели выживаемости, распределение Вейбулла и модель пропорциональных рисков Кокса [8], широко используются для оценки вероятности отказа на основе временных характеристик эксплуатации [7]. Данные методы, как правило, рассматривают время до отказа как основную наблюдаемую величину и опираются на агрегированные статистические характеристики. Это ограничивает их способ-

ность учитывать структуру и последовательность эксплуатационных событий, а также снижает точность прогнозов на краткосрочных временных горизонтах [11].

Подходы, основанные на анализе журналов событий (event log analysis, process mining), позволяют выявлять закономерности в последовательностях дискретных событий и реконструировать процессы функционирования систем [12]. В задачах технического обслуживания такие методы применяются для анализа последовательностей операций и выявления аномалий [13].

Вместе с тем большинство исследований ориентировано на системы с высокой плотностью событий и структурированными логами. Применение данных подходов к задачам прогнозирования отказов на основе редких и слабо структурированных событий сервисного обслуживания остается ограниченным.

Исследования по применению методов машинного обучения в задачах технического обслуживания медицинского оборудования [9, 14, 15], как правило, опираются либо на встроенные диагностические данные оборудования, либо на ограниченные выборки с экспериментальными условиями наблюдения.

Подходы, основанные исключительно на анализе дискретных событий сервисного обслуживания без использования телеметрии и данных о нагрузке, представлены в литературе ограниченно [4, 9, 11, 12]. Это определяет актуальность разработки методов, способных извлекать предиктивную информацию из доступных эксплуатационных данных.

В качестве объекта исследования использованы данные эксплуатации и сервисного обслуживания электроэнцефалографического оборудования производства ООО «Нейрософт» (г. Иваново). Данные представлены записями сервисных заявок и содержат следующие поля: идентификатор единицы оборудования; модель; дата отгрузки; дата события; описание неисправности; содержание выполненных работ; дата восстановления работоспособности; гарантийный статус (рис. 1). Для построения обучающей выборки использовались только единицы оборудования, имеющие достаточную историю эксплуатации (не менее двух зафиксированных событий). На основе последовательностей событий сформированы временные срезы, соответствующие моментам наблюдения состояния оборудования.

Каждое событие классифицировалось по типу: ремонт, отказ, диагностика. Классификация выполнялась по заранее заданным правилам на основе ключевых слов и структурированных признаков записей сервисных заявок (табл. 1).




Рис. 1. Идентификация дискретных (событийных) данных для анализа

Таблица 1. Пример фрагмента событийного лога сервисных заявок

eq_id	ev_id	ev_date	ev_type	criticality	fault_code	desc
EEG_001	1	2021-03-10	Диагностика	1	IF01	Проверка интерфейсных элементов
EEG_001	2	2021-06-15	Ремонт	2	CT02	Замена платы индикации
EEG_001	3	2021-11-20	Отказ	3	PS03	Отказ блока питания
EEG_002	1	2021-01-25	Ремонт	1	MC01	Ремонт механического держателя электродов
EEG_002	2	2021-09-05	Диагностика	2	CT01	Диагностика платы управления

Для повышения воспроизводимости использовался фиксированный словарь соответствий. Дополнительно каждому событию присваивался уровень критичности по трехбалльной шкале в соответствии с типом затронутого функционального узла: 1 – воздействия на механические компоненты и интерфейсные элементы; 2 – воздействия на платы управления и индикации; 3 – воздействия на аналоговый тракт, источник питания и контроллеры обработки сигнала. Соответствие между типами неисправностей и

уровнями критичности фиксировалось в виде справочной таблицы до начала эксперимента.

Для каждой единицы оборудования формировались временные срезы по точкам истории: каждое событие, начиная со второго, порождало одно наблюдение в обучающей выборке. Признаки формировались исключительно по событиям, предшествующим дате среза (дата среза – дата данного события), что исключает утечку информации из будущего (рис. 2).




Рис. 2. Алгоритм нормализации событийных данных

Сформированные признаки разделены на две группы: агрегированные по временным окнам 30, 90 и 180 дней до даты среза (число событий каждого типа; максимальная и средняя критичность; число уникальных типов неисправностей; интенсивность событий) и исторические признаки по всей предшествующей истории. Выделены исторические признаки по всей предшествующей истории: средний и минимальный интервал между событиями; число повторов с коротким интервалом (менее 90 дней); изменение интервала между последними событиями; время между последними двумя событиями; среднее и максимальное время восстановления; число ремонтов в год; число уникальных типов неисправностей; максимальная критичность; число гарантийных ремонтов; наличие и число полных замен прибора. Итоговое признаковое пространство включало 43 признака.

В качестве целевой переменной использовалась бинарная метка, отражающая наступление значимого эксплуатационного события в течение 90 дней после даты среза. Горизонт 90 дней выбран исходя из типичных интервалов планового технического обслуживания и горизонта принятия решений по закупке запасных частей для медицинского оборудования. Такой горизонт позволяет использовать модель в качестве инструмента поддержки краткосрочного планирования сервиса. К значимым событиям относились отказы и ремонтные воздействия, влияющие на работоспособность оборудования. Диагностические и вспомогательные операции

не учитывались как целевые события. Доля положительного класса составила 14%. Дополнительно формировались метки для горизонтов 30 и 180 дней (рис. 3).

Разбиение на обучающую и тестовую выборки выполнялось по объектам: все наблюдения одного прибора относились либо только к обучающей, либо только к тестовой выборке. Это исключает утечку информации об индивидуальных характеристиках прибора между выборками. Тестовая выборка составила 30 % от общего числа приборов.

Обучались две модели: логистическая регрессия с балансировкой классов и градиентный бустинг XGBoost. Перед подачей в логистическую регрессию признаки стандартизировались (рис. 4).

В качестве базовой модели для решения задачи бинарной классификации была использована логистическая регрессия с L2-регуляризацией и автоматическим взвешиванием классов (`class_weight='balanced'`, `C=0,1`). Такой выбор обусловлен, во-первых, интерпретируемостью модели, позволяющей анализировать вклад отдельных признаков в логарифм отношения шансов отказа, что важно в контексте медицинской техники. Во-вторых, логистическая регрессия является стандартной отправной точкой для оценки наличия предиктивного сигнала в данных: при умеренном числе признаков и относительно небольшом числе объектов она обеспечивает устойчивые оценки и позволяет выявить, достаточно ли информативно сформировано признаковое пространство.




Рис. 3. Структура признакового пространства и целевых переменных модели прогнозирования отказов




Рис. 4. Алгоритм валидации прогнозного метода на основе дискретных данных

Использование параметра `class_weight='balanced'` компенсирует дисбаланс классов (доля отказов около 14 %) за счет автоматического увеличения вклада миноритарного класса в функцию потерь, а значение `C = 0,1` задает умеренно сильную регуляризацию, снижающую риск переобучения на скоррелированных интервальных и агрегированных признаках.

В качестве основной нелинейной модели использован градиентный бустинг деревьев решений XGBoost с параметрами `n_estimators=50`, `max_depth=3`, `learning_rate=0,1`, `scale_pos_weight`, пропорциональными отношению числа объектов отрицательного и положительного классов. Такая конфигурация отражает компромисс между модельной сложностью и обобщающей способностью: неглубокие деревья и ограниченное количество итераций бустинга позволяют улавливать существенные нелинейные взаимодействия признаков (например, сочетание частоты событий и интервалов между ними) при контролируемом уровне переобучения. Параметр `scale_pos_weight` реализует для XGBoost механизм учета дисбаланса классов, аналогичный использованию весов в логистической регрессии, что особенно важно при относительно малой доле отказов. Экспериментальные результаты показали существенное превосходство XGBoost по метрике ROC-AUC по сравнению с логистической регрессией, что свидетельствует о значимом нелинейном характере зависимостей в сформированном признаковом пространстве и тем самым обосновывает выбор данной модели в качестве основной для построения прогностических оценок.

Основной метрикой качества выбрана ROC-AUC как устойчивая к дисбалансу классов. Для получения устойчивой оценки применялась стратифицированная кросс-валидация по объектам (5 фолдов). Интерпретация модели выполнена методом SHAP с использованием TreeExplainer [16].

Результаты исследования. Результаты оценки моделей методом стратифицированной кросс-валидации по объектам представлены в табл. 2.

Таблица 2. Результаты кросс-валидации (5 фолдов, разбиение по объектам)

Модель	ROC-AUC (среднее отклонение)	ROC-AUC (стандартное отклонение)
Логистическая регрессия	0,60	±0,19
XGBoost	0,82	±0,13

Модель XGBoost продемонстрировала отклонение ROC-AUC = 0,82, что соответствует хорошему уровню разделяющей способности для задач бинарной классификации с дисбалансом классов. Логистическая регрессия показала отклонение ROC-AUC = 0,60, что подтверждает наличие предиктивного сигнала в данных и указывает на нелинейный характер зависимостей. Стандартное отклонение ±0,13 для XGBoost свидетельствует об умеренной устойчивости результата при ограниченном объеме выборки.

Анализ значимости признаков методом SHAP выявил, что наибольший вклад в прогноз вносят признаки, связанные с временной структурой событий эксплуатации. К числу наиболее значимых относятся:

- интервал между последними событиями;
- средние и минимальные интервалы между событиями;
- частота и интенсивность ремонтных воздействий;
- характеристики восстановления (время простоя).

Таким образом, временная структура последовательности событий выступает основным носителем предиктивной информации в рамках предложенного подхода.

Анализ зависимости SHAP-значений признака «время между последними двумя событиями» от его числового значения выявил пороговый характер влияния: при значениях менее ≈ 281 дня наблюдается выраженный рост вклада признака в прогноз отказа. Обнаруженный пороговый характер влияния интервального признака фактически отражает изменение условной интенсивности отказов по мере сокращения интервала между событиями, что согласуется с представлениями теории надежности о росте риска при увеличении частоты отказов и ремонтов. Данный порог рассматривается как индикатор повышения вероятности отказа при сокращении интервалов между событиями.

Использование SHAP обеспечивает адаптивную композицию вклада признаков в пространство логитов модели XGBoost, что позволяет интерпретировать вклад каждого признака как вклад в логарифм отношения шансов отказа.

В ходе анализа выявлен ряд нелинейных зависимостей. Признак «возраст прибора» показывает отрицательную корреляцию с прогнозируемым риском: более молодые приборы ассоциированы с более высоким риском отказа. Данный эффект может отражать повышенную интенсивность отказов на начальном этапе эксплуатации, что согласуется с известными закономерностями теории надежности.

Признак «максимальное время восстановления» показывает отрицательную зависимость: длительный простой в прошлом ассоциирован со сниженным краткосрочным риском, возможно вследствие более полного восстановления при продолжительном ремонтном воздействии. Признак «число уникальных типов неисправностей за всю историю» при высоких значениях также показывает отрицательную зависимость с риском, что может быть связано с более широким спектром ранее выполненных ремонтных воздействий.

Выводы. Предложенный и апробированный метод прогнозирования отказов медицинского оборудования на основе дискретных событийных данных эксплуатации без использования телеметрии, основанный на формировании признакового пространства из временных последовательностей событий сервисного обслуживания с агрегацией по скользящим временным окнам и последующем построении интерпретируемых моделей машинного обучения, включает два взаимосвязанных этапа. Первый этап – формирование информативного признакового пространства (43 признака) путем агрегации событийных последовательностей по скользящим временным окнам и извлечения интервальных характеристик сервисной истории – представляет собой ключевой методический вклад, обеспечивающий преобразование нерегулярных записей сервисных журналов в структуру, пригодную для применения методов

машинного обучения. Второй этап – построение и валидация прогностической модели на основе сформированных признаков. Верификация на реальных данных эксплуатации электроэнцефалографического оборудования показала, что сформированное признаковое пространство содержит предиктивный сигнал, достаточный для достижения ROC-AUC = 0,82 при кросс-валидации по объектам: временная структура событийной последовательности несет извлекаемую информацию о техническом состоянии оборудования, недоступную классическим агрегированным моделям надежности.

Ключевым наблюдением является доминирующая роль интервальных признаков в прогнозе. Сокращение интервалов между последовательными событиями ремонта рассматривается как индикатор накопления эксплуатационных нарушений. Данная интерпретация согласуется с общими представлениями о динамике деградации технических систем, в которых рост частоты событий часто предшествует критическому выходу из строя [17, 18].

Предложенный метод принципиально отличается от телеметрических подходов по типу используемых данных: вместо непрерывных сигналов датчиков используются записи стандартных процессов сервисного обслуживания. По сравнению с методами анализа выживаемости [8], предложенный подход учитывает динамику изменений в событийной последовательности, обеспечивая прогноз на заданных горизонтах [7, 11]. Наиболее близким по постановке является направление log-based PdM [12, 13], однако существующие исследования преимущественно ориентированы на промышленное оборудование с высокой частотой событий [15].

Валидация на реальных данных эксплуатации электроэнцефалографического оборудования показала, что модель градиентного бустинга достигает ROC-AUC = 0,82 при кросс-валидации по объектам на горизонте прогнозирования 90 дней. Анализ значимости признаков методом SHAP показал, что основным носителем предиктивной информации является временная структура событийной последовательности – прежде всего, интервалы между последовательными событиями. Сокращение данных интервалов рассматривается как индикатор повышения вероятности отказа.

Выборка ограничена данными одного производителя и одного класса оборудования; обобщаемость результатов требует дополнительной валидации. В данных отсутствует информация о фактической нагрузке оборудования. Тестовая выборка содержит ограниченное число положительных примеров, что снижает устойчивость оценки на hold-out выборке, кросс-валидация по объектам принята в качестве основной метрики. Кроме того, качество результа-

тов зависит от согласованности и полноты ведения эксплуатационных журналов, что может варьироваться между организациями.

Предложенный подход не требует модификации оборудования, установки дополнительных датчиков или создания телеметрической инфраструктуры, что определяет его применимость к оборудованию, эксплуатируемому без средств непрерывного мониторинга.

Перспективными направлениями являются: валидация на расширенном датасете; включение признаков нагрузки оборудования; адаптация к другим классам медицинской техники; разработка прикладных регламентов принятия решений на основе прогнозных оценок. Полученные прогнозные оценки могут использоваться для ранжирования парка оборудования по уровню отказа в ближайшие 90 дней и формирования приоритетного списка объектов для внепланового или усиленного обслуживания. Это позволяет интегрировать модель в процедуры планирования профилактических работ и управления запасами комплектующих, не изменяя существующую инфраструктуру.

Список литературы

1. **A review** on vibration-based condition monitoring of rotating machinery / M. Tiboni, C. Remino, R. Bussola, C. Amici // *Applied Sciences*. – 2022. – Vol. 12, No. 3. – P. 972. DOI: 10.3390/app12030972.
2. **Applications** of machine learning to machine fault diagnosis: A review and roadmap / Y. Lei, B. Yang, X. Jiang, et al. // *Mechanical Systems and Signal Processing*. – 2020. – Vol. 138. – P. 106587. DOI: 10.1016/j.ymssp.2019.106587.
3. **Махмуд Р.** Обзор предиктивного обслуживания: его характеристики, методы и перспективы развития // *Политехнический молодежный журнал*. – 2025. – № 3(98). URL: <https://ptsj.bmstu.ru/catalog/icec/auto/1043.html> (дата обращения: 27.04.2026).
4. **Рукомин М.А.** Современные подходы прогнозирования отказов // *Вестник науки*. – 2025. – № 8(89). URL: <https://cyberleninka.ru/article/n/sovremennye-podhody-prognozirovaniya-otkazov> (дата обращения: 27.04.2026).
5. **Predictive** maintenance enabled by machine learning: Use cases and challenges in the automotive industry / A. Theissler, J. Pérez-Velázquez, M. Ketelgerdes, G. Elger // *Reliability Engineering & System Safety*. – 2021. – Vol. 215. – P. 107864. DOI: 10.1016/j.ress.2021.107864.
6. **A systematic** mapping of the advancing use of machine learning techniques for predictive maintenance / M. Nacchia, F. Fruggiero, A. Lambiase, K. Bruton // *Applied Sciences*. – 2021. – Vol. 11, No. 6. – P. 2546. DOI: 10.3390/app11062546.
7. **Hrnjica B., Softic S.** The survival analysis for a predictive maintenance in manufacturing // *IFIP Advances in Information and Communication Technology*. – 2021. – Vol. 632. – P. 78–85. DOI: 10.1007/978-3-030-85906-0_9.
8. **Cox D.R.** Regression models and life-tables // *Journal of the Royal Statistical Society. Series B*. – 1972. – Vol. 34, No. 2. – P. 187–220. DOI: 10.1111/j.2517-6161.1972.tb00899.x.
9. **Шумак К.Д.** Математические методы прогнозирования отказов медицинского оборудования // *Научное обозрение. Технические науки*. – 2017. – № 1. – С. 99–101. URL: <https://s.science-engineering.ru/pdf/2017/1/1153.pdf> (дата обращения: 27.04.2026).
10. **Machine learning** for predictive maintenance: A multiple classifier approach / G.A. Susto, A. Schirru, S. Pampuri, et al. // *IEEE Transactions on Industrial Informatics*. – 2015. – Vol. 11, No. 3. – P. 812–820. DOI: 10.1109/TII.2014.2349359.
11. **Esteban L., Martínez L., Navarro M.** Data mining in predictive maintenance systems: A taxonomy and systematic review // *WIREs Data Mining and Knowledge Discovery*. – 2022. – Vol. 12, No. 4. – e1471. DOI: 10.1002/widm.1471.
12. **Van der Aalst W.M.P.** *Process Mining: Data Science in Action*. – 2nd ed. – Berlin: Springer, 2016. – 467 p. DOI: 10.1007/978-3-662-49851-4.
13. **Event abstraction** in process mining: literature review and taxonomy / S. Van Zelst, F. Mannhardt, M. de Leoni, A. Koschmider // *Granular Computing*. – 2021. – Vol. 6, No. 3. – P. 719–736. DOI: 10.1007/s41066-020-00226-2.
14. **Zamzam A.H., Hasikin K., Wahab A.K.A.** Integrated failure analysis using machine learning predictive system for smart management of medical equipment maintenance // *Engineering Applications of Artificial Intelligence*. – 2023. – Vol. 125. – P. 106715. DOI: 10.1016/j.engappai.2023.106715.
15. **Liao H., Cade W., Behdad S.** Machine learning to predict medical devices repair and maintenance needs // *Journal of Manufacturing Science and Engineering*. – 2022. – Vol. 144, No. 3. – P. 031007. DOI: 10.1115/1.4052398.
16. **Lundberg S.M., Lee S.-I.** A unified approach to interpreting model predictions // *Proceedings of the 31st International Conference on Neural Information Processing Systems*. – 2017. – P. 4765–4774.
17. **Jardine A.K.S., Lin D., Banjevic D.** A review on machinery diagnostics and prognostics implementing condition-based maintenance // *Mechanical Systems and Signal Processing*. – 2006. – Vol. 20, No. 7. – P. 1483–1510. DOI: 10.1016/j.ymssp.2005.09.012.
18. **Peng Y., Dong M., Zuo M.J.** Current status of machine prognostics in condition-based maintenance: a review // *The International Journal of Advanced Manufacturing Technology*. – 2010. – Vol. 50, No. 1–4. – P. 297–313. DOI: 10.1007/s00170-009-2482-0.

References

1. Tiboni, M., Remino, C., Bussola, R., Amici, C. A review on vibration-based condition monitoring of rotating machinery. *Applied Sciences*, 2022, vol. 12, no. 3, p. 972. DOI: 10.3390/app12030972.
2. Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N., Nandi, A.K. Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mechanical Systems and Signal Processing*, 2020, vol. 138, p. 106587. DOI: 10.1016/j.ymssp.2019.106587.
3. Mahmoud, R. *Politekhnicheskij molodezhnyy zhurnal*, 2025, no. 3 (98). URL: <https://ptsj.bmstu.ru/articles/1043/eng/1043.pdf>.
4. Rukomin, M.A. *Vestnik nauki*, 2025, no. 8(89). URL: <https://cyberleninka.ru/article/n/sovremennye-podhody-prognozirovaniya-otkazov.pdf>.

5. Theissler, A., Pérez-Velázquez, J., Ketelgerdes, M., Elger, G. Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry. *Reliability Engineering & System Safety*, 2021, vol. 215, p. 107864. DOI: 10.1016/j.ress.2021.107864.
6. Nacchia, M., Fruggiero, F., Lambiase, A., Bruton, K. A systematic mapping of the advancing use of machine learning techniques for predictive maintenance. *Applied Sciences*, 2021, vol. 11, no. 6, p. 2546. DOI: 10.3390/app11062546.
7. Hrnjica, B., Softic, S. The survival analysis for a predictive maintenance in manufacturing. *IFIP Advances in Information and Communication Technology*, 2021, vol. 632, pp. 78–85. DOI: 10.1007/978-3-030-85906-0_9.
8. Cox, D.R. Regression models and life-tables. *Journal of the Royal Statistical Society. Series B*, 1972, vol. 34, no. 2, pp. 187–220. DOI: 10.1111/j.2517-6161.1972.tb00899.x.
9. Shumak, K.D. *Nauchnoe obozrenie. Tekhnicheskije nauki*, 2017, no. 1, pp. 99–101. URL: <https://science-engineering.ru/pdf/2017/1/1153.pdf>.
10. Susto, G.A., Schirru, A., Pampuri, S., McLoone, S., Beghi, A. Machine learning for predictive maintenance: A multiple classifier approach. *IEEE Transactions on Industrial Informatics*, 2015, vol. 11, no. 3, pp. 812–820. DOI: 10.1109/TII.2014.2349359.
11. Esteban, L., Martínez, L., Navarro, M. Data mining in predictive maintenance systems: A taxonomy and systematic review. *WIREs Data Mining and Knowledge Discovery*, 2022, vol. 12, no. 4, e1471. DOI: 10.1002/widm.1471.
12. Van der Aalst, W.M.P. *Process Mining: Data Science in Action*. Berlin: Springer, 2016. 467 p. DOI: 10.1007/978-3-662-49851-4.
13. Van Zelst, S., Mannhardt, F., de Leoni, M., Koschmider, A. Event abstraction in process mining: literature review and taxonomy. *Granular Computing*, 2021, vol. 6, no. 3, pp. 719–736. DOI: 10.1007/s41066-020-00226-2.
14. Zamzam, A.H., Abdul Wahab, A.K., Abidin, I.Z. Integrated failure analysis using machine learning predictive system for smart management of medical equipment maintenance. *Engineering Applications of Artificial Intelligence*, 2023, vol. 125, p. 106715. DOI: 10.1016/j.engappai.2023.106715.
15. Liao, H., Cade, W., Behdad, S. Machine learning to predict medical devices repair and maintenance needs. *Journal of Manufacturing Science and Engineering*, 2022, vol. 144, no. 3, p. 031007. DOI: 10.1115/1.4052398.
16. Lundberg, S.M., Lee, S.-I. A unified approach to interpreting model predictions. *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 2017, pp. 4765–4774.
17. Jardine, A.K.S., Lin, D., Banjevic, D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 2006, vol. 20, no. 7, pp. 1483–1510. DOI: 10.1016/j.ymssp.2005.09.012.
18. Peng, Y., Dong, M., Zuo, M.J. Current status of machine prognostics in condition-based maintenance: a review. *The International Journal of Advanced Manufacturing Technology*, 2010, vol. 50, no. 1–4, pp. 297–313. DOI: 10.1007/s00170-009-2482-0.