



Применение искусственного интеллекта для реализации алгоритмов потенциала негативности рассогласования в промышленных автоматизированных системах прогнозируемого обслуживания

Постановка проблемы. Одна из актуальных проблем промышленной автоматизации заключается в том, что работа немногих имеющихся на Российском рынке систем прогнозируемого обслуживания, как правило, основывается на сборе и анализе данных оборудования без учета совместного воздействия внутренних и внешних факторов. В текущих экономических условиях необходим обоснованный выбор и применение новых технологий искусственного интеллекта для исследования и реализации базовых принципов потенциала негативности рассогласования, которые откроют новые горизонты для повышения эффективности и надежности промышленных автоматизированных систем прогнозируемого или предписывающего обслуживания многостадийных технологических процессов. Моделирование автоматических реакций на изменения окружающей среды и прогнозирование отказов позволит создать адаптивные системы, которые существенно снизят риски возникновения сбоев и аварий, а также будут способствовать оптимизации производственных ресурсов и снижению эксплуатационных затрат.

Цель. Исследовать возможность применения технологий искусственного интеллекта для реализации алгоритмов, созданных на основе потенциала негативности рассогласования (англ. mismatch negativity, MMN) и возможности их применения в промышленных автоматизированных системах прогнозируемого или предписывающего обслуживания, а также разработать базовый MMN-алгоритм и реализовать его на языке программирования Python.

Результаты. Разработан алгоритм, реализующий базовые принципы потенциала негативности рассогласования. Опре-

делена практическая необходимость применения данного вида алгоритма, основанных на нейрофизиологических механизмах обработки сенсорной информации в мозге человека, для обнаружения аномалий в работе промышленного оборудования, вызванных внешними факторами, такими как температура, влажность, вибрации и электромагнитные помехи, что позволяет решить следующие задачи промышленной автоматизации: обнаружение аномалий; моделирование воздействия окружающей среды; оптимизация эксплуатационных процессов; прогнозирование отказов; адаптация к изменяющимся условиям. Предложена базовая архитектура автоматизированной системы, учитывающая необходимость использования программных алгоритмов потенциала негативности рассогласования, которая состоит из модулей верификации данных, обучения модели, обнаружения аномалий, прогнозной модели, визуализации и модуля интеграции с другими производственными информационными и автоматизированными системами. В работе также представлен программный код реализации базового MMN-алгоритма на языке Python.

Практическая значимость. Результаты исследования могут быть использованы для проектирования промышленных автоматизированных систем прогнозируемого или предписывающего обслуживания, в которых точность и время принятия решения играют важную роль.

Ключевые слова: искусственный интеллект, потенциал негативности рассогласования, прогнозируемое обслуживание, нейрофизиология, промышленная автоматизация.

Alexander Yu. Chesalov

Atlansis Software Systems Limited Liability Company, Tver, Russia

Application of Artificial Intelligence for the Implementation of Mismatch Negativity Potential Algorithms in Industrial Automated Predictive Maintenance Systems

Problem statement. One of the urgent problems of industrial automation is that the operation of the few predictive maintenance systems available on the Russian market is usually based on the collection and analysis of equipment data without considering the joint impact of internal and external factors. In the current economic conditions, it is necessary to make a reasonable choice and apply new technologies of artificial intelligence for research and realization of basic principles of mismatch negativity potential, which will open new horizons for increasing efficiency and reliability of industrial automated systems of predictive or prescriptive maintenance of multistage technological processes.

Modeling of automatic reactions to environmental changes and prediction of failures will allow to develop adaptive systems that will significantly reduce the risks of failures and accidents, as well as contribute to optimization of production resources and reduction of operating costs.

Purpose. To study the possibility of using artificial intelligence technologies to implement algorithms based on the potential of mismatch negativity (MMN) and the possibility of their application in industrial automated systems of predictive or prescriptive maintenance, as well as to develop a basic MMN algorithm and implement it in the Python programming language.

Results. An algorithm implementing the basic principles of mismatch negativity potential has been developed. The practical necessity of using such an algorithm, which is based on neurophysiological mechanisms of sensory information processing in the human brain, for detecting anomalies in the operation of industrial equipment caused by external factors such as temperature, humidity, vibrations, and electromagnetic interference was determined, which allows solving the following tasks of industrial automation: anomaly detection, modeling of environmental impact, optimization of operational processes, prediction of failures, adaptation to changes in the environment. The basic architecture of the automated system is proposed, which takes into account the need to use software

algorithms of mismatch negativity potential. It consists of modules of data verification, model training, anomaly detection, predictive model, visualization and module of integration with other industrial information and automated systems. The paper also presents the program code for the implementation of the basic MMN algorithm in Python language.

Practical significance. The results of the study can be used to design industrial automated systems of predictive or prescriptive maintenance, in which accuracy and decision time play an important role.

Keywords: artificial intelligence, mismatch negativity potential, predictive maintenance, neurophysiology, industrial automation.

Введение

Промышленные системы, производственные линии и оборудование подвержены влиянию множества факторов окружающей среды, таких как температура, влажность, вибрации и электромагнитные помехи. Эти факторы могут приводить к постепенному ухудшению состояния оборудования, что влечет за собой риски аварий и простоев. Традиционные методы мониторинга и диагностики часто оказываются недостаточно эффективными для своевременного выявления аномалий, особенно в условиях динамически изменяющейся среды.

Одна из проблем современной автоматизации заключается в том, что работа немногих имеющихся на Российском рынке автоматизированных систем прогнозируемого или предписывающего обслуживания основывается, чаще всего, на сборе, анализе и построении прогнозной аналитики конкретного оборудования или комплекса взаимосвязанного оборудования (например, производственной линии) без учета воздействия внешних факторов, влияние которых, порой, не очевидно, но в рамках промышленных кластеров или экосистем огромно.

Пример из личной практики. Промышленное предприятие производит проволоку. При ее производстве возникает брак и, естественно у предприятия проблемы с за-

казчиками и убытки. Анализ информации, предоставленной системой прогнозируемого обслуживания, полученной с датчиков производственной линии не дал никаких результатов. Тогда, было принято решение установить дополнительные датчики (регистрирующие вибрацию, температуру, влажность и давление) в цеху и прилегающих к нему помещениях. Результат всех удивил. К цеху, где производится проволока прилегал цех выплавки, а к цеху выплавки прилегал большое складское помещение, где осуществлялась погрузка и разгрузка медных слитков. Так вот, оказалось, что на качестве выплавляемой продукции сказываются открытые долгое время ворота складского цеха зимой, когда осуществляется погрузка и разгрузка слитков. А на качество проволоки в свою очередь влияет температурные условия цеха выплавки и качество исходного сырья для нее. Таким образом, за счет установки дополнительных датчиков удалось определить причину брака проволоки, а установкой воздушных шлюзов между помещениями удалось устранить причину брака и повысить качество выпускаемой продукции.

Всего этого можно было бы избежать, если бы системой прогнозируемого обслуживания собиралась и анализировалась информация не только с конкретного оборудования, но и с внешних датчиков.

Анализ технологий проектирования автоматизированных систем прогнозируемого в промышленности

Несомненно, существует множество научно-исследовательских работ, посвященных кибер-физическим системам, автоматизации производства и прогнозируемому обслуживанию. Так, например, в работах [1, 2, 3, 4, 5] произведен анализ современных тенденций и достижений в области развития интеллектуальных систем и систем прогнозируемого обслуживания в условиях использования больших данных, собираемых с устройств промышленного Интернета вещей. Интеллектуальное производство на основе данных (англ. Data-driven smart manufacturing (DDSC)) — это подход, при котором данные становятся ключевым ресурсом для принятия решений и управления производственными процессами. Основной акцент в публикациях делается на объединении больших данных и аналитических подходов для повышения эффективности производственных процессов, сокращения издержек и улучшения качества выпускаемой продукции. В исследованиях отмечается важность создания современных инструментов прогнозирования, которые позволяют обеспечить стабильную работу и высокую производительность промышленных объектов. Это достигается за счет внедрения технологий машинного обуче-

ния, анализа больших объемов данных, облачных платформ и промышленного Интернета вещей. Особое внимание уделяется тому, что ключевым элементом современного производства является система прогнозируемого технического обслуживания, которая позволяет своевременно определять вероятность возникновения поломки и предотвращать сбои промышленного оборудования.

Работы [6, 7, 8, 9, 10] посвящены разработке архитектур киберфизических систем (англ. Cyber-Physical Systems, CPS) для производственных систем (с учетом анализа внешних факторов воздействия на них), соответствующих концепции Индустрии 4.0. Авторы предлагают интегрированную структуру, которая объединяет физические и кибернетические компоненты для создания умных (интеллектуальных), автономных (самоуправляемых) и гибких производственных систем. Авторы подчеркивают необходимость создания интеллектуальных систем прогнозируемого обслуживания производственных активов, а также использования искусственного интеллекта и машинного обучения для создания систем поддержки — принятия решений.

В работах [11, 12, 13] рассмотрены методы машинного обучения для решения задач прогнозирующего обслуживания в промышленных системах (с учетом внешних факторов, воздействующих на работу промышленного оборудования). Авторы предлагают подход, основанный на использовании нескольких классификаторов, который позволяет повысить точность прогнозирования отказов оборудования. В статьях рассматриваются различные алгоритмы машинного обучения, такие как метод опорных векторов, случайные леса и нейронные сети, и доказываются их эффективность исполь-

зования на реальных промышленных данных. Основным выводом заключается в том, что комбинирование нескольких классификаторов позволяет достичь более высокой точности и надежности прогнозов. Такой подход способствует снижению затрат на техническое обслуживание, уменьшению простоев оборудования и повышению общей эффективности производственных процессов.

Тем не менее найти работы, которые бы объединили в себе использование новых технологий, созданных на основе исследования вопросов применения потенциала негативности рассогласования и искусственного интеллекта в автоматизированных системах, представляется затруднительным, в силу сложности реализации данной задачи и определенной специфики исследований данного направления работ.

Цель работы. Исследовать возможность применения технологий искусственного интеллекта для реализации алгоритмов (MMN-алгоритмов), созданных на основе потенциала негативности рассогласования (Mismatch Negativity, MMN) и возможности их применения в промышленных автоматизированных системах прогнозируемого и предписывающего обслуживания.

Анализ возможности применения технологий искусственного интеллекта для реализации алгоритмов (MMN-алгоритмов)

Современная нейрофизиология активно изучает процессы обработки сенсорной информации в мозге человека, которые происходят без участия сознательных усилий и фокусировки внимания. Одним из ключевых феноменов в этой области является так называемый потенциал негативности рассогласования — это автоматическая реакция мозга

на отклонение от ожидаемого паттерна стимулов. Этот процесс происходит на уровне подсознания и не требует активного внимания. Тем не менее, этот механизм позволяет мозгу практически мгновенно (регистрируется через 100–250 мс после изменения стимула) и эффективно обнаруживать изменения в окружающей среде и принимать быстрые решения в экстремальных ситуациях, что имеет важнейшее значение для адаптации и выживания человека в окружающей его среде.

Что касается вопроса «мгновенной» передачи информации из окружающего нас мира в наше подсознание, то согласно исследованию, которое было проведено в Цзеюй Чжэн и Маркусом Майстером из Калифорнийского технологического института (работа опубликована в журнале *Neuron*), сенсорные системы человеческого тела собирают данные об окружающей среде со скоростью триллион бит в секунду (10^9 бит/с), что в 100 миллиардов раз быстрее, чем наши мыслительные процессы. По мнению ученых, человеческий мозг работает в двух различных режимах: «внешний», когда мозг обрабатывает быстрые многомерные сенсорные и моторные сигналы, и «внутренний», когда мозг обрабатывает сокращенные до десятков бит/с сигналы, необходимые для управления поведением человека [14].

Гипотеза автора заключается в том, что основные принципы, которые лежат в основе реализации сознанием человека потенциала негативности рассогласования, могут быть адаптированы для создания интеллектуальных систем, способных выявлять отклонения в работе оборудования на ранних стадиях. Исследование механизмов сбора и анализа информации, а также реализация MMN-подобных алгоритмов должно осуществляться с при-

менением современных технологий искусственного интеллекта (ИИ), что открывает новые возможности для автоматизации прогнозируемого и предписывающего обслуживания промышленного оборудования и повышения устойчивости промышленных систем к внешним воздействиям.

Применение MMN-подобных алгоритмов в промышленных автоматизированных системах для мониторинга и управления оборудованием в обычных и экстремальных условиях функционирования позволит решить следующие задачи прогнозируемого и предписывающего обслуживания:

1. Обнаружение аномалий. Современные алгоритмы ИИ (например, основанные на рекуррентных нейронных сетях или трансформерах) могут быть обучены на больших объемах данных, собранных с промышленного оборудования и датчиков окружающей среды, чтобы выявлять аномалии в работе оборудования, вызванных изменением внешних факторов, таких как температура, влажность, вибрации или электромагнитные помехи. Что позволяет своевременно обнаруживать потенциальные сбои или неисправности, вызванные изменением внешних условий.

2. Моделирование воздействия окружающей среды. С использованием данных о рассогласованиях, ИИ может создавать точные модели воздействия окружающей среды на оборудование. Эти модели могут учитывать различные сценарии и прогнозировать потенциальные негативные последствия.

3. Оптимизация эксплуатационных процессов. На основе выявленных рассогласований, ИИ может предлагать оптимальные стратегии эксплуатации оборудования, которые минимизируют негативное воздействие окружающей сре-



Рис. 1. Система сбора и обработки информации человеческим сознанием

Fig. 1. System of information collecting and processing by human consciousness

ды и повышают надежность и долговечность оборудования.

4. Прогнозирование отказов. Используя методы прогнозной аналитики, ИИ может предсказывать возможные сбои в работе оборудования на основе анализа внешних факторов. Это позволяет перейти от прогнозируемого к предписывающему обслуживанию, что снижает затраты и повышает надежность систем.

5. Адаптация к изменяющимся условиям. Подобно тому, как мозг адаптируется к новым стимулам, промышленные системы могут использовать ИИ для автоматической настройки параметров работы оборудования в ответ на изменения окружающей среды. Например, при повышении температуры система может автоматически снизить нагрузку на оборудование или включить дополнительные охлаждающие механизмы.

Возвращаясь к вопросам изучению и пониманию когнитивных функций человека (внимание, ориентация, память, гнозис, исполнительные функции, праксис, язык, социальное познание и зритель-

но-пространственные навыки), и понимая основных принципов работы MMN-алгоритмов, инженерам – программистам, которые будут работать в этой области, необходимо обратить свое внимание на когнитивную психологию и нейрофизиологию, которая занимается исследованием функций нервной системы, включая процессы кодирования, передачи и обработки информации в нейронных сетях человеческого мозга, а также механизмов, лежащих в основе системных функций, которые определяют поведение и реакции человека [15].

Когнитивная психология имеет важное значение в исследовании того, как мозг человека обрабатывает сенсорную информацию (схема представлена на рисунке 1). В современной науке она часто опирается на параллели между познавательными процессами у людей и принципами обработки данных в компьютерных системах.

В процессе формирования когнитивной психологии как самостоятельной научной дисциплины [16], отмечается, что одним из ключевых исследо-

вателей, заложивших ее основы, стал Дж. А. Миллер. В 1956 году он совместно с Дж. С. Брунером организовал научный центр при Гарвардском университете, посвященный изучению когнитивных процессов. Основной задачей когнитивной психологии стало исследование механизмов обработки информации, которую человек получает из окружающей среды. Еще одним значимым ученым в этой области считается У. Г. Найссер. В 1976 году он предложил концепцию восприятия, где познание рассматривалось как активный процесс, включающий взаимодействие человека с внешним миром.

В исследовании [17] отмечается, что в современной когнитивной психологии компьютер рассматривается в качестве инструмента для моделирования процессов человеческого мышления и разработки систем искусственного интеллекта. Такие системы способны превосходить человека по ряду параметров, включая скорость и точность обработки информации, а также объем данных, которые могут быть сохранены и проанализированы.

В области нейрофизиологии в настоящее время выделяются три ключевые группы методов, которые используются для исследования структурной и функциональной организации нервной системы человека: морфологические, клинические и экспериментальные подходы.

Клиническая нейрофизиология, наряду с методами нейровизуализации, такими как позитронно-эмиссионная томография (ПЭТ), функциональная магнитно-резонансная томография (фМРТ) и однофотонно-эмиссионная компьютерная томография (ОФЭКТ), располагает широким спектром инструментов для анализа когнитивных функций. Среди них выделяются высокоплотная электро-




Рис. 2. Схематическое представление пиков положительных и отрицательных компонентов вызванного потенциала и потенциал негативности рассогласования

Fig. 2. Schematic representation of the peaks of the positive and negative components of the evoked potential and the mismatch negativity potential

энцефалография (ЭЭГ), магнитоэнцефалография (МЭГ), навигационная транскраниальная магнитная стимуляция (нТМС), а также вызванные потенциалы (ВП) различных модальностей.

Прежде чем перейти к исследованию потенциала негативности рассогласования, необходимо обратить внимание на такой метод исследования нервной системы, который называется «вызванные потенциалы».

В исследовании [18] вызванные потенциалы (или вызванный ответ, от англ. evoked potential, evoked response) описываются как электрические сигналы, регистрируемые в головном мозге человека в ответ на внешние стимулы различной модальности. Изучение вызванных потенциалов активно ведется с 1960-х годов.

Вызванные потенциалы, связанные с событиями (от англ. event-related potentials), представляют собой один из наиболее широко используемых типов когнитивных вызванных потенциалов. Они

отражают электрическую активность мозга, возникающую в ответ на конкретные сенсорные или когнитивные стимулы из внешней среды. Эти потенциалы применяются для отслеживания активности мозга на различных уровнях — от базового сенсорного восприятия до сложных когнитивных процессов.

Нейрофизиологи фиксируют следующие виды вызванных потенциалов, используемых в клинической практике: слуховые вызванные потенциалы, зрительные вызванные потенциалы и соматосенсорные вызванные потенциалы.

К основным характеристикам вызванных потенциалов относятся латентный период (время задержки реакции), амплитуда (или площадь сигнала), полярность (отрицательная или положительная) и форма волны.

Вызванные потенциалы (представленные на рисунке 2), связанные с событиями, обладают стабильной и повторяемой формой сигнала, которая визуализируется в

виде последовательности пиков. Положительные компоненты обозначаются буквой P (например, P100, P200, P300), а отрицательные — буквой N (например, N100, N200). Цифры в обозначениях указывают на латентный период (ЛП) пика, выраженный в миллисекундах.

Как указано в исследовании [19], анализ таких компонентов, как P300 и MMN, дает возможность выявить принципы функционирования мозга, которые лежат в основе обработки информации как в обычных, так и в экстремальных условиях, под влиянием внешних факторов. Эти компоненты позволяют изучить механизмы реакции, внимания, распознавания стимулов, принятия решений, прогнозирования событий, а также извлечения данных из памяти и другие когнитивные процессы.

Архитектура автоматизированной системы прогнозируемого обслуживания на основе MMN-алгоритмов

Основная задача создания MMN-подобных алгоритмов заключается в том, чтобы максимально точно зафиксировать механизмы обработки сенсорной информации из окружающей среды нервной системой человека, которые реализуются в экстремальных жизненных условиях. Эти алгоритмы необходимо перенести в новую архитектуру автоматизированной системы прогнозируемого или предписывающего обслуживания (которая представлена на рисунке 3), которая бы реализовывала (условно говоря) функциональные возможности человеческого тела по сбору и возможности человеческого сознания по обработке информации. В некотором смысле, архитектура автоматизированной системы была бы схожа с сенсорной (нервной) системой, которая с большой




Рис. 3. Концептуальная архитектура автоматизированной системы прогнозируемого или предписывающего обслуживания с реализованными MMN-алгоритмами

Fig. 3. Conceptual architecture of the automated system of predictive or prescriptive maintenance with implemented MMN-algorithms

скоростью собирает огромное количество данных из окружающей среды, обрабатывает их и принимает своевременное решение. Это позволило бы в разы повысить точность прогнозов интеллектуальных аналитических систем, ускорить обнаружение неисправностей и сократить время принятия своевременных решений.

Таким образом автоматизированная система прогнозируемого или предписывающего обслуживания, включающая MMN-алгоритмы, должна поддерживать реализацию следующих модулей (функциональных подсистем) и основных функций:

1. Верификация данных

- Нормализация данных. Входные сигналы нормализуются для приведения к единому масштабу. Это может быть выполнено с помощью методов, таких как Min-Max нормализация или Z-нормализация.

- Фильтрация шумов. Для устранения шумов применяются фильтры, такие как фильтр низких частот (Low-pass filter) или вейвлет-преобразование.

Это помогает выделить полезные сигналы и устранить высокочастотные шумы.

- Разделение данных. Данную процедуру необходимо производить для обучения основной модели, с целью ее дальнейшего тестирования.

2. Обучение модели

- Архитектура модели. В зависимости от типа данных, используется глубокая нейронная сеть, например, авторегрессионная модель (ARIMA), рекуррентная нейронная сеть долгая краткосрочная память (англ. Long short-term memory, LSTM) или CNN (сверточная нейронная сеть). Модель обучается на нормализованных данных для предсказания следующих значений временного ряда.

- Функция потерь. В качестве функции потерь используется среднеквадратичная ошибка (MSE) или средняя абсолютная ошибка (MAE), чтобы минимизировать разницу между предсказанными и реальными значениями.

- Обучение с учителем: Модель обучается на данных, где

аномалии отсутствуют, чтобы научиться предсказывать нормальное поведение системы.

3. Обнаружение аномалий

- **Предсказание значений.** Модель предсказывает значения временного ряда на основе предыдущих данных.

- **Вычисление потенциала негативности рассогласования.** Рассогласование вычисляется, как разница между реальными и предсказанными значениями.

- **Пороговое значение.** Устанавливается пороговое значение для рассогласования. Если MMN превышает порог, это свидетельствует о наличии аномалии. Порог может быть определен статистически.

4. Прогнозная модель для оценки вероятности отказа оборудования [20].

- **Классификация аномалий.** Выявленные аномалии классифицируются по степени их серьезности. Например, аномалии могут быть разделены на «незначительные», «средние» и «критические».

- **Прогнозная модель.** На основе исторических данных о выявленных аномалиях строится прогнозная модель, которая оценивает вероятность отказа оборудования. Для этого может быть использован метод логистической регрессии или градиентный бустинг.

- **Оценка вероятности отказа.** Модель оценивает вероятность отказа оборудования на основе частоты и классификации аномалий.

5. Визуализация и отчетность

- **Визуализация аномалий.** Результаты обнаружения аномалий визуализируются с помощью графиков временных рядов, где аномалии выделяются цветом или маркерами.

- **Отчетность.** Формируется отчет, содержащий информацию о выявленных аномалиях, их серьезности и вероятности отказа оборудования.

Для имитации механизмов обработки сенсорной инфор-

мации, как в мозге человека, в автоматизированную систему прогнозируемого или предписывающего обслуживания, включающую MMN-алгоритмы, должны быть встроены следующие элементы:

- **Механизмы внимания.** Внедрение механизмов внимания в нейронные сети для фокусировки на наиболее важных сигналах. Это позволяет системе выделять ключевые показатели, которые могут указывать на аномалии.

- **Адаптивное обучение.** Модель должна адаптироваться к изменениям в данных (например, износ оборудования, изменение внешних условий). Это достигается за счет непрерывного обновления модели на основе новых данных.

- **Быстрая реакция на рассогласование.** Алгоритм должен быстро реагировать на рассогласование между ожидаемыми и фактическими значениями. Это достигается за счет использования легковесных моделей и оптимизированных алгоритмов.

К преимуществам предложенной архитектуры автоматизированной системы прогнозируемого или предписывающего обслуживания можно отнести: высокую точность обнаружения аномалий, за счет использования MMN-алгоритма, механизмов внимания, быстрой реакции на рассогласование и имеющиеся адаптивные механизмы переобучения моделей, а также возможности оценки вероятности выхода из строя оборудования.

Реализация базового MMN-алгоритма на языке программирования Python

С учетом предложенной архитектуры, базовый пример реализации MMN-алгоритма для автоматизированной системы прогнозируемого или предписывающего обслуживания на языке Python выглядит следующим образом:

```
# Необходимо установить
# библиотеки numpy, pandas,
# scikit-learn, tensorflow и xgboost
import numpy as np
import pandas as pd
from sklearn.preprocessing
import MinMaxScaler
from tensorflow.keras.models
import Sequential
from tensorflow.keras.layers
import LSTM, Dense, Attention
from sklearn.metrics import
mean_squared_error
from xgboost import XGB-
Classifier
from sklearn.model_selection
import train_test_split
from sklearn.metrics import
classification_report, roc_auc_
score
```

```
# 1. Загрузка и подготовка
# данных
```

```
# Файлы equipment_data.
# csv, external_factors.csv и
# failure_data.csv должны содер-
# жать данные в правильном
# формате
```

```
# equipment_data.csv должен
# содержать временные ряды
# failure_data.csv — метки
# сбоев
```

```
def load_and_preprocess_
data():
```

```
# Загрузка данных
equipment_data = pd.read_
csv('equipment_data.csv')
external_data = pd.read_
csv('external_factors.csv')
```

```
# Нормализация данных
scaler = MinMaxScaler()
normalized_equipment =
scaler.fit_transform(equipment_
data)
normalized_external = scaler.
fit_transform(external_data)
return normalized_equipment,
normalized_external
```

```
# 2. Создание временных
# последовательностей
```

```
def create_sequences(data, ex-
ternal, window_size=50):
sequences, targets = [], []
for i in range(len(data) - win-
dow_size - 1):
sequences.append(np.
concatenate((data[i:(i + window_
```

```

size), 0], external[i:(i + window_
size), :]), axis=1))
    targets.append(data[i +
window_size, 0])
    return np.array(sequences),
np.array(targets)

# 3. Построение модели
LSTM с механизмом внимания
def build_lstm_model(input_
shape):
    model = Sequential()
    model.add(LSTM(50,
return_sequences=True, input_
shape=input_shape))
    model.add(Attention())
(model.output) # Добавление
механизма внимания
    model.add(LSTM(50, return_
sequences=False))
    model.add(Dense(1))
    model.compile(loss='mean_
squared_error', optimizer =
'adam')
    return model

# 4. Обучение модели LSTM
def train_lstm_model(model,
X, Y, epochs=20, batch_size=64):
    model.fit(X, Y, epochs =
epochs, batch_size = batch_size,
verbose=1)
    return model

# 5. Вычисление уровня
рассогласования
def calculate_discrepancy
(actual, predicted):
    return np.abs(actual -
predicted.flatten())

# 6. Подготовка данных для
классификации
def prepare_classification_
data(predictions, discrepancies,
failure_labels):
    features = np.column_
stack((predictions.flatten(),
discrepancies))
    X_train, X_test, y_train, y_
test = train_test_split(features,
failure_labels, test_size=0.2,
random_state=42)
    return X_train, X_test, y_
train, y_test

# 7. Обучение модели
XGBoost
def train_xgboost_model(X_
train, y_train):
    model = XGBClassifier(use_
label_encoder=False, eval_
metric='logloss')
    model.fit(X_train, y_train)
    return model

# 8. Оценка модели XGBoost
def evaluate_model(model,
X_test, y_test):
    y_pred = model.predict (X_
test)
    y_pred_proba = model.
predict_proba(X_test)[:, 1]

    print("Classification Report:")
    print(classification_report(y_
test, y_pred))

    print("ROC-AUC Score:")
    print(roc_auc_score(y_test,
y_pred_proba))

# 9. Прогнозирование
вероятности отказа
def predict_failure_probability
(model, new_data):
    probability = model.predict_
proba (new_data)[:, 1]
    return probability[0] * 100

# Основной блок
выполнения
if __name__ == "__main__":
#Загрузка и предварительная
обработка данных
    equipment_data, external_
data = load_and_preprocess_
data()

# Создание временных
последовательностей
    X, Y = create_sequences
(equipment_data, external_data,
window_size=50)
    X = X.reshape (X.shape[0],
X.shape[1], X.shape[2])

# Построение и обучение
модели LSTM
    lstm_model = build_lstm_
model ((X.shape[1], X.shape[2]))
    lstm_model = train_lstm_
model (lstm_model, X, Y)

# Предсказание и вычисле-
ние уровня рассогласования
    predictions = lstm_model.
predict(X)
    discrepancies = calculate_
discrepancy(Y, predictions)

# Загрузка данных о сбоях
failure_data = pd.read_csv
('failure_data.csv')
failure_labels = failure_
data['failure'].values

# Подготовка данных для
классификации
X_train, X_test, y_train,
y_test = prepare_classification_
data(predictions, discrepancies,
failure_labels)

# Обучение модели XGBoost
xgb_model = train_xgboost_
model(X_train, y_train)

# Оценка модели
evaluate_model(xgb_model,
X_test, y_test)

# Прогнозирование вероят-
ности отказа для новых данных
new_data = np.array([[0.5,
0.1]]) # Пример новых данных
failure_probability = predict_
failure_probability(xgb_model,
new_data)
print(f"Вероятность отказа:
{failure_probability:.2f}%")

```

Представленный MMN-алгоритм, позволяет не только обнаруживать аномалии, но и оценивать вероятность отказа оборудования на основе выявленных аномалий. Это делает автоматизированную систему более эффективной в части прогнозируемого обслуживания, так как она предоставляет инженерам информацию о потенциальных рисках и помогает принимать своевременные решения. Также к преимуществам такого алгоритма можно отнести то, что он может быть доработан и адаптирован под конкретные задачи и типы данных (временные ряды, изображения, звук и т.д.).

Заключение

Применение автоматизированных систем, реализующих MMN-алгоритмы, особенно актуально для промышленных предприятий атомной, космической, металлургической,

топливно-энергетической и химической отраслей экономики. Кроме того, это направление исследований очень важно, как для медицины, так и для робототехники. Например, объединение технологий искусственного интеллекта и данных мониторинга электроэнцефалограммы, с помощью которой производят оценку работы функций головного мозга, позволит создавать новые нейроинтерфейсы, биоэлектрические и миоэлектрические протезы, коллаборативных роботов (коботов) и многое другое [21].

Как мы с вами видим, перспективы применения ИИ для реализации MMN-подобных алгоритмов в промышленных системах открывает новые горизонты для повышения их надежности и эффективности работы. Однако остаются вызовы, связанные с необходимостью: разработки новых подходов для сбора больших объемов данных с большого

числа внутренних и внешних датчиков, и их эффективно-го анализа; научных исследований и совершенствования MMN-алгоритмов; разработки новых алгоритмов, реализующих механизмы внимания для фокусировки на наиболее важных сигналах; совершенствования механизмов адаптивного обучения.

Дальнейшие исследования в этой области могут быть направлены на разработку более сложных ИИ-моделей, способных учитывать множественные внутренние и внешние факторы и их взаимосвязи, что позволит создавать еще более надежные и интеллектуальные промышленные системы. А в последствии на разработку более компактных и энергоэффективных моделей для промышленных автоматизированных систем реального времени.

Применение современных технологий искусствен-

ного интеллекта для реализации базовых принципов потенциала негативности рас-согласования, открывает новые горизонты для повышения эффективности и надежности промышленных экосистем систем. Моделирование автоматических реакций на изменения окружающей среды позволяет создавать адаптивные системы, способные быстро и эффективно реагировать на внешние воздействия. Это не только снижает риски сбоев и аварий, но и способствует оптимизации производственных ресурсов и снижению эксплуатационных затрат, что позитивно сказывается на себестоимости продукции и капитализации промышленных предприятий.

Результаты исследования могут быть использованы при проектировании промышленных автоматизированных систем прогнозируемого и предписывающего обслуживания.

Литература

1. Jay Lee, Edzel Lapira, Behrad Bagheri, Hung-an Kao. Recent advances and trends in predictive manufacturing systems in big data environment // *Manufacturing Letters*. 2013. Т. 1. № 1. С. 38–41. DOI: 10.1016/j.mfglet.2013.09.005. (Дата обращения: 18.03.2025).
2. Fei Tao, Qinglin Qi, Ang Liu, Andrew Kusiak. Data-driven smart manufacturing // *Journal of Manufacturing Systems*. 2018. Т. 48. С. 157–169, DOI: 10.1016/j.jmsy.2018.01.006. (Дата обращения: 18.03.2025).
3. Zhang Y., Huang T. & Bompard E.F. Big data analytics in smart grids: a review // *Energy Informatics*. 2018. № 1(1). DOI: 10.1186/s42162-018-0007-5. (Дата обращения: 18.03.2025).
4. Kusiak A. Smart manufacturing must embrace big data // *Nature*. 2017. № 544 (7648). С. 23–25. DOI: 10.1038/544023a. (Дата обращения: 18.03.2025).
5. Jayavardhana Gubbi, Rajkumar Buyya, Slaven Marusic, Marimuthu Palaniswami. Internet of Things (IoT): A vision, architectural elements, and future directions // *Future Generation Computer Systems*. 2013. Т. 29. № 7. С. 1645–1660. DOI: 10.1016/j.future.2013.01.010. (Дата обращения: 18.03.2025).
6. Jay Lee, Behrad Bagheri, Hung-An Kao. A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems // *Manufacturing Letters*. 2015. № 3. С. 18–23. DOI: 10.1016/j.mfglet.2014.12.001. (Дата обращения: 18.03.2025).
7. Lihui Wang, Martin Törngren, Mauro Onori. Current status and advancement of cyber-physical systems in manufacturing // *Journal of Manufacturing Systems*. 2015. Т. 37(2). С. 517–527. DOI: 10.1016/j.jmsy.2015.04.008. (Дата обращения: 18.03.2025).
8. Yuqian Lu, Xun Xu, Lihui Wang. Smart manufacturing process and system automation – A critical review of the standards and envisioned scenarios // *Journal of Manufacturing Systems*. 2020. Т. 56. С. 312–325. DOI: 10.1016/j.jmsy.2020.06.010. (Дата обращения: 18.03.2025).
9. Zhou K., Liu T., & Zhou L. Industry 4.0: Towards future industrial opportunities and challenges. In 2015 12th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD). 2015. С. 2147–2152. DOI: 10.1109/FSKD.2015.7382284. (Дата обращения: 18.03.2025).
10. Xu L. D., Xu E. L., & Li L. Industry 4.0: state of the art and future trends // *International Journal of Production Research*. 2018. № 56(8). С. 2941–2962. DOI: 10.1080/00207543.2018.1444806. (Дата обращения: 18.03.2025).
11. 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. № 11(3). С. 812–820. DOI: 10.1109/TII.2014.2349359. (Дата обращения: 18.03.2025).

12. Panagiotis Mallioris, Eirini Aivazidou, Dimitrios Bechtsis. Predictive maintenance in Industry 4.0: A systematic multi-sector mapping // CIRP Journal of Manufacturing Science and Technology. 2024. Т. 50. С. 80–103. DOI: 10.1016/j.cirpj.2024.02.003. 2024. (Дата обращения: 18.03.2025).

13. Andrew K.S. Jardine, Daming Lin, Dragan Banjevic. A review on machinery diagnostics and prognostics implementing condition-based maintenance // Mechanical Systems and Signal Processing. 2006. Т. 20. № 7. С. 1483–1510. DOI: 10.1016/j.ymssp.2005.09.012. (Дата обращения: 18.03.2025).

14. Zheng J, Meister M. The unbearable slowness of being: Why do we live at 10 bits/s? Neuron [Электрон. ресурс]. 2025. № 113(2). С. 192–204. Режим доступа: <https://arxiv.org/html/2408.10234v2>. (Дата обращения: 18.03.2025).

15. Дорогина О.И. Нейрофизиология [Электрон. ресурс]. Екатеринбург: Уральский федеральный университет, 2019. 100 с. Режим доступа: https://elar.urfu.ru/bitstream/10995/77151/1/978-5-7996-2619-8_2019.pdf (Дата обращения: 18.03.2025).

16. Манцулич В.В. История становления когнитивной психологии и развития взглядов на

проблему когнитивных и метакогнитивных способностей личности // Вестник Московского городского педагогического университета. Серия «Педагогика и психология». 2022. № 16 (4). С. 90–102. DOI: 10.25688/2076-9121.2022.16.4.05.

17. Когнитивная психология / Под ред. В.Н. Дружинина, Д.В. Ушакова. М.: ПЕР СЭ, 2002. 479 с.

18. Вызванные потенциалы мозга (ВП) [Электрон. ресурс]. Режим доступа: <https://smi.to/вызванные-потенциалы/>. (Дата обращения: 17.03.2025).

19. Березина И.Ю., Михайлов А.Ю., Горечкая Т.А. и др. Применение вызванных потенциалов, связанных с событием (Р300), у лиц, злоупотребляющих психоактивными веществами // Вопросы наркологии. 2020. № 12. С. 19–43. DOI: 10.47877/0234-0623_2020_12_19.

20. Guansong Pang, Chunhua Shen, Longbing Cao, and Anton van den Hengel. Deep Learning for Anomaly Detection: A Review // ACM Comput. Surv. 2020. Т. 1. № 1. DOI: 10.1145/3439950.

21. Шустов Д.И., Федотов И.А., Кряжкова Д.Ю. Использование потенциала негативности рассогласования при диагностике психозов: систематический обзор метаанализов [Электрон. ресурс] // ФГБУ «НМИЦ ПН им. В.П. Сербского» Минздрава России, 2024. Режим доступа: https://psychiatr.ru/files/magazines/2024_08_scp_2423.pdf. (Дата обращения: 17.03.2025).

References

1. Knyaz'kov V.A. Mashinnoye obucheniye: Teoriya i praktika = Machine Learning: Theory and Practice. Moscow: Dialectics; 2020. (In Russ.)

2. Gusev S.V. Metody mashinnogo obucheniya v ekonomike = Machine Learning Methods in Economics. Saint Petersburg: Piter; 2021. (In Russ.)

3. Timofeyev V.N. Vvedeniye v mashinnoye obucheniye i yego prilozheniya v ekonomike = Introduction to Machine Learning and its Applications in Economics. Moscow: KNORUS; 2019. (In Russ.)

4. Lebedev A.I. Iskusstvennyy intellekt i mashinnoye obucheniye v ekonomike = Artificial Intelligence and Machine Learning in Economics. Moscow: Science; 2018. (In Russ.)

5. Petrov D.V. Modeli mashinnogo obucheniya dlya analiza dannykh v ekonomike = Machine Learning Models for Data Analysis in Economics. Kazan: Kazan University; 2020. (In Russ.)

6. Sergeyeva N.A. Analiz dannykh i mashinnoye obucheniye v ekonomike i biznese = Data Analysis and Machine Learning in Economics and Business. Moscow: Yurayt; 2019. (In Russ.)

7. Shevchenko YU.I. Ispol'zovaniye neyronnykh setey v ekonomicheskikh issledovaniyakh = Using Neural Networks in Economic Research. Rostov-on-Don: Phoenix; 2021. (In Russ.)

8. Bogdanov I.V. Prognozirovaniye rynochnykh trendov s pomoshch'yu mashinnogo obucheniya = Forecasting Market Trends Using Machine Learning. Moscow: Alfa-Bank; 2020. (In Russ.)

9. Litvinova I.S. Upravleniye riskami s ispol'zovaniyem mashinnogo obucheniya = Risk Management Using Machine Learning. Ekaterinburg: UrFU; 2022. (In Russ.)

10. Kuznetsova T.A. Mashinnoye obucheniye v ekonomicheskoy analize = Machine Learning in Economic Analysis. Moscow: Finance and Statistics; 2021. (In Russ.)

11. Gamidov M.SH. Modeli analiza dannykh i mashinnoye obucheniye v ekonomike = Data Analysis Models and Machine Learning in Economics. Dushanbe: Tajik National University; 2021.

12. Radzhabov R.M. Informatsionnyye tekhnologii i mashinnoye obucheniye v ekonomicheskoy razvitii = Information Technology and Machine Learning in Economic Development. Dushanbe: Donish; 2020.

13. Dzhabborov F.Z. Mashinnoye obucheniye i yego ispol'zovaniye v ekonomicheskoy prognozirovanii v Tadjikistane = Machine Learning and Its Use in Economic Forecasting in Tajikistan. Dushanbe: Academy of Sciences of the Republic of Tajikistan; 2022.

14. Kurbanov A.M. Metody analiza dannykh v ekonomike = Methods of data analysis in economics. Dushanbe: Donish; 2019.
15. Sharifov R.M. Algoritmy mashinnogo obucheniya i ikh primeneniye v finansakh = Machine learning algorithms and their application in finance. Dushanbe: Donish; 2020.
16. Gasanov S.T. Ispol'zovaniye iskusstvennykh neyronov v ekonomicheskoy analize = Using artificial neurons in economic analysis. Dushanbe: Library; 2021.
17. Boboyev A.I. Mashinnoye obucheniye i analiz dannykh v ekonomicheskoy praktike = Machine learning and data analysis in economic practice. Dushanbe: Donish; 2022.
18. Sodikov A.M. Tekhnologii ispol'zovaniya analiza dannykh v ekonomike = Technologies for using data analysis in economics. Dushanbe: Jakhon; 2021.
19. Mukhtorov KH.I. Ispol'zovaniye prakticheskikh modeley v mashinnom obuchenii = Using practical models in machine learning. Dushanbe: Sado; 2019.
20. Fayzulloyev A.M. Rol' mashinnogo obucheniya v otsenke riskov v ekonomike = The Role of Machine Learning in Risk Assessment in the Economy. Dushanbe: Istiklol; 2020.
21. Abdulloyev M.T. Rukovodstvo po ispol'zovaniyu modeley analiza dannykh i mashinnogo obucheniya = Guide to Using Data Analysis and Machine Learning Models. Dushanbe: Manzara; 2021.
22. Dzhurayev M.N. Tsifrovaya analitika i teoriya mashinnogo obucheniya = Digital Analytics and Machine Learning Theory. Dushanbe: Literature; 2022.
23. Kholov R.A. Obuchayushchiyesya mashiny v analize ekonomicheskikh potokov v Tadzhikistane = Learning Machines in the Analysis of Economic Flows in Tajikistan. Dushanbe: Kulol; 2020.
24. Niyozov I.K. Sposoby analiza slozhnykh dannykh v ekonomike i biznese = Methods for Analyzing Complex Data in Economics and Business. Dushanbe: Sharq; 2019.

Сведения об авторе

Александр Юрьевич Чесалов

Общество с ограниченной ответственностью

«Программные системы Атлансис»,

Тверь, Россия

Эл. почта: achesalov@mail.ru

Information about the author

Alexander Y. Chesalov

Atlansis Software Systems Limited Liability

Company,

Tver, Russia

E-mail: achesalov@mail.ru