

УДК 658.562

Юрий Нурғалиевич Кожубаев

Санкт-Петербургский политехнический университет Петра Великого, доцент кафедры электроэнергетики и электромеханики, кандидат технических наук, Россия, Санкт-Петербург, e-mail: kozhubaev_yun@spbstu.ru

Роман Викторович Ершов

АО «Воркутауголь», заместитель генерального директора, Россия, Воркута, e-mail: Um-urii@rambler.ru

Артем Алексеевич Милицын

Санкт-Петербургский политехнический университет Петра Великого, студент, Россия, Санкт-Петербург, e-mail: militsyn.aa@edu.spbstu.ru

Арсен Рустемович Ахметов

Санкт-Петербургский политехнический университет Петра Великого, студент, Россия, Санкт-Петербург, e-mail: akhmetovarsen24@gmail.com

Илья Андреевич Петров

Санкт-Петербургский политехнический университет Петра Великого, студент, Россия, Санкт-Петербург, e-mail: iljapetrov111@mail.ru

Управление и автоматизированный мониторинг электромеханических систем ленточных конвейеров

Авторское резюме

Состояние вопроса. В настоящее время внедрение систем предиктивного обслуживания (Predictive Maintenance) промышленного оборудования, в частности ленточных конвейеров, сдерживается сложностью технической реализации и необходимостью адаптации решений под конкретные технологические процессы. Существующие методы часто требуют глубоких знаний в области вибродиагностики или значительных вычислительных мощностей. Актуальность исследования обусловлена необходимостью разработки доступных и эффективных инструментов мониторинга, способных выявлять неисправности оборудования (разрыв петель, провисание цепи) на ранних стадиях без остановки производства. Целью исследования является разработка и апробация системы прогностического обслуживания изогнутой конвейерной ленты, основанной на концепции цифрового двойника и методах машинного обучения.

Материалы и методы. Экспериментальные исследования проведены на лабораторной установке, оснащенной комплексом датчиков (акселерометры, микрофоны, датчики тока). Сбор данных осуществлен с высокой частотой дискретизации (51,2 кГц) с последующей понижающей передискретизацией до 10 кГц методом линейной интерполяции в целях оптимизации вычислительных затрат. Сравнительный анализ данных и классификация состояний («норма», «неисправность») осуществлены с использованием алгоритмов машинного обучения: случайный лес (Random Forest), логистическая регрессия, метод опорных векторов (SVM) и деревья решений. Обучение и тестирование моделей проведено на комбинированном наборе данных с разделением в пропорции 80/20 %.

Результаты. Сравнительный анализ показал, что наилучшую эффективность демонстрирует алгоритм «Случайный лес» с показателем AUC 0,87 и F1-оценкой 0,88. Установлено, что понижение частоты дискретизации до 10 кГц является оптимальным компромиссом, позволяющим сократить время обработки одной минуты записи с 241 с до 56 с при сохранении диагностической ценности сигнала. Разработанная модель успешно идентифицирует различные типы неисправностей, обеспечивая высокую точность прогнозирования (до 98 % на отдельных тестовых выборках).

Выводы. Результаты исследования подтверждают эффективность применения подхода на основе цифрового двойника и машинного обучения для диагностики электромеханических систем конвейеров. Достигнутая точность и быстродействие системы позволяют рекомендовать предложенное решение для внедрения в реальные производственные процессы. Использование разработанной методики позволяет перейти от планового ремонта к обслуживанию по состоянию, минимизируя время простоев и снижая эксплуатационные расходы без необходимости привлечения узкопрофильных специалистов по вибродиагностике.

Ключевые слова: ленточный конвейер, предиктивное обслуживание, машинное обучение, цифровой двойник, диагностика неисправностей

Yuri Nurgalievich Kozhubaev

Peter the Great St. Petersburg Polytechnic University, Candidate of Engineering Sciences, (PhD), Associate Professor of Electrical Power Engineering and Electromechanics Department, Russia, Saint-Petersburg, e-mail: kozhubaev_yun@spbstu.ru

Roman Viktorovich Ershov

JSC "Vorkutaugol", Deputy General Director, Russia, Vorkuta, e-mail: Um-urii@rambler.ru

Artem Alekseevich Militsyn

Peter the Great St. Petersburg Polytechnic University, Student, Russia, Saint-Petersburg, e-mail: militsyn.aa@edu.spbstu.ru

Arsen Rustemovich Akhmetov

Peter the Great St. Petersburg Polytechnic University, Student, Russia, Saint-Petersburg, e-mail: akhmetovarsen24@gmail.com

Ilya Andreevich Petrov

Peter the Great St. Petersburg Polytechnic University, Student, Russia, Saint-Petersburg, e-mail: iljapetrov111@mail.ru

Control and automated monitoring of electromechanical belt conveyor systems

Abstract

Background. Current implementation of predictive maintenance systems for industrial equipment, particularly belt conveyor systems, is hindered by technical complexity and the necessity to adapt solutions to specific technological processes. Existing methods often require profound knowledge in the field of vibration diagnostics or substantial computational resources. The relevance of this research is justified by the urgent need to develop accessible and efficient monitoring tools capable to detect faults (loop breakage, chain sagging) at early stages without production shutdown. The aim of this study is to develop and validate a predictive maintenance system for curved belt conveyors based on the concept of a digital twin and machine learning methods.

Materials and methods. Experimental investigations have been conducted on a laboratory test rig equipped with a comprehensive sensor array (accelerometers, microphones, current sensors). Data acquisition has been performed at high sampling frequency (51,2 kHz), followed by down sampling to 10 kHz using linear interpolation to optimize computational costs. For data analysis and condition classification ("normal" vs. "fault"), four machine learning algorithms have been implemented and compared. They are Random Forest, logistic regression, support vector machines (SVM), and decision trees. Model training and testing have been performed on a combined dataset with 80/20 train-test split ratio.

Results. Comparative analysis has demonstrated that the Random Forest algorithm exhibits superior performance with an AUC of 0,87 and F1-score of 0,88. It has been established that reducing the sampling frequency to 10 kHz represents an optimal trade-off, reducing the processing time for one minute of recorded data from 241 s to 56 s while preserving signal diagnostic value. The developed model successfully identifies various fault types, achieving high prediction accuracy (up to 98 % on selected test sets).

Conclusions. The research results confirm the effectiveness of applying a digital twin approach combined with machine learning methods to diagnose electromechanical conveyor systems. The achieved accuracy and response time of the system allow us to recommend the proposed solution for implementation in real-world production processes. Application of the developed methodology enables transition from scheduled maintenance to condition-based maintenance, minimizing downtime and reducing operational costs without requiring specialized vibration diagnostics experts.

Key words: belt conveyor, predictive maintenance, machine learning, digital twin, fault diagnosis

DOI: 10.17588/2072-2672.2026.3.077-088

Введение. В последние годы все больший практический интерес приобретает методология прогнозирования и управления состоянием оборудования, которая использует различные виды собранной информации в целях обнаружения аномалий номинального поведения оборудования, определения его остаточного срока службы и прогнозирования его остаточного срока службы. В этих условиях использование нового подхода к обслуживанию промышленного оборудования, называемого прогностическим обслуживанием, основанным на использовании данных мониторинга, математических моделей и экспертных знаний, позволяет планировать операции по обслуживанию с учетом характеристик технологического процесса и текущего состояния оборудования [1–3].

По сравнению с другими подходами к техническому обслуживанию, прогностическое

обслуживание может быть намного более эффективным и действенным, поскольку позволяет планировать техническое обслуживание в оптимальные моменты времени, исключая как преждевременные вмешательства, так и запаздывающие, приводящие к повреждению оборудования и длительным простоям. Несмотря на очевидные преимущества, прогностическое обслуживание до сих пор не стало массовой практикой в промышленности. Основными барьерами для его внедрения являются сложности, связанные с технической реализацией [4–6].

В настоящем исследовании особое внимание уделяется трем ключевым аспектам:

- 1) выбору оптимальной модели для прогнозирования;
- 2) балансировке между точностью модели, ее надежностью и требованиями к вычислительным ресурсам;

3) обеспечению актуальности модели за счет постоянного обновления на основе данных, полученных с физических объектов.

Стоит подчеркнуть, что, несмотря на растущую популярность прогностического обслуживания, примеры его успешного применения в реальных производственных условиях остаются единичными. Это объясняется тем, что решения в сфере прогностического обслуживания требуют их индивидуальной адаптации к каждому конкретному случаю и сильно зависят от специфики технологического процесса.

В этой связи некоторые исследователи отмечают, что необходимо изучить потенциал использования такого подхода, особенно в отношении качества данных и выбора правильного алгоритма прогнозирования [7–9].

Ниже предлагается решение указанной проблемы с использованием прогностического подхода к обслуживанию конвейерной ленты. Это решение основано на точном цифровом двойнике, т. е. цифровой копии физического объекта, с которым он постоянно синхронизируется. Требования к системе, включая функциональные и технические аспекты, изложены в техническом задании. Реализация программной части цифрового двойника и обучаемой модели прогностического обслуживания подробно представлена в [10–12].

Исследование проведено на примере упаковочного производства, где изогнутая конвейерная лента используется для автоматизации процесса реализации и наполнения пластиковых пакетов. Задача – ограничить возникновение различных типов неисправностей во время работы изогнутой конвейерной ленты и, по возможности, избежать их, чтобы не допустить остановки производства для их устранения, что приводит к высоким затратам. Неисправности бывают двух типов: разрыв петель, соединяющих ленту с цепью, и провисание самой цепи, что может вызвать нежелательное ее поведение во время процесса [13–15].

Методы исследования. Значительным шагом к реализации подхода прогностического обслуживания является определение модели прогнозирования. Основные подходы прогностического обслуживания, представленные в литературе, можно разделить на три типа.

Первый подход основан на использовании методов анализа данных для построения моделей, способных прогнозировать состояние компонентов системы. Основные преимущества данного подхода заключаются в том, что он не требует глубоких знаний физики процесса и обладает сравнительно низкими вычислительными затратами после завершения обучения модели. Однако у этого метода есть и ограничения: он требует наличия значительного объема исторических данных для обучения и нуждается в обновлении модели при изменении

условий эксплуатации. На практике данный подход демонстрирует хорошие результаты при решении задач прогнозирования износа оборудования и увеличения времени между отказами. Кроме того, перспективным направлением является применение методов глубокого обучения для оценки остаточного ресурса вращающихся элементов на основе анализа вибрационных характеристик [16–18].

Второй подход, известный как подход на основе физических моделей, предполагает построение математических моделей, описывающих физические процессы функционирования и деградации системы. Для определения технического состояния оборудования и прогнозирования возможных отказов используются методы математического и статистического анализа. В отличие от моделей, ориентированных на данные, физические модели требуют более глубокого понимания исследуемых процессов и характеризуются большей вычислительной сложностью. Вместе с тем они менее зависимы от объема обучающих данных и позволяют оценивать параметры системы, которые невозможно измерить напрямую. Данный подход успешно применяется для анализа вибрационных характеристик в задачах прогнозирования состояния оборудования.

Третье направление, называемое гибридным, сочетает физико-математические модели и экспертные знания с методами анализа данных. Такие решения способны обеспечивать более точные прогнозы, однако их разработка требует интеграции различных типов моделей. Гибридные подходы часто используют концепцию цифрового двойника, который объединяет алгоритмы анализа данных с физическими моделями деградации, что позволяет учитывать разнообразные аспекты функционирования оборудования.

На основе этих подходов в научной литературе предложены различные решения для внедрения прогностического обслуживания конвейерных лент. Одно из таких решений предполагает разработку системы прогнозирующего обслуживания для двигателя конвейерной ленты с использованием интеллектуальных датчиков вибрации и программируемых логических контроллеров. Основная задача такой системы – предотвращать превышение допустимых уровней вибрации путем создания программы технического обслуживания, учитывающей как текущее состояние оборудования, так и прогнозируемое развитие деградационных процессов.

Данная система включает механизм непрерывного анализа состояния в реальном времени с автоматическим переходом в безопасный режим при обнаружении аномалий. При этом рассчитывается степень отклонения от нормальных рабочих параметров. Хотя данный подход демонстрирует хорошие результаты, он использует предварительно обработанные дан-

ные, в отличие от предлагаемого решения, работающего непосредственно с «сырыми» показаниями датчиков.

Анализ проблем конвейерных лент показывает, что основные неисправности обычно связаны с вибрационными явлениями, которые могут вызывать серьезные нарушения производственного процесса. Основными причинами вибрации являются:

- деформации ленты и колебания скорости движения;
- проблемы монтажа и сборки;
- провисание приводной цепи;
- разрывы соединений между цепью и лентой.

Хотя существующие решения обеспечивают хорошее понимание процессов износа и приемлемую точность прогнозирования, они требуют глубоких специальных знаний о природе вибрационных процессов в конвейерных системах, а также сложной процедуры разработки и верификации математических моделей. Предлагаемый подход направлен на снижение этих требований. Хотя базовое понимание процессов все же необходимо, система не требует детального знания вибрационных характеристик, так как используемая модель автоматически преобразует данные датчиков в полезную диагностическую информацию.

Современные подходы к прогностическому обслуживанию достигают максимальной эффективности при условии постоянной синхронизации физических и цифровых моделей с реальными производственными процессами. В этом контексте особый интерес представляет технология цифровых двойников, обеспечивающая актуальность виртуальной копии оборудования за счет непрерывного обновления данных о состоянии физического объекта. Применение цифровых двойников в системах прогностического обслуживания позволяет значительно повысить качество мониторинга и прогнозирования:

- за счет расширения возможностей анализа текущего состояния оборудования;
- повышения точности прогнозных моделей;
- обеспечения информационной поддержки для планирования процессов обслуживания оборудования.

Совместное использование физического оборудования и его цифрового двойника создает принципиально новые возможности [19–21] для оптимизации процессов технического обслуживания, существенно повышая точность прогнозов и общую эффективность системы прогностического обслуживания.

Однако внедрение DT-технологий сопряжено с рядом вызовов [22–24]:

- 1) сложностями сбора и обработки данных в реальном времени;

- 2) проблемами разработки адекватных цифровых моделей;

- 3) высокими требованиями к вычислительным ресурсам;

- 4) ограниченным количеством успешных кейсов промышленного внедрения;

- 5) отсутствием универсальных решений для различных типов оборудования.

Анализ существующих разработок показывает, что на текущем этапе отсутствуют комплексные решения, полностью соответствующие требованиям мониторинга конвейерных лент [25–27]. В связи с этим в рамках данного исследования предлагается:

- специально разработанная модель машинного обучения;
- система непрерывного мониторинга параметров работы;
- алгоритмы формирования оптимальных графиков обслуживания.

Предлагаемый подход направлен на создание максимально эффективной системы прогностического обслуживания конвейерного оборудования с учетом специфики его эксплуатации.

Результаты исследования. Методология прогнозирования и управления состоянием оборудования. Традиционная методология прогнозирования и управления состоянием оборудования предполагает последовательное выполнение трех ключевых этапов при внедрении системы прогностического обслуживания конвейерных лент:

1. *Этап мониторинга и сбора данных.* На данном этапе осуществляется сбор необходимых параметров работы оборудования через систему специализированных датчиков и измерительных приборов. Собранные данные проходят предварительную обработку, включающую: очистку от шумов и артефактов; нормализацию значений; приведение к единому временному формату.

Такая подготовка данных обеспечивает их пригодность для последующего анализа.

2. *Этап диагностики и анализа.* На этом этапе выполняется: оценка степени износа оборудования; выявление текущих и потенциальных неисправностей; анализ динамики деградационных процессов. Для реализации этих задач применяются различные методы – от статистического анализа до сложных алгоритмов машинного обучения [28–30], позволяющих прогнозировать момент выхода параметров за допустимые границы.

3. *Этап принятия решений.* Заключительная фаза предполагает: интерпретацию результатов диагностики; разработку оптимального плана обслуживания; подготовку рекомендаций для персонала.

Особое внимание уделяется наглядному представлению информации операторам и техническим специалистам с учетом принципов

человеко-машинного взаимодействия. Ниже предлагается детальная реализация каждого из этих этапов в рамках конкретного промышленного кейса.

Шаг 1. *Наблюдение за конвейером с помощью датчиков. Система мониторинга конвейерной ленты.*

Экспериментальная установка состояла из комплексной системы датчиков, установленных на раме конвейерной ленты. Конфигурация измерительной системы включала:

1) датчиковый комплекс:

- пьезоэлектрический микрофон для акустического мониторинга;
- набор одноосных и трехосных акселерометров:

ось X – вдоль направления движения ленты;

ось Y – перпендикулярно поверхности крепления;

ось Z – перпендикулярно направлению движения;

- фотоэлектрический датчик положения;
- три токовых датчика для контроля электропривода;

2) схему размещения.

Датчики были равномерно распределены в 5 контрольных точках вдоль изгиба конвейерной траектории.

Программа испытаний включала моделирование следующих режимов работы:

- нормальный режим (базовое состояние);

- искусственно созданное провисание приводной цепи (1, 2 и 5 мм);

- частичный и полный разъем соединительных элементов (от 1 до 12 петель).

Методика испытаний заключалась в следующем:

- каждое состояние (кроме нормального) поддерживалось в течение 10 мин;

- нормальный режим фиксировался более 200 мин для сбора референсных данных;

- частота дискретизации данных составляла 51,2 кГц;

- данные записывались в виде минутных сегментов объемом 588 МБ каждый.

Для хранения измерительной информации использовался специализированный формат данных. Каждый файл содержал 24 канала: 23 канала соответствовали показаниям датчиков, а один – виртуальный канал Erog – использовался для маркировки состояния системы: 0 – нормальный режим; 1 – аварийный режим.

Такая организация данных позволила четко идентифицировать различные состояния конвейерной системы и создать надежную базу для последующего анализа [31–33].

Большинство методов цифровой обработки сигналов основано на стратегии «разделяй и властвуй», называемой суперпозицией.

При обработке сигнал разделяется на простые компоненты, каждый из которых обрабатывается индивидуально, после чего полученные результаты объединяются для формирования итоговой оценки.

Современные исследования динамики конвейерных лент показывают, что максимальная частота их поперечных колебаний обычно не превышает 200 Гц. Согласно фундаментальным принципам цифровой обработки сигналов, для корректного измерения таких колебаний теоретически достаточно частоты дискретизации 400 Гц. Однако в настоящем исследовании была применена значительно более высокая частота – 51,2 кГц, что позволило получить исключительно детализированную картину вибрационных процессов.

Использование столь высокой частоты дискретизации обеспечило превосходное качество регистрации вибрационных характеристик (рис. 1 и 2), но одновременно создало серьезные вычислительные сложности. Каждый файл телеметрии достигал объема 588 МБ, что требовало специальных подходов к обработке и анализу данных.




Рис. 1. Суперпозиция, полученная в состоянии номинального режима (серый) и в режиме с одним удаленным контуром(черный)




Рис. 2. Увеличенная суперпозиция, номинальная (серая) и с удаленной петлей(черная)

На рис. 3 представлены результаты сравнения сигналов акселерометра по оси X в номинальном режиме и при наличии дефекта. Визуальный анализ показывает, что различия между режимами носят достаточно тонкий характер – наблюдаются незначительные изменения формы сигнала, распределения пиков и динамики затухания колебаний. Для более детального изучения этих различий был применен масштабированный анализ, результаты которого представлены на рис. 4.




Рис. 3. Суперпозиция номинального теста, исходного и повторно дискретизированного 10000 Гц

Увеличенные участки сигналов, представленные на рис. 4, позволяют более четко увидеть различия, особенно в диапазонах времени 0,002–0,006 с и 0,01–0,012 с. Однако стоит отметить, что аналогичный анализ других каналов измерений не выявил столь значительных изменений. Это подчеркивает необходимость комплексного подхода к диагностике состояния конвейерной ленты, который учитывает данные со всех датчиков системы.




Рис. 4. Суперпозиция исходного канала, соответствующего номинальному тесту (серый), и его повторной выборки на частоте 5000 Гц

Результаты, представленные на рис. 2 и 3, демонстрируют возможность обнаружения дефектов конвейерных лент на основе изменений их вибрационных характеристик. Тем не менее для успешного применения данного подхода в промышленных условиях требуется разработка более продвинутых алгоритмов обработки сигналов, которые смогут учитывать состояние всех элементов системы в целом. Особое внимание следует уделить созданию адаптивных методов анализа, способных выявлять незначительные изменения даже в условиях промышленных шумов и изменяющихся рабочих режимов.

Проведенный анализ выявил существенные ограничения первоначального подхода, который рассматривал лишь фрагменты сигналов в двух режимах работы, игнорируя комплексный анализ данных со всех датчиков. Основная

сложность заключалась в обработке значительных объемов телеметрии – каждый файл данных размером 588 МБ содержал информацию, записанную с частотой 51 200 Гц. Для решения этой проблемы была разработана и успешно апробирована методика понижающей передискретизации сигналов.

Применение линейной интерполяции позволило снизить частоту дискретизации до 10 000 Гц при сохранении всех ключевых характеристик сигналов. Это решение, полностью соответствующее теореме Котельникова, обеспечило почти четырехкратное уменьшение объема данных (до 151 МБ на файл) с минимальной потерей информативности. Сравнительный анализ показал, что максимальное отклонение амплитудных значений не превысило 1,196, при этом все существенные особенности сигналов, включая их форму и ключевые параметры, остались неизменными. Например, для сигнала пиковые значения изменились с исходного диапазона (–7,057...8,184) на (–5,895...6,988) после обработки.

Это открывает возможности для комплексного анализа информации со всех датчиков системы, что особенно важно для разработки надежных алгоритмов прогнозирования состояния конвейерных лент. Полученные результаты могут быть рекомендованы для внедрения в системах промышленного мониторинга, где требуется обработка значительных объемов вибродиагностических данных в реальном времени.

Таким образом, реализация предложенной архитектуры цифрового двойника позволяет обеспечить непрерывный мониторинг состояния оборудования, повысить точность прогнозирования неисправностей и сократить непредвиденные простои.

Сравнительный анализ результатов выявил существенные различия между подходами. При частоте 5 000 Гц, хотя формально соответствующей теореме Найквиста-Шеннона и обеспечивающей уменьшение объема данных до 99,5 МБ, наблюдалась значительная потеря информативности. Графическое представление демонстрирует, что передискретизированный сигнал (черная кривая) теряет характерные пики и существенно искажает структуру по сравнению с оригиналом (серая кривая). В отличие от этого, результаты передискретизации до 10000 Гц (рис. 4) показывают хорошее соответствие исходным данным при приемлемом уменьшении их объема.

На основании проведенного анализа можно сделать вывод, что частота 10 000 Гц представляет собой оптимальный компромисс между необходимостью уменьшения объема данных и сохранением их диагностической ценности. Этот вывод подтверждается визуальным сравнением графиков (рис. 4), где очевидно, что более высокая частота дискретизации лучше

сохраняет ключевые особенности сигналов, важные для последующего анализа и прогнозирования состояния оборудования. Таким образом, для дальнейших исследований была выбрана частота 10 000 Гц как обеспечивающая наилучшее соотношение между производительностью системы мониторинга и точностью получаемых результатов.

Шаг 2. Анализ телеметрических данных конвейера с использованием модели машинного обучения. На этом шаге осуществляется идентификация неисправностей во время нормального функционирования конвейерной ленты с использованием данных, собранных на шаге 1. В этой связи была разработана модель машинного обучения для мониторинга и прогнозирования состояния конвейерной ленты.

Для анализа телеметрических данных и выявления неисправностей были рассмотрены следующие методы машинного обучения:

1. **Бинарная классификация**, которая позволяет разделять данные на два predetermined класса (например, "норма" и "неисправность"). Этот подход отличается относительной простотой реализации, но ограничен в возможностях детализации состояния системы.

2. **Многоклассовая классификация**, расширяющая возможности бинарного подхода за счет введения дополнительных классов для более точной дифференциации различных состояний оборудования.

3. **Методы регрессии**, использующие зависимость между входными параметрами и целевыми переменными для прогнозирования состояния системы. Эти методы особенно полезны при работе с непрерывными параметрами.

4. **Обнаружение аномалий** – подход, основанный на определении нормального рабочего состояния системы с последующей идентификацией отклонений от этого состояния.

В ходе исследования было проведено тестирование и сравнительный анализ нескольких конкретных реализаций этих методов:

- случайный лес (для бинарной классификации);
- логистическая регрессия;
- линейный метод опорных векторов;
- деревья решений.

Результаты сравнительного анализа методов показывают, что каждый из них демонстрирует различную точность и вычислительную эффективность применительно к задаче диагностики конвейерных лент. Особый интерес представляют методы на основе рекуррентных нейронных сетей [11], которые, согласно исследованиям, показывают высокую эффективность для подобных задач, однако требуют значительных вычислительных ресурсов. Их детальное изучение планируется в рамках дальнейших исследований.

Оптимальный компромисс между точностью и вычислительной эффективностью демонстрируют метод случайного леса и линейный метод, что наглядно иллюстрирует сравнительная диаграмма на рис. 5. Однако при расширении задачи до многоклассовой классификации или прогнозирования степени износа оборудования может потребоваться применение более сложных алгоритмов, включая нейронные сети.




Рис. 5. ROC-кривые для четырех разработанных алгоритмов

Оценка и сравнение различных методов МО. Процедура разделения данных выполнялась особым образом: из каждого канала измерений и для каждого рассматриваемого случая случайным образом отбиралось 20 % записей для тестовой выборки. Этот подход гарантировал репрезентативность данных и равномерное представление всех режимов работы в тестовой выборке.

Для комплексной оценки эффективности четырех различных алгоритмов (случайный лес, логистическая регрессия и деревья решений) использовались два ключевых показателя:

1) кривые рабочих характеристик приемника, наглядно демонстрирующие соотношение долей истинно положительных и ложноположительных классификаций при различных пороговых значениях;

2) площадь под ROC-кривой – интегральный показатель качества классификации, где значение 1 соответствует идеальному алгоритму:

$$AUC = \int_0^1 TPR dx, \quad (1)$$

где TPR – метрика, которая используется для оценки эффективности моделей бинарной классификации.

Интегральная метрика AUC (1) отражает вероятность того, что модель ранжирует случайно выбранный положительный пример выше отрицательного. Для идеального классификатора $AUC = 1$, что соответствует полному разделению классов.

Результаты сравнительного анализа представлены на рис. 5. Кривые ROC для всех четырех методов построены на основе одинаковых наборов обучающих и тестовых данных, что обеспечивает корректность их сравнения. На графиках хорошо прослеживаются различия в эффективности алгоритмов – некоторые демонстрируют почти идеальную классификацию (кривая близка к верхнему левому углу), в то время как другие показывают более скромные результаты. Лучшие алгоритмы достигают значений AUC , близких к 0,9–0,95, что свидетельствует об их высокой пригодности для решения поставленной задачи диагностики. При этом важно отметить, что даже незначительные различия в AUC (например, 0,92 против 0,89) могут иметь существенное значение при промышленном внедрении системы мониторинга [34, 35].

Следует отметить, что идеальная оценка – $AUC = 1$, в то время как случайный подход (который случайным образом присваивает образцу метку 0 или 1) имеет $AUC = 0,5$. Алгоритм «Случайный лес» имеет $AUC 0,87$, давая лучшую производительность среди всех оцененных моделей. Кроме того, для более точной оценки четырех разработанных алгоритмов для каждого алгоритма были рассчитаны следующие индексы:

- оценка точности (процент правильно предсказанных случаев), которая представляет собой способность модели не маркировать отрицательный образец как положительный;
- оценка полноты (процент положительных событий, правильно предсказанных, по отношению к общему числу положительных событий), которая представляет собой способность модели находить все положительные образцы;
- оценка F1 (средневзвешенное значение точности и полноты), дающая общую оценку алгоритма.

Рассчитанные индексы для четырех алгоритмов, представленные в таблице, выявили лучшую производительность, тем самым подтвердив оценку с использованием индекса AUC .

Индекс алгоритмов

Индексы	Случайный лес	Логистическая регрессия	Метод опорных векторов	Деревья решений
Оценка точности	0,88	0,74	0,76	0,85
Оценка запоминания	0,89	0,86	0,63	0,84
F1-оценка	0,88	0,79	0,68	0,84

На основании полученных результатов для продолжения исследования был выбран алгоритм «Случайный лес».

Оценка предлагаемого решения. Экспериментальные испытания подтвердили эффективность разработанной системы мониторинга на основе цифрового двойника. Комплексная оценка включала анализ статистики прогнозов, ключевых метрик качества классификации и матриц ошибок, что позволило объективно оценить работоспособность решения.

На первом этапе тестирования модель продемонстрировала стабильную работу при обработке восьми номинальных и шести аварийных сценариев (см. рис. 5). Система корректно идентифицировала $1,40 \cdot 10^6$ нормальных режимов и $2,23 \cdot 10^5$ неисправностей, при этом допустив $8,00 \cdot 10^4$ ложных срабатываний и пропустив $1,37 \cdot 10^5$ аварийных ситуаций. Полученные метрики (точность 0,88, полнота 0,62, F1-мера 0,74) свидетельствуют о надежности системы в условиях разнородных входных данных.

Последующее углубленное тестирование на специализированном наборе данных выявило улучшение показателей до 0,83 по точности и полноте при идеальном значении F1-меры (1,00). Такой результат объясняется способностью алгоритма адаптироваться к конкретным типам неисправностей при сохранении стабильности работы.

Визуализация результатов на рис. 6 и 7 наглядно демонстрирует превосходство предложенного решения перед традиционными методами мониторинга. Особенно важно отметить устойчивость алгоритма при обработке различных сценариев, что подтверждает его готовность к промышленному внедрению.

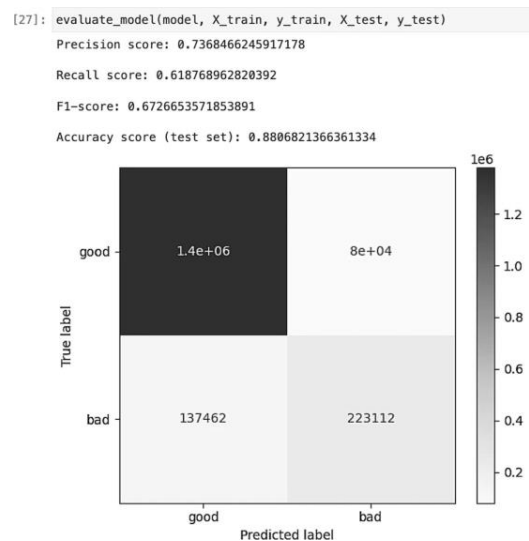


Рис. 6. Код и результаты для прогнозирования нового файла

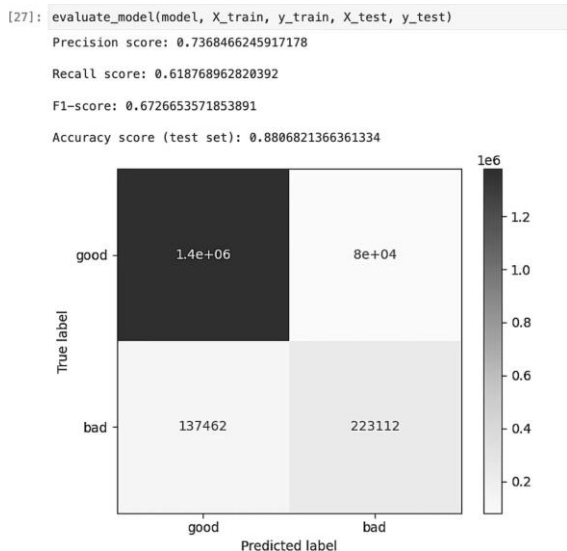


Рис. 7. Оценка результатов второго теста (входные данные: восемь номинальных файлов и шесть файлов ошибок)

Третий тест был направлен на оценку влияния понижающей передискретизации данных на качество прогнозирования. В данном случае на вход модели машинного обучения подавался файл, соответствующий номинальному режиму работы, обработанный с использованием выбранной частоты дискретизации. Результаты, представленные на рис. 8, показали высокую точность классификации – 98 %, что подтверждает возможность корректного распознавания номинального состояния после передискретизации. Полученные данные свидетельствуют о том, что снижение частоты дискретизации может приводить к некоторой потере информации, однако данный эффект является допустимым компромиссом, поскольку позволяет существенно сократить время вычислений по сравнению с обработкой исходных данных без передискретизации.

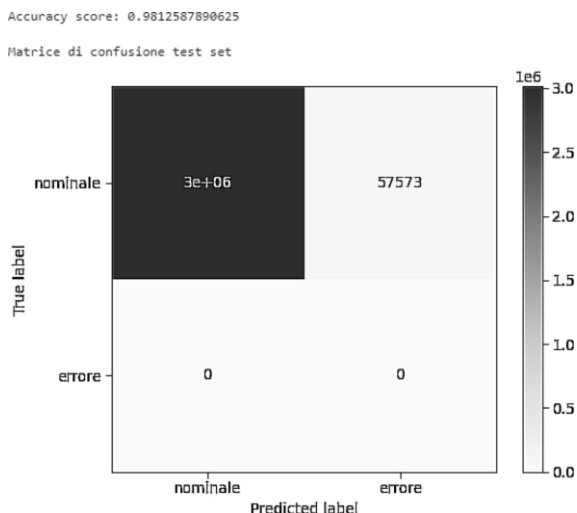


Рис. 8. Оценка результатов третьего теста (входные данные – один файл, соответствующий случаю ошибки)

Выводы. Экспериментальные испытания подтвердили эффективность разработанной системы мониторинга на основе цифрового двойника. Комплексная оценка включала анализ статистики прогнозов, ключевых метрик качества классификации и матриц ошибок, что позволило объективно оценить работоспособность решения.

Несмотря на то что результаты, полученные во всех трех тестах, могут быть дополнительно улучшены, проведенный анализ оценки показал, что эти результаты согласуются с высоким числом верных прогнозов и низким числом неверных. Это позволяет надежно различать нормальные и неисправные состояния конвейерной системы и своевременно формировать рекомендации для операторов.

Оценка вычислительных затрат показала, что использование данных, передискретизированных до 10 000 Гц, позволяет сократить время обработки одной минуты записи с 241 до 56 с по сравнению с исходными данными без передискретизации. Это дает приемлемое время отклика, что позволяет осуществлять мониторинг ленты в процессе ее нормального использования путем прогнозирования каждой минуты сбора данных с повторной выборкой или, в качестве альтернативы, 1 мин каждые 4 мин сбора данных без повторной выборки.

В рамках данного исследования была разработана и протестирована модель машинного обучения, интегрированная в решение на основе цифрового двойника, для прогнозирования неисправностей изогнутой конвейерной ленты. Полученные результаты подтвердили эффективность предложенного подхода, продемонстрировав высокую точность и надежность в идентификации неисправностей, а также приемлемое время отклика системы. Это свидетельствует о том, что предложенное решение может быть успешно применено в реальных производственных условиях для повышения эффективности процессов технического обслуживания конвейерных систем.

Список литературы

1. Errandonea I., Beltran S., Arrizabalaga S. Digital twin for maintenance: a literature review // *Comput Ind.* 2020. DOI: 10.1016/j.compind.2020.103316.
2. An experimental methodology to evaluate machine learning methods for fault diagnosis based on vibration signals / T.W. Rauber, A.L. da Silva Loca, F. de Assis Boldt, et al. // *Expert Syst App.* – 2021. – Vol. 167. – P. 114022. DOI: 10.1016/j.eswa.2020.114022.
3. Intelligent machine learning based total productive maintenance approach for achieving zero downtime in industrial machinery / T.R. Mohan, J.P. Roselyn, R.A. Uthra, K. Umachandran // *Comput. Ind. Eng.* – 2021. – Vol. 157. – P. 107267. DOI: 10.1016/j.cie.2021.107267.
4. Zhang W., Yang D., Wang H. Data-driven methods for predictive maintenance of industrial equip-

ment: a survey // *IEEE Syst J.* – 2019. – Vol. 13, No. 3. – P. 2213–2227. DOI: 10.1109/JSYST.2019.2905565.

5. **Ran Y., Lin P., Zhou X.** A survey of predictive maintenance: systems, purposes and approaches // *Electr Eng Syst Sci.* – 2019. DOI: 10.48550/arXiv.1912.07383.

6. **A digital twin approach based on nonparametric Bayesian network for complex system health monitoring / J. Yu, Y. Song, D. Tang, J. Dai // J Manuf Syst. – 2021. – Vol. 58. – P. 293–304. DOI: 10.1016/j.jmsy.2020.07.005.**

7. **Kiangala K.S., Wang Z.** Initiating predictive maintenance for a conveyor motor in a bottling plant using industry 4.0 concepts // *Int J Adv Manuf Tech.* – 2018. – Vol. 97. – P. 3251–3271. DOI: 10.1007/s00170-018-2093-8.

8. **Steenwinckel B., De Paepe D., Vanden Haute S.** Flags: a methodology for adaptive anomaly detection and root cause analysis on sensor data streams by fusing expert knowledge with machine learning // *Future Gener Comput Syst.* – 2021. – Vol. 116. – P. 30–48. DOI: 10.1016/j.future.2020.10.015.

9. **A digital twin approach based on nonparametric Bayesian network for complex system health monitoring / J. Yu, Y. Song, D. Tang, J. Dai // J Manuf Syst. 2021. T. 58. C. 293–304. DOI: 10.1016/j.jmsy.2020.07.005.**

10. **Englert T., Graichen K.** Nonlinear model predictive torque control of PMSMs for high performance applications // *Control Engineering Practice.* – 2018. – Vol. 81. – P. 43–54. DOI: 10.1016/j.conengprac.2018.08.023.

11. **Influence of an installation angle of the conveyor lift on the volumes of mining and preparing work at quarries at the cyclic-flow technology of ore mining / V.L. Yakovlev, A.V. Glebov, V.A. Bersenyov, et al. // News of the National Academy of Sciences of the Republic of Kazakhstan, Series of Geology and Technical Sciences. – 2020. – Vol. 4, No. 442. – P. 127–137. DOI: 10.32014/2020.2518-170X.93.**

12. **New low-noise sensorless control strategy for permanent magnet synchronous motor drives based on variable-frequency voltage signal injection / H. Zhu, L. Zhang, Z. Peng, et al. // IET Electr. Power Appl. – 2025. – P. e12538. DOI: 10.1049/elp2.12538.**

13. **Tiddens W., Braaksma J., Tinga T.** Exploring predictive maintenance applications in industry // *J Qual Maint Eng.* – 2022. – Vol. 28, No. 1. – P. 68–85. DOI: 10.1108/JQME-05-2020-0029.

14. **A systematic literature review of machine learning methods applied to predictive maintenance / T.P. Carvalho, F.A. Soares, R. Vita, et al. // Comput Ind Eng. – 2019. – Vol. 137. – P. 106024. DOI: 10.1016/j.cie.2019.106024.**

15. **Grieves M., Vickers J.** Digital twin: mitigating unpredictable, undesirable emergent behavior in complex systems // *Springer, Cham.* – 2017. – P. 85–113. DOI: 10.1007/978-3-319-38756-7_421.

16. **Errandonea I., Beltran S., Arrizabalaga S.** Digital twin for maintenance: a literature review // *Comput Ind.* – 2020. DOI: 10.1016/j.compind.2020.103316.

17. **A comparative study on machine learning algorithms for smart manufacturing: tool wear prediction using random forests / D. Wu, C. Jennings, J. Terpenney, et al. // J Manuf Sci Eng. – 2017. – Vol. 139, No. 7. DOI: 10.1115/1.4036350.**

18. **Beloglazov I., Plaschinsky V.** Development MPC for the Grinding Process in SAG Mills Using DEM Investigations on Liner Wear // *Materials.* – 2024. – Vol. 17, No. 4. DOI: 10.3390/ma17040795.

19. **Sharikov Y.V., Snegirev N.V., Tkachev I.V.** Development of a control system based on predictive mathematical model of the C5-C6 isomerization process //

Journal of Chemical Technology and Metallurgy. – 2020. – Vol. 55, No. 2. – P. 335–344. URL: https://journal.uctm.edu/node/j2020-2/12_19-28_p_335-344.pdf

20. **Second-Order Model-Based Predictive Control of Dual Three-Phase PMSM Based on Current Loop Operation Optimization / L. Li, W. Zhou, X. Bi, et al. // Actuators. – 2022. – Vol. 11. – P. 251. DOI: 10.3390/act11090251.**

21. **Sychev Y.A., Aladin M.E.** Overall performance analysis of general-purpose power quality controls on the basis of active converters in nonlinearly loaded industrial power lines // *MIAB. Mining Inf. Anal. Bull.* – 2023. – No. 11. – P. 159–181. DOI: 10.25018/0236_1493_2023_11_0_159.

22. **Applications of simulation modeling in mining project risk management: criteria, algorithm, evaluation / M. Nevskaya, A. Sharapova, T. Kosovtseva, L. Nikolaychuk // Journal of Infrastructure, Policy and Development. – 2024. – Vol. 8. – P. 5375. DOI: 10.24294/jipd.v8ix.5375.**

23. **Multi-terminal dc grid overall control with modular multilevel converters / M.J. Carrizosa, N. Stankovic, J.-C. Vannier, et al. // Journal of Mining Institute. – 2020. – Vol. 243. – P. 357–370. DOI: 10.31897/PMI.2020.3.357**

24. **Matlab/Simulink Based Modeling and Simulation of Fuzzy PI Control for PMSM / D. Gu, Y. Yao, D.M. Zhang, et al. // Procedia Computer Science. – 2020. – Vol. 166. – P. 195–199. DOI: 10.1016/j.procs.2020.02.047.**

25. **Robust model-based control and stability analysis of PMSM drive with DC-link voltage and parameter variations / M. Mehrasa, H. Gholinezhadomran, P. Tarassodi, et al. // Results in Control and Optimization. – 2024. – Vol. 17. – P. 100469. DOI: 10.1016/j.rico.2024.100469.**

26. **Ustinov D.A., Aysar A.R.** Analysis of the Impact of the Distributed Generation Facilities on Protection Systems and Voltage Mode: Review // *Occupational Safety in Industry.* – 2023. – P. 15–20. DOI: 10.24000/0409-2961-2023-2-15-20.

27. **Speed Control for Permanent Magnet Synchronous Motor Based on Terminal Sliding Mode High-order Control / T.-L. Le, M.-F. Hsieh, P.-T. Nguyen, M.-T. Nguyen // Proceedings of 2023 International Conference on System Science and Engineering (ICSSE), Ho Chi Minh, Vietnam. – 2023. – P. 496–501. DOI: 10.1109/ICSSE58758.2023.10227245.**

28. **Chen T., Chen L., Chai F.** Behavior Modeling and Design of Winding-Switching Permanent Magnet Synchronous Machine System Based on Normalized Model // *Proceedings of 2023 26th International Conference on Electrical Machines and Systems (ICEMS), Zhuhai, China.* – 2023. – P. 5228–5232. DOI: 10.1109/ICEMS59686.2023.10344841.

29. **Shpenst V.A., Orel E.A.** Improving the reliability of DC-DC power supply by reserving feedback signals // *Energetika. Proceedings of CIS Higher Education Institutions and Power Engineering Associations.* – 2021. – Vol. 64, No. 5. – P. 408–420. DOI: 10.21122/1029-7448-2021-64-5-408-420.

30. **Al-Dujaili A.** Electrical faults classification in permanent magnet synchronous motor using ResNet neural network // *International Review of Applied Sciences and Engineering.* – 2024. – Vol. 15. DOI: 10.1556/1848.2024.00789.

31. **Thermal protection implementation of the contact overheadline based on bay controllers of electric transport traction substations in the mining industry / D.Y. Lantsev, V.Y. Frolov, S.G. Zverev, et al. // Journal of Mining Institute. – 2021. – Vol. 251. – P. 738–744. DOI: 10.31897/PMI.2021.5.13.**

32. **Symmetrical** Modeling of Physical Properties of Flexible Structure of Silicone Materials for Control of Pneumatic Soft Actuators / E.H. Muratbakeev, Y.N. Kozhubaev, Y. Yao, U. Shehzad // *Symmetry*. – 2024. – Vol. 16. – P. 750. DOI: 10.3390/sym16060750.

33. **Vasiliev B.Y., Kozyaruk A.E., Mardashov D.V.** Increasing the Utilization Factor of an Autonomous Inverter under Space Vector Control // *Russ. Electr. Engin.* – 2020. – Vol. 91. – P. 247–254. DOI: 10.3103/S1068371220040082.

34. **Majnik M., Bosnic Z.** ROC analysis of classifiers in machine learning: a survey // *Intell Data Anal.* – 2013. – Vol. 17. – P. 531–558. DOI: 10.3233/IDA-130592.

35. **Prognostics** and health management for maintenance practitioners - review, implementation and tools evaluation / V. Atamuradov, K. Medjaher, P. Dersin, et al. // *Int J Progn Health Manag.* – 2017. – Vol. 8, No. 3. – P. 1–31. DOI: 10.36001/ijphm.2017.v8i3.2667.

References

1. Errandonea, I., Beltran, S., Arrizabalaga, S. Digital twin for maintenance: a literature review. *Computers in Industry*, 2020. DOI: 10.1016/j.compind.2020.103316.

2. Rauber, T.W., da Silva Loca, A.L., de Assis Boldt, F., Rodrigues, A.L. An experimental methodology to evaluate machine learning methods for fault diagnosis based on vibration signals. *Expert Systems with Applications*, 2021, vol. 167, p. 114022. DOI: 10.1016/j.eswa.2020.114022.

3. Mohan, T.R., Roselyn, J.P., Uthra, R.A., Devaraj, D., Umachandran, K. Intelligent machine learning based total productive maintenance approach for achieving zero downtime in industrial machinery. *Computers & Industrial Engineering*, 2021, vol. 157, p. 107267. DOI: 10.1016/j.cie.2021.107267.

4. Zhang, W., Yang, D., Wang, H. Data-driven methods for predictive maintenance of industrial equipment: a survey. *IEEE Systems Journal*, 2019, vol. 13, no. 3, pp. 2213–2227. DOI: 10.1109/JSYST.2019.2905565.

5. Ran, Y., Lin, P., Zhou, X. A survey of predictive maintenance: systems, purposes and approaches. *Electrical Engineering and Systems Science*, 2019. DOI: 10.48550/arXiv.1912.07383.

6. Yu, J., Song, Y., Tang, D., Dai, J. A digital twin approach based on nonparametric Bayesian network for complex system health monitoring. *Journal of Manufacturing Systems*, 2021, vol. 58, pp. 293–304. DOI: 10.1016/j.jmsy.2020.07.005.

7. Kiangala, K.S., Wang, Z. Initiating predictive maintenance for a conveyor motor in a bottling plant using industry 4.0 concepts. *International Journal of Advanced Manufacturing Technology*, 2018, vol. 97, pp. 3251–3271. DOI: 10.1007/s00170-018-2093-8.

8. Steenwinckel, B., De Paepe, D., Vanden Haute, S. Flags: a methodology for adaptive anomaly detection and root cause analysis on sensor data streams by fusing expert knowledge with machine learning. *Future Generation Computer Systems*, 2021, vol. 116, pp. 30–48. DOI: 10.1016/j.future.2020.10.015.

9. Yu, J., Song, Y., Tang, D., Dai, J. A digital twin approach based on nonparametric Bayesian network for complex system health monitoring. *Journal of Manufacturing Systems*, 2021, vol. 58, pp. 293–304. DOI: 10.1016/j.jmsy.2020.07.005.

10. Englert, T., Graichen, K. Nonlinear model predictive torque control of PMSMs for high performance applications. *Control Engineering Practice*, 2018, vol. 81, pp. 43–54. DOI: 10.1016/j.conengprac.2018.08.023.

11. Yakovlev, V.L., Glebov, A.V., Bersenyov, V.A., Kulniyaz, S.S., Ligotskiy, D.N. Influence of an installation angle of the conveyor lift on the volumes of mining and preparing work at quarries at the cyclic-flow technology of ore mining. *News of the National Academy of Sciences of the Republic of Kazakhstan, Series of Geology and Technical Sciences*, 2020, vol. 4, no. 442, pp. 127–137. DOI: 10.32014/2020.2518-170X.93.

12. Zhu, H., Zhang, L., Peng, Z., Tan, F., Xu, L. New low-noise sensorless control strategy for permanent magnet synchronous motor drives based on variable-frequency voltage signal injection. *IET Electric Power Applications*, 2025, p. e12538. DOI: 10.1049/elp2.12538.

13. Tiddens, W., Braaksma, J., Tinga, T. Exploring predictive maintenance applications in industry. *Journal of Quality in Maintenance Engineering*, 2022, vol. 28, no. 1, pp. 68–85. DOI: 10.1108/JQME-05-2020-0029.

14. Carvalho, T.P., Soares, F.A., Vita, R., Francisco, R.D.P., Basto, J.P., Alcalá, S. A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 2019, vol. 137, p. 106024. DOI: 10.1016/j.cie.2019.106024.

15. Grieves, M., Vickers, J. Digital twin: mitigating unpredictable, undesirable emergent behavior in complex systems. *Springer*, 2017, pp. 85–113. DOI: 10.1007/978-3-319-38756-7_421.

16. Errandonea, I., Beltran, S., Arrizabalaga, S. Digital twin for maintenance: a literature review. *Computers in Industry*, 2020. DOI: 10.1016/j.compind.2020.103316.

17. Wu, D., Jennings, C., Terpenney, J., Gao, R.X., Kumara, S. A comparative study on machine learning algorithms for smart manufacturing: tool wear prediction using random forests. *Journal of Manufacturing Science and Engineering*, 2017, vol. 139, no. 7. DOI: 10.1115/1.4036350.

18. Beloglazov, I., Plaschinsky, V. Development MPC for the Grinding Process in SAG Mills Using DEM Investigations on Liner Wear. *Materials*, 2024, vol. 17, no. 4. DOI: 10.3390/ma17040795.

19. Sharikov, Y.V., Snegirev, N.V., Tkachev, I.V. Development of a control system based on predictive mathematical model of the C5-C6 isomerization process. *Journal of Chemical Technology and Metallurgy*. 2020, vol. 55, no. 2, pp. 335–344. URL: https://journal.uctm.edu/node/j2020-2/12_19-28_p_335-344.pdf.

20. Li, L., Zhou, W., Bi, X., Sun, X., Shi, X. Second-Order Model-Based Predictive Control of Dual Three-Phase PMSM Based on Current Loop Operation Optimization. *Actuators*, 2022, vol. 11, p. 251. DOI: 10.3390/act11090251.

21. Sychev, Y.A., Aladin, M.E. Overall performance analysis of general-purpose power quality controls on the basis of active converters in nonlinearly loaded industrial power lines. *Mining Informational and Analytical Bulletin*, 2023, no. 11, pp. 159–181. DOI: 10.25018/0236_1493_2023_11_0_159.

22. Nevskaya, M., Sharapova, A., Kosovtseva, T., Nikolaychuk, L. Applications of simulation modeling in mining project risk management: criteria, algorithm, evaluation. *Journal of Infrastructure, Policy and*

Development, 2024, vol. 8, no. x, p. 5375. DOI: 10.24294/jipd.v8ix.5375.

23. Carrizosa, M.J., Stankovic, N., Vannier, J.-C., Shklyarskiy, Y.E., Bardanov, A.I. Multi-terminal dc grid overall control with modular multilevel converters. *Journal of Mining Institute*, 2020, vol. 243, pp. 357–370. DOI: 10.31897/PMI.2020.3.357.

24. Gu, D.W., Yao, Y., Zhang, D.M., Cui, Y.B., Zeng, F.Q. Matlab/Simulink Based Modeling and Simulation of Fuzzy PI Control for PMSM. *Procedia Computer Science*, 2020, vol. 166, pp. 195–199. DOI: 10.1016/j.procs.2020.02.047.

25. Mehrasa, M., Gholinezhadomran, H., Tarassodi, P., Rodrigues, E.M.G., Salehfar, H. Robust model-based control and stability analysis of PMSM drive with DC-link voltage and parameter variations. *Results in Control and Optimization*, 2024, vol. 17, p. 100469. DOI: 10.1016/j.rico.2024.100469.

26. Ustinov, D.A., Aysar, A.R. Analysis of the Impact of the Distributed Generation Facilities on Protection Systems and Voltage Mode: Review. *Occupational Safety in Industry*, 2023, pp. 15–20. DOI: 10.24000/0409-2961-2023-2-15-20.

27. Le, T.-L., Hsieh, M.-F., Nguyen, P.-T., Nguyen, M.-T. Speed Control for Permanent Magnet Synchronous Motor Based on Terminal Sliding Mode High-order Control. *2023 International Conference on System Science and Engineering (ICSSE)*, Ho Chi Minh, Vietnam, 2023, pp. 496–501. DOI: 10.1109/ICSSE58758.2023.10227245.

28. Chen, T., Chen, L., Chai, F. Behavior Modeling and Design of Winding-Switching Permanent Magnet Synchronous Machine System Based on Normalized Model. *2023 26th International Conference on Electrical Machines and Systems (ICEMS)*, Zhuhai, China, 2023, pp. 5228–5232. DOI: 10.1109/ICEMS59686.2023.10344841.

29. Shpenst, V.A., Orel, E.A. Improving the reliability of DC-DC power supply by reserving feedback signals. *Energetika. Proceedings of CIS Higher Education*

Institutions and Power Engineering Associations, 2021, vol. 64, no. 5, pp. 408–420. DOI: 10.21122/1029-7448-2021-64-5-408-420.

30. Al-Dujaili, A. Electrical faults classification in permanent magnet synchronous motor using ResNet neural network. *International Review of Applied Sciences and Engineering*, 2024, vol. 15. DOI: 10.1556/1848.2024.00789.

31. Lantsev, D.Y., Frolov, V.Y., Zverev, S.G., Uhrlandt, D., Valenta, J. Thermal protection implementation of the contact overheadline based on bay controllers of electric transport traction substations in the mining industry. *Journal of Mining Institute*, 2021, vol. 251, no. 3, pp. 738–744. DOI: 10.31897/PMI.2021.5.13.

32. Muratbakeev, E.H., Kozhubaev, Y.N., Yao, Y., Shehzad, U. Symmetrical Modeling of Physical Properties of Flexible Structure of Silicone Materials for Control of Pneumatic Soft Actuators. *Symmetry*, 2024, vol. 16, p. 750. DOI: 10.3390/sym16060750.

33. Vasiliev, B.Y., Kozyaruk, A.E., Mardashov, D.V. Increasing the Utilization Factor of an Autonomous Inverter under Space Vector Control. *Russian Electrical Engineering*, 2020, vol. 91, pp. 247–254. DOI: 10.3103/S1068371220040082.

34. Majnik, B., Bosnic, Z. ROC analysis of classifiers in machine learning: a survey. *Intelligent Data Analysis*, 2013, vol. 17, pp. 531–558. DOI: 10.3233/IDA-130592.

35. Atamuradov, V., Medjaher, K., Dersin, P., Lamoureux, B., Zerhouni, N. Prognostics and health management for maintenance practitioners – review, implementation and tools evaluation. *International Journal of Prognostics and Health Management*, 2017, vol. 8, no. 3, pp. 1–31. DOI: 10.36001/ijphm.2017.v8i3.2667.