

СОВРЕМЕННЫЙ ПОДХОД К ПОСТРОЕНИЮ ПРЕДСКАЗАТЕЛЬНЫХ МОДЕЛЕЙ НА ОСНОВЕ ИСТОРИЧЕСКОГО ОПЫТА ЭКСПЛУАТАЦИИ ПРОМЫШЛЕННОГО ОБОРУДОВАНИЯ

A MODERN APPROACH TO BUILDING PREDICTIVE MODELS BASED ON HISTORICAL OPERATING EXPERIENCE OF INDUSTRIAL EQUIPMENT

A. Chesalov

Summary. The digital transformation of industry, the transition to a data economy, and the imperative of technological sovereignty necessitate the development and implementation of intelligent systems for predictive and prescriptive maintenance. Predictive models based on the analysis of accumulated historical operating experience of industrial equipment are becoming a key element of such systems. This article explores a modern approach for creating, training, and operating such models. It discusses a convergent architecture that combines the Industrial Internet of Things, edge artificial intelligence, cloud computing, and cognitive systems. Particular attention is paid to methodological approaches to working with uncertain and contradictory historical data based on the Dempster-Shafer evidence theory, as well as to the prospects for integrating large-scale language models. It is concluded that the synergy of these technologies forms the basis for creating self-learning industrial ecosystems capable of continuously accumulating and leveraging operational experience.

Keywords: predictive maintenance, predictive models, Dempster-Shafer theory.

Чесалов Александр Юрьевич

кандидат технических наук, генеральный директор,
ООО «Программные системы Атлансис», г. Тверь
achesalov@mail.ru

Аннотация. Цифровая трансформация промышленности, переход к экономике данных и императив технологического суверенитета обуславливают необходимость разработки и внедрения интеллектуальных систем прогнозируемого и предписывающего обслуживания. Ключевым элементом таких систем становятся предсказательные модели, основанные на анализе накопленного исторического опыта эксплуатации промышленного оборудования. В статье исследуется современный подход, обеспечивающий создание, обучение и эксплуатацию таких моделей. Рассматривается конвергентная архитектура, объединяющая технологии промышленного Интернета вещей, периферийного искусственного интеллекта, облачных вычислений и когнитивных систем. Особое внимание уделяется методологическим подходам к работе с неопределенными и противоречивыми историческими данными на основе теории свидетельств Демпстера-Шафера, а также к перспективам интеграции больших языковых моделей. Делается вывод о том, что синергия перечисленных технологий формирует основу для создания самообучающихся промышленных экосистем, способных к непрерывному накоплению и использованию операционного опыта.

Ключевые слова: прогнозируемое обслуживание, предсказательные модели, теория Демпстера — Шафера.

Введение

Современный этап развития промышленности характеризуется переходом от стратегий реактивного и профилактического обслуживания к проактивным моделям, основанным на данных. Эффективность прогнозируемого (англ. Predictive Maintenance, PdM) и предписывающего обслуживания (англ. Prescriptive Maintenance) напрямую зависит от способности системы извлекать знания из массива исторических данных, накопленных в ходе эксплуатации оборудования: журналов телеметрии, отчетов о ремонтах, результатов предыдущих диагностик, метаданных об условиях работы. Однако создание надежных предсказательных моделей на этой основе сопряжено с рядом вызовов: высокой неопределенностью и конфликтностью данных от разнородных сенсоров инфраструктуры промышленного Интернета вещей (англ. Industrial Internet of Things, IIoT), необходимостью обработки в режиме, близком к реаль-

ному времени, потребностью в объяснимости и интеграции с устоявшимися производственными системами (например, такими как системой управления производством (MES), системой управления активами предприятия (EAM), системой планирования ресурсами (ERP), системой управления качеством продукции (QMS), компьютеризированной системой управления техническим обслуживанием (CMMS) и другими отраслевыми производственными системами) [1, 2, 3, 4].

Целью исследования является анализ и синтез новых информационных технологий, обеспечивающих полный жизненный цикл создания предсказательных моделей — от сбора и верификации исторического опыта эксплуатации промышленного оборудования до их развертывания и непрерывного обновления в контуре промышленной автоматизации, и предложение концептуальной архитектуры соответствующей промышленной системы.

Современный этап цифровой трансформации промышленности, ассоциируемый с концепцией «Индустрии 4.0», характеризуется повсеместным внедрением киберфизических систем, насыщенных сенсорами и средствами генерации данных [5, 6]. Одной из ключевых задач в этом контексте является переход от реактивного и плано-предупредительного обслуживания к прогнозному и предписывающему. Эффективность таких систем напрямую зависит от качества и полноты используемых предсказательных (прогнозных) моделей.

Традиционно эти модели строятся на основе анализа телеметрии, поступающей непосредственно с контролируемого актива. Однако, как показывает практика, значительная доля отказов и деградационных процессов инициируется или усугубляется комплексным влиянием внешних факторов: колебаний температуры и влажности, вибраций от смежного оборудования, электромагнитных помех, качества сырья и человеческого фактора. Игнорирование этого контекста, а также накопленного исторического опыта эксплуатации аналогичного оборудования в сходных условиях, приводит к снижению точности прогнозов и запоздалому реагированию.

Таким образом, актуальной научно-технической проблемой является разработка новых информационных технологий и архитектур, позволяющих создавать и постоянно совершенствовать предсказательные модели за счет интеграции и анализа «прошлого опыта». Под «опытом» понимается совокупность:

- Исторических временных рядов данных с внутренних датчиков оборудования.
- Архивов записей о воздействии внешних факторов среды.
- Базы данных и знаний об инцидентах, отказах, проведенных ремонтах и их эффективности.
- Исторических данных эксплуатации парка однотипного оборудования.

От анализа данных к использованию опыта

Эволюцию предиктивных систем можно разделить на несколько этапов:

1. Ориентированный на управление данными (англ. Data-driven). В нем фокус делается на сборе и анализе больших объемов данных с оборудования. Применяются классические алгоритмы машинного обучения (случайные леса, метод опорных векторов) и статистические методы для выявления корреляций и построения прогнозов. Тем не менее, при таком подходе, опыт систематизируется слабо, модели часто «забывают» прошлые аномалии после переобучения.
2. Модельно-ориентированный (англ. Model-based). Определяется созданием максимально точных цифровых двойников (англ. digital twins), физи-

ко-математических моделей, отражающих процессы износа и деградации. Модель калибруется на исторических данных, что является формой учета опыта. Однако такие модели очень сложны в разработке и поддержке для уникального оборудования и плохо адаптируются к новым, ранее не наблюдаемым внешним воздействиям.

3. Опытно-ориентированный (англ. Experience-driven). Новая парадигма, где ядром системы является постоянно пополняемая и структурированная «база опыта». Технологии искусственного интеллекта (ИИ) используются не только для анализа текущих данных, но и для извлечения знаний из исторических прецедентов, их обобщения и переноса на новые условия. Ключевыми технологическими компонентами для реализации этого этапа являются:

- Трансферное обучение (англ. Transfer Learning). Позволяет дообучать модели, созданные на данных одного объекта или в одних условиях, для работы с другим аналогичным объектом, значительно экономя время и данные. Это прямой перенос опыта.
- Федеративное обучение (Federated Learning). Дает возможность совместного обучения модели на данных распределенного парка оборудования без передачи «сырых» данных в центральный узел, сохраняя конфиденциальность и накапливая коллективный опыт.
- Нейросетевые архитектуры с памятью. Рекуррентные нейронные сети (англ. Recurrent neural network, RNN), в частности LSTM (англ. Long Short-Term Memory) и GRU (англ. Gated Recurrent Unit), а также сети с механизмами внимания, способны выявлять долгосрочные временные зависимости и «запоминать» контекст, что критически важно для учета последовательности событий, приведших к отказу в прошлом.
- Метаобучение (англ. Meta-Learning) или «обучение обучению». Алгоритмы, способные быстро адаптироваться к новым задачам на основе небольшого количества примеров, используя знания, извлеченные из решения множества предыдущих схожих задач.

Концепция архитектуры самообучающейся промышленной системы

На основе выполненного анализа предлагается многоуровневая архитектура системы прогнозируемого обслуживания и оценки остаточного срока службы промышленного оборудования, реализующей принципы опыт-ориентированного прогнозирования (Рис. 1).

Рассмотрим подробнее каждый из уровней системы:

1. Слой сбора и агрегации данных. Помимо внутренних датчиков оборудования, интегрируют-

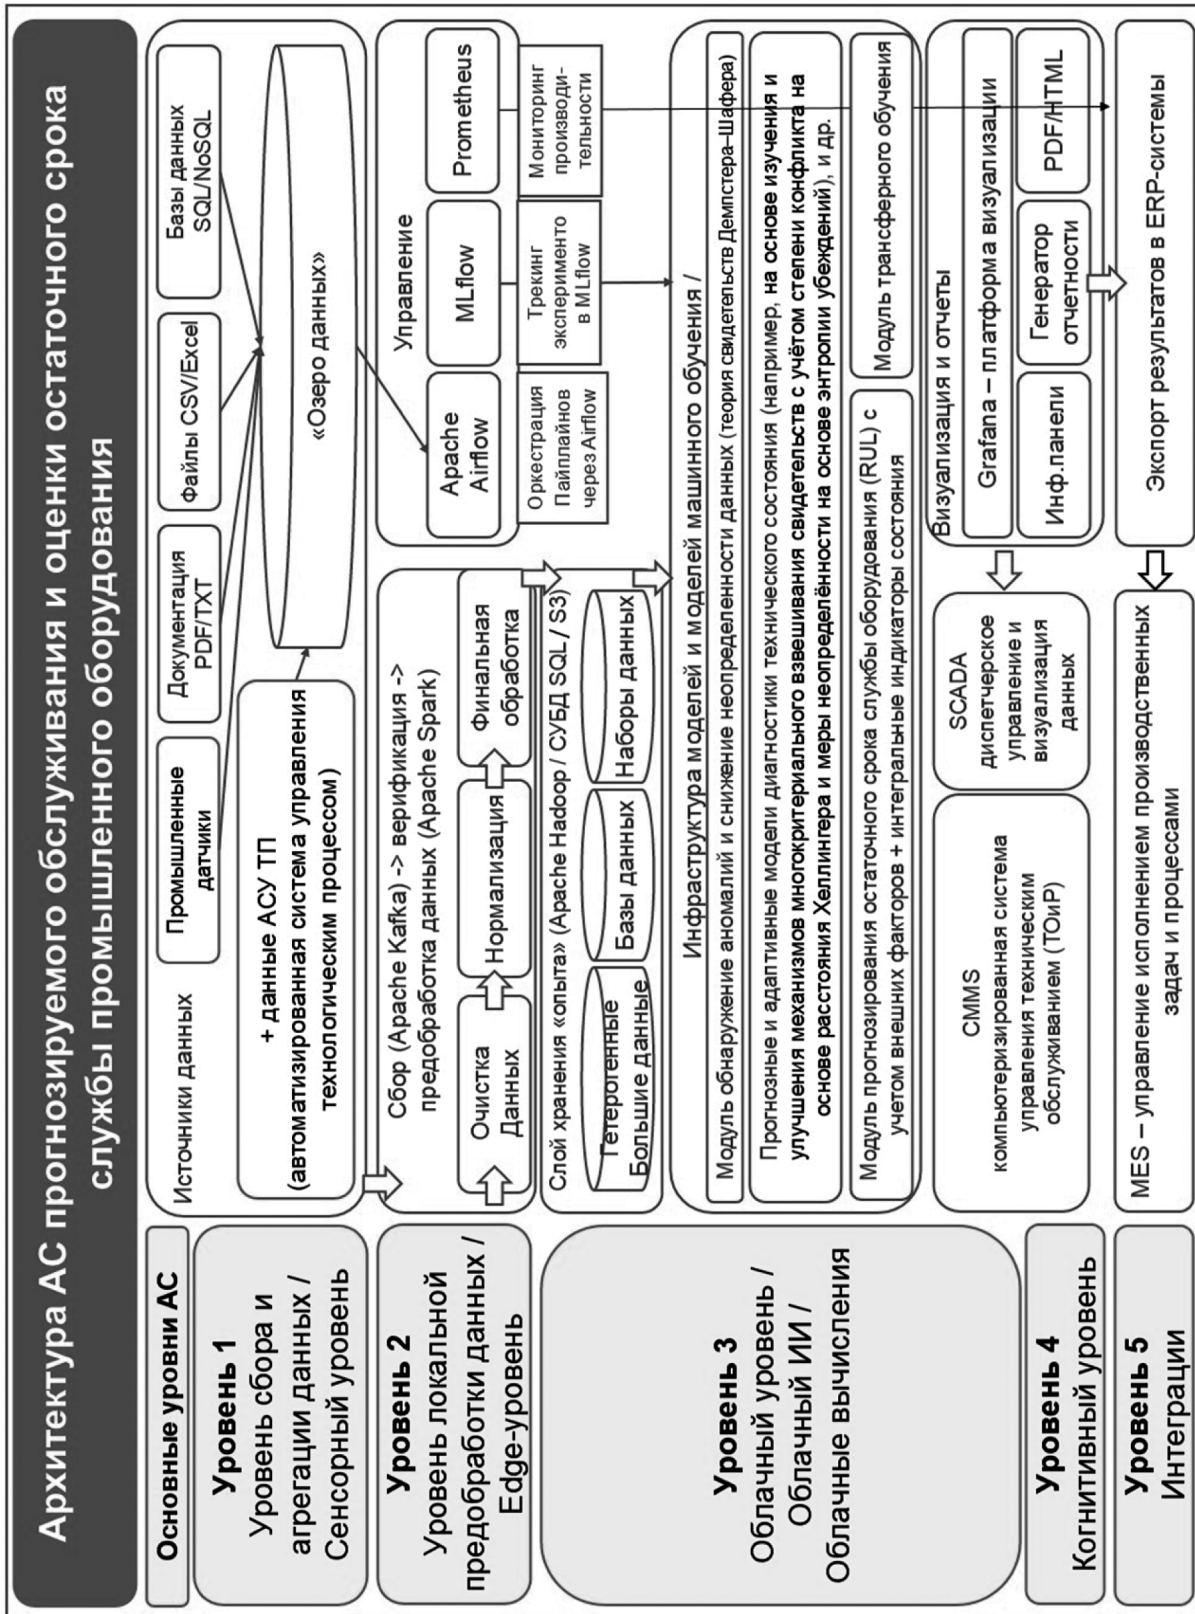


Рис. 1. Архитектура автоматизированной системы прогнозируемого обслуживания и оценки остаточного срока службы промышленного оборудования

ся внешние сенсорные сети (например, микроклимат, вибрация конструкций, данные АСУТП / SCADA-систем смежных процессов). Данные проходят верификацию, нормализацию и синхронизацию во временной шкале.

2. Слой хранения накопленного «опыта». Специализированная база данных или озеро данных, где хранятся не только сырые и очищенные данные, но и размеченные прецеденты (такие как аномалии, отказы, успешные вмешательства и другие), признаки, извлеченные моделями.
3. Слой моделей и анализа (в подсистеме «Инфраструктура моделей и моделей машинного обучения»). Включает ансамбль моделей для:
 - Быстрой детекции аномалий. Легковесные модели (например, автоэнкодеры), работающие в режиме реального времени, задачей которых является выявление значимых отклонений от ожидаемого паттерна («рассогласования»), аналогично нейрофизиологическому феномену MMN (англ. Mismatch Negativity) [7]. Это триггер для углубленного анализа. Прогнозирования отказов и остаточного срока службы оборудования. Комплексные модели (например, LSTM, градиентный бустинг и другие), использующие текущий контекст и извлеченные из слоя хранения накопленного «опыта» схожие исторические прецеденты для оценки вероятности отказа и остаточного ресурса.
 - Модуль трансферного обучения. Отвечает за адаптацию базовых моделей под специфику конкретного экземпляра оборудования на основе его собственной истории эксплуатации.
4. Слой интерпретации и принятия решений. Визуализирует результаты, предоставляет инженеру объяснимые рекомендации на основе технологий объяснимого искусственного интеллекта (англ. Explainable AI, XAI) со ссылками на схожие исторические случаи и предлагает сценарии прогнозируемого / предписывающего обслуживания. Все новые решения и их результаты обратно фиксируются в слое хранения накопленного «опыта», замыкая цикл самообучения автоматизированной системы прогнозируемого обслуживания.

Таким образом, переход к созданию предсказательных моделей, активно использующих прошлый опыт, является закономерным этапом развития интеллектуальных промышленных систем. Это требует интеграции новых информационных технологий: расширенных сетей промышленного Интернета вещей за счет дополнения их решениями на основе периферийного искусственного интеллекта (англ. Edge AI) [8], методов глубокого обучения с памятью и вниманием, парадигм трансферного и федеративного обучения, а также создания специализированных структур данных для хранения и поиска прецедентов.

Согласно данным исследования [9], внедрение Edge AI позволяет обрабатывать локально до 70 % всех данных, генерируемых устройствами промышленного интернета вещей. Такая организация вычислений способствует снижению энергопотребления, связанного с передачей данных, на величину до 40 %. В результате достигается повышение точности прогнозирования отказов оборудования до 97 % при одновременном сокращении продолжительности незапланированных простоев на 65 %.

Предложенная базовая архитектура предполагает эволюцию систем от простых анализаторов данных к самообучающимся киберфизическим системам, способным накапливать, структурировать и эффективно применять коллективный эксплуатационный опыт в рамках инфраструктуры сетевых предприятий [10, 11]. Это открывает путь к существенному повышению точности прогнозов отказов в работе промышленного оборудования, оптимизации жизненного цикла активов и, в конечном итоге, к созданию устойчивых и адаптивных промышленных экосистем.

Методология построения предсказательных моделей на основе исторических данных

В соответствии с представленной архитектурой (Рис. 1), процесс создания предсказательной модели можно представить как многоуровневый конвейер, реализуемый в рамках конвергентной архитектуры интеллектуальной PdM-системы:

1. Сбор и агрегация исторического и оперативного опыта. На сенсорном и периферийном (Edge) уровнях осуществляется сбор данных с датчиков IIoT (например, вибрация, температура, акустика, ток). Современный тренд — оснащение самих датчиков возможностями предобработки и первичного анализа за счет применения Edge AI, что позволяет снизить нагрузку на сеть и выделять значимые признаки непосредственно у источника. Исторические данные из CMMS (такие как текстовые отчеты, руководства) формируют контекстуальный слой, критически важный для понимания причинно-следственных связей.
2. Преодоление неопределенности исторических данных. Качество исторических данных часто неидеально: возможны пропуски, шумы, противоречивые показания от разных сенсоров. Для формализации и снижения такой неопределенности эффективно применяется математический аппарат теории свидетельств Демпстера-Шафера (англ. Dempster-Shafer theory, DST). В отличие от байесовского подхода, DST не требует априорных вероятностей и позволяет явно моделировать незнание. Развитием этого подхода является использование адаптивного взвешивания свиде-

тельств от разных источников на основе комбинированных метрик, например расстояния Хеллингера (оценка конфликта) и энтропии Денга (мера внутренней неопределенности). Это позволяет строить более робастные модели даже на зашумленных и противоречивых исторических данных [12].

3. Обучение и валидация моделей. На облачном уровне исторические данные, прошедшие этап снижения неопределенности, используются для обучения гибридных моделей машинного обучения. Это могут быть:
 - Модели для анализа временных рядов (LSTM, Transformers) — для прогнозирования траектории деградации и оценки остаточного срока службы (англ. Remaining Useful Life) [13].
 - Модели классификации и обнаружения аномалий — для идентификации типовых и нетипичных отказов на основе исторических паттернов.
 - Перспективным направлением является использование больших языковых моделей (англ. Large Language Model, LLM), например, таких как OpenThinker2-32B, для анализа неструктурированного исторического опыта (текстовые отчеты, записи инженеров) и генерации экспертных заключений или даже фрагментов кода для диагностических алгоритмов [14].
4. Эксплуатация и непрерывное обучение. Обученная модель развертывается в рабочем контуре. При этом важнейшим свойством современной системы является способность к непрерывному дообучению на новых оперативных данных, что позволяет адаптироваться к «дрейфу концепта» — изменению поведения оборудования со временем. Технологии MLOps (англ. Machine Learning Operations) способны обеспечить автоматизацию процессов переобучения, тестирования и развертывания новых версий моделей.
5. Интеграция и предоставление рекомендаций. На интеграционном уровне результаты работы моделей (прогнозы, рекомендации) трансформируются в конкретные предписания для систем управления (MES, CMMS) или персонала. Ключевую роль здесь играет объяснимость — способность системы обосновать свой прогноз, что повышает доверие со стороны специалистов.

К наиболее перспективным направлениям развития технологий построению предсказательных моделей на основе исторического опыта относятся:

1. Биоинспирированные алгоритмы, такие как модели, основанные на феномене потенциала негативности рассогласования, способные фоновно обнаруживать неизвестные ранее аномалии, обучаясь только на данных о «нормальном» состоянии.
2. Нейроморфные вычисления для реализации энергоэффективной обработки сенсорных потоков непосредственно на периферии.
3. Квантовые алгоритмы для решения сложных оптимизационных задач при планировании графиков обслуживания на основе многолетнего исторического опыта.
4. Цифровые двойники нового поколения, которые становятся динамическими репозиториями всего исторического опыта жизненного цикла актива, позволяя проводить симуляции и «что-если» анализ для выработки оптимальных предписаний.

Заключение

Создание эффективных предсказательных моделей на основе исторического (накопленного) опыта в современной промышленности перестало быть задачей исключительно в области управления и анализа данных. Это комплексная инженерная проблема, требующая глубоких исследований и синергии новых информационных технологий на всех уровнях: от интеллектуальных сенсоров и алгоритмов работы с неопределенностью до когнитивных систем и методов непрерывной интеграции и поставки моделей машинного обучения. Накопленный исторический опыт эксплуатации превращается в ключевой стратегический актив предприятия. Подходы, рассмотренные в статье, позволяют трансформировать опыт, знания и предписания, формируя основу для перехода к автономным, интеллектуальным производствам и реализации принципов Индустрии 4.0, с перспективой перехода к Индустрии 5.0. Дальнейшие исследования должны быть сфокусированы на повышении уровня автономности таких систем, углублении методов объяснимого ИИ для критических решений и создании стандартизированных отраслевых платформ для обмена анонимизированным историческим опытом в рамках безопасных промышленных экосистем.

ЛИТЕРАТУРА

1. Галкин Д.И., Чесалов А.Ю. Перспективы цифровой трансформации производителей оборудования неразрушающего контроля на примере опыта НИИИИ МНПО «СПЕКТР» // XXIII Всероссийская научно-техническая конференция по неразрушающему контролю и технической диагностике «Умные технологии НК. Единство теории и практики»: сб. тр. Москва, 23–25 октября 2023 г. С. 187–170. — М.: Издательский дом «Спектр», 2023. — С. 167–170.
2. Палюх Б.В., Чесалов А.Ю. Методологический подход к цифровой трансформации предприятий отрасли производителей оборудования неразрушающего контроля // «Инжиниринг предприятий и управление знаниями» (ИП&УЗ — 2023) сборник научных трудов XXVI Российской научной конференции. 29–30 ноября 2023 г. / под науч. ред. д.э.н. Ю.Ф. Тельнова. — Москва: ФГБОУ ВО «РЭУ им. Г.В. Плеханова», 2023. — С. 256–260.
3. Галкин Д.И., Ефимов А.Г., Чесалов А.Ю. Перспективы создания цифровой инфраструктуры данных в НК // Территория NTD — январь-март — 2024. — С. 62–65.
4. Палюх Б.В., Чесалов А.Ю. Современные подходы к созданию автоматизированных систем прогнозируемого обслуживания многостадийных технологических процессов в промышленности. // «Инжиниринг предприятий и управление знаниями» (ИП&УЗ — 2024): сборник научных трудов XXVII Российской научной конференции. 28–29 ноября 2024 г. Том 1. / под науч. ред. д.э.н. Ю.Ф. Тельнова. — Москва: ФГБОУ ВО «РЭУ им. Г.В. Плеханова», 2024. — С. 351–357.
5. Чесалов А.Ю. Применение прорывных технологий искусственного интеллекта в промышленных экосистемах Индустрии 4.0. // Перспективные интеграционные процессы в мировой экономике: нооподход / Сборник материалов IX Санкт-Петербургского международного экономического конгресса (СПЭК-2024) / Под общ. ред. С.Д. Бодрунова. Том 2. — М.: ИНИР им. С.Ю. Витте, 2024. — С. 176–184.
6. Чесалов А.Ю. Перспективы развития автоматизированных систем прогнозируемого обслуживания в промышленности на основе технологий искусственного интеллекта. // «Развитие современной науки и технологий в условиях трансформационных процессов», (2025, Москва): сборник материалов XXXII Международной научно-практической конференции (шифр — МКНТ 32). Москва, 12 июня 2025 г. — Издательство «Знание-М», 2025. — С. 47–55
7. Чесалов А.Ю. Применение искусственного интеллекта для реализации алгоритмов потенциала негативности рассогласования в промышленных автоматизированных системах прогнозируемого обслуживания // Открытое образование. 2025; 29(3): 11–21. <https://doi.org/10.21686/1818-4243-2025-3-11-21>.
8. Чесалов А.Ю. Тенденции развития периферийного искусственного интеллекта в автоматизации технологических процессов // Автоматизация в промышленности. — 2025. — №7. — С. 9–14.
9. Mohammed A. H. Real-time data processing in cloud and edge computing // International Journal of Computer Engineering and Technology (IJCET). 2024. Vol. 15. Issue 6. pp. 1940–1951.
10. Тельнов Ю.Ф., Казаков В.А., Данилов А.В., Денисов А.А. Требования к программной реализации системы Индустрии 4.0 для создания сетевых предприятий // Программные продукты и системы. 2022. Т. 35. № 4. С. 557–571. DOI: 10.15827/0236-235X.140.557-571
11. Тельнов Ю.Ф., Казаков В.А., Данилов А.В., Брызгалов А.А. Разработка моделей производственных и бизнес-процессов сетевых предприятий на основе многоагентных систем // Программные продукты и системы. 2023. №4. С. 632–643. doi: 10.15827/0236-235X.142.632-643
12. Чесалов А.Ю. Математическая модель снижения неопределенности на основе теории свидетельств Демпстера–Шафера на уровне сбора данных в автоматизированных системах прогнозируемого обслуживания // Динамика сложных систем — XXI век. — 2025. Т. 19. № 4. С. 62–74. DOI: 10.18127/j19997493-202504-07.
13. Fuhui Wu, Qingbo Wu, Yusong Tan, Xinghua Xu. Remaining Useful Life Prediction Based on Deep Learning: A Survey. [Электронный ресурс]. www.mdpi.com — URL: <https://www.mdpi.com/1424-8220/24/11/3454> (дата обращения: 02.04.2025).
14. Чесалов А.Ю. Анализ возможности применения модели OpenThinker2-32B в автоматизированных системах прогнозируемого обслуживания для малых и средних промышленных предприятий // Нейрокомпьютеры: разработка, применение. — 2025. Т. 27. № 5. С. 56–70. DOI: <https://doi.org/10.18127/j19998554-202505-07>.

© Чесалов Александр Юрьевич (achesalov@mail.ru)

Журнал «Современная наука: актуальные проблемы теории и практики»