

ЭКОНОМИКА, УПРАВЛЕНИЕ И РЫНОК ПРОДУКЦИИ

ECONOMICS, MANAGEMENT AND PRODUCT MARKET

ISSN 1995-2732 (Print), 2412-9003 (Online)
УДК 669.1:004.9
DOI: 10.18503/1995-2732-2025-23-3-187-194



АКТУАЛЬНЫЕ ПРОБЛЕМЫ РАЗВИТИЯ ПРЕДИКТИВНОЙ АНАЛИТИКИ В ПРОМЫШЛЕННОСТИ

Ершов А.Н.

ООО «Объединенная сервисная компания», группа ПАО «ММК», Магнитогорск, Россия

Аннотация. В статье рассматриваются актуальные проблемы развития предиктивной аналитики на предприятиях промышленности с учетом специфики и возможностей внедрения в Российской Федерации. Ключевым вызовом является необходимость сбора и обработки огромных массивов достоверных данных при минимальной нагрузке на вычислительную инфраструктуру. В качестве альтернативы полностью облачным решениям предлагается использование альтернативного построения архитектуры технических решений. В статье рассматриваются туманные и edge-вычисления, которые позволяют обрабатывать данные ближе к их источнику, снижая задержки и затраты. На основе практического опыта выделен комплекс проблем, сдерживающих развитие предиктивной аналитики в России: отсутствие системного подхода к внедрению, завышенные ожидания от готовых решений, неготовность предприятий к масштабной цифровой трансформации, сложности с обменом данными и использованием облачных решений. В заключение предлагаются пути решения, включая унификацию подходов к разработке устройств на «нижнем уровне» и протоколов передачи данных, стратегическое партнерство промышленных предприятий, а также создание обезличенных банков промышленных данных при государственной поддержке для совместной разработки и совершенствования прогнозных моделей.

Ключевые слова: предиктивная аналитика промышленного оборудования, интернет вещей (IoT), анализ больших данных, алгоритмы прогнозирования, туманные и edge-вычисления, искусственный интеллект, машинное обучение, предиктивное техническое обслуживание (PdM), промышленность 4.0, киберфизические системы, сбор данных, достоверность данных, аномалии данных, обработка данных, прогнозная модель, математическое моделирование, цифровая трансформация, отечественные разработки, системный подход, банки промышленных данных

© Ершов А.Н., 2025

Для цитирования

Ершов А.Н. Актуальные проблемы развития предиктивной аналитики в промышленности // Вестник Магнитогорского государственного технического университета им. Г.И. Носова. 2025. Т. 23. №3. С. 187-194. <https://doi.org/10.18503/1995-2732-2025-23-3-187-194>



Контент доступен под лицензией Creative Commons Attribution 4.0 License.
The content is available under Creative Commons Attribution 4.0 License.

CURRENT ISSUES IN THE DEVELOPMENT OF PREDICTIVE ANALYTICS IN INDUSTRY

Ershov A.N.

United Service Company LLC, part of PJSC "MMK" Group, Magnitogorsk, Russia

Abstract. The article examines current challenges in the development of predictive analytics at industrial enterprises, considering the specificities and implementation possibilities within the Russian Federation. A key challenge is the necessity to collect and process vast amounts of reliable data with minimal load on the computational infrastructure. As an alternative to purely cloud-native solutions the use of alternative technical solutions architecture is proposed. The article discusses fog and edge computing which enable data processing closer to its source reducing latency and costs. Based on practical experience a set of problems hindering the development of predictive analytics in Russia is highlighted: the lack of a systematic approach to implementation, inflated expectations from ready-made solutions, unpreparedness of enterprises for large-scale digital transformation, and difficulties with data exchange and the use of cloud solutions. In conclusion, solutions are proposed, including the standardization of approaches to developing low level devices and data transmission protocols, strategic partnerships between industrial enterprises, and the creation of anonymized industrial data banks with state support for the joint development and refinement of predictive models.

Keywords: predictive analytics of industrial equipment, Internet of Things (IoT), big data analysis, forecasting algorithms, fog and edge computing, artificial intelligence, machine learning, predictive maintenance (PdM), Industry 4.0, cyber-physical systems, data collection, data reliability, data anomalies, data processing, predictive model, mathematical modeling, digital transformation, domestic development, systematic approach, industrial data banks.

For citation

Ershov A.N. Current Issues in the Development of Predictive Analytics in Industry. *Vestnik Magnitogorskogo Gosudarstvennogo Tekhnicheskogo Universiteta im. G.I. Nosova* [Vestnik of Nosov Magnitogorsk State Technical University]. 2025, vol. 23, no. 3, pp. 187-194. <https://doi.org/10.18503/1995-2732-2025-23-3-187-194>

Развитие интернета вещей и предиктивной аналитики

Развитие интернета вещей (Internet Of Things – IoT) и киберфизических систем представляет собой основу для возникновения сценария Индустрии 4.0 [1-3]. Эти технологии закладывают основу для реализации концепции интеллектуального производства. Реальным примером интеллектуализации с применением этих технологий является предиктивное обслуживание промышленного технологического оборудования (Predictive Maintenance – PdM), целью которого является заблаговременное предсказание возможных отказов, инцидентов или аварий на технологическом оборудовании и последующее устранение причин зарождения дефектов, приводящих к отказам [1, 3].

До последнего времени в промышленности производилось плановое техническое обслуживание оборудования по утвержденным графикам. Серьезным недостатком такого подхода является то, что регулярный ремонт без видимой причины может оказаться избыточным, в то же время регулярный ремонт не всегда гарантирует того, что агрегат не выйдет из строя и после вовремя проведенного планового обслуживания. Причиной может быть как использованные в процессе ремонта некачественные запасные детали (тендерные процедуры нацелены на низкую стоимость, а не качество), так и неудовлетворительно проведенная работа по причине отсутствия достаточ-

ного контроля и квалификации обслуживающего и восстанавливающего персонала. К этому нужно прибавить вынужденную необходимость простоя производственных линий на время планового обслуживания [3].

Вместе с тем сбор информации с большого количества датчиков, установленных на узлах оборудования и измеряющих различные параметры (температура, давление, проток, расход, вибрация, сопротивление изоляции и т.д.), и дальнейшая обработка этой информации позволяют формировать точный график выхода из строя отдельных узлов оборудования [3, 4]. Применение искусственного интеллекта при обработке информации с датчиков, а также различных данных об оборудовании (например, записи журналов о поломках на производственной линии) способно повысить точность рекомендаций, выдаваемых системами предиктивной аналитики. Предиктивный подход к обслуживанию и ремонту основного промышленного технологического оборудования может повысить эффективность производства [3-7].

Основная идея PdM заключается в экстраполяции знаний для определения оставшегося полезного срока службы компонентов промышленного оборудования (остаточного ресурса) [3-6]. Большинство современных подходов машинного обучения для PdM используют различные данные мониторинга состояния (например, вибрацию, давление, температуру и т.д.) и

данные о сбоях для прогнозирования оставшегося полезного срока службы [8, 9]. Однако признаки износа компонентов не всегда легко идентифицировать и проследить в зависимости от производственных циклов, нагрузок, сортамента, человеческого фактора и условий эксплуатации [8].

Таким образом, открытыми проблемами являются трудности с получением данных с маркировкой качества и их интерпретацией. Доступные данные не имеют аннотаций, содержат пропущенные значения, плохо структурированы, собираются и хранятся в различных системах и базах данных, которые не связаны между собой. Этот факт приводит к высокой потребности в наличии огромного количества аннотированных наборов данных, связанных со сбоями. Процедура аннотации – это проблема, которая до сих пор остается открытой и представляет собой ключевую проблему для разработки подходов ML (Machine Learning – машинное обучение) или глубокого обучения (Deep Learning – DL) для точного решения задачи PdM [3].

Проблемы сбора и обработки промышленных данных в предиктивной аналитике

В предиктивной аналитике можно выделить несколько основных параметров, особенно важных для создания качественных моделей прогнозирования: частота сбора данных, их ценность, достоверность, объем и разнообразие. Важность частоты сбора данных обусловлена тем, что узлы агрегатов промышленного оборудования зачастую совершают перемещения с высокой частотой, при этом необходимо отслеживать их состояние в режиме реального времени. Данные должны обладать определенной ценностью, нет смысла отслеживать те показатели, которые никогда не влияют на работоспособность узлов.

Одной из основных проблем предиктивной аналитики является вопрос достоверности собираемых данных. Так как на установленные датчики воздействует агрессивная среда, необходимо быть полностью уверенным в том, что воздействие любых параметров конкретной среды не влияет на достоверность данных. Для выявления таких данных требуется применение алгоритмов контроля с применением математических операций, позволяющих исключать так называемые «выбросы», не используемые в массиве для определения текущего показания, поступающего от измерительного модуля. Так как помимо высокой частоты сбора данных требуется непрерывный мониторинг состояния оборудования, объемы собираемых данных могут быть очень большими. Естественно, нельзя не отметить важность разнообразия собираемых данных, это должны быть данные с различных узлов оборудования, а также данные различных отслеживаемых параметров [3, 7]. Чем больше данных собирается, тем выше точность выдаваемого прогноза о развивающемся дефекте. Чем раньше система позволит выявить аномалию или изменение данных, да-

же с незначительным изменением во времени, но имеющую нарастающую или убывающую составляющую, тем раньше будет зафиксирована точка начала развития дефекта и тем больше времени для подготовки к устранению или недопущению отказа оборудования будет у персонала.

Важной задачей в обработке данных для предиктивной аналитики является верное обнаружение аномалий в данных. Аномальными считаются данные с такими значениями, которые сильно отличаются от ожидаемых. Получение аномалий в данных может быть связано с ошибками в системе сбора данных, например при неисправной работе датчика на оборудовании, сбоях при передаче данных из датчика в систему и т.д. Но не всегда аномальные данные несут ложную информацию о работе оборудования, они могут, наоборот, возникать при сбоях производственной линии или предвещать зарождение нового дефекта, еще незнакомого используемым системам диагностики и предиктивного анализа. Именно поэтому требуется разграничивать эти два типа аномалий в данных. Также аномалии в данных могут быть точечными, когда выпадает одна или несколько точек в данных, и коллективными, когда определенное количество точек являются аномальными подряд. Обработка аномальных данных может производиться централизованно (вычислительный процесс осуществляется на одном и том же оборудовании) либо в несколько этапов на различном оборудовании (например, эта обработка данных может проводиться в облаке) [3].

Поскольку существуют разные типы аномалий и они могут быть обусловлены несколькими факторами, корректнее использовать данные не от одного датчика, а сразу от нескольких и учитывать корреляцию между ними. Применение ИИ также может быть оправдано для поиска аномалий, так как позволяет обрабатывать многомерные данные и извлекать скрытые связи между данными в сложных системах. Могут использоваться как временные, так и пространственные корреляции. Учет корреляций может использоваться вместе с другими методами, такими как экспоненциальное скользящее среднее (EMA), или нечеткие методы. Помимо использования данных о корреляции могут применяться кластерные методы, такие как нечеткая кластеризация, пространственная кластеризация приложений с шумом на основе плотности (DBSCAN), анализ главных компонентов (PCA) или алгоритм сбалансированного итеративного сокращения и кластеризации с использованием иерархий (BIRCH) [3].

Рассмотрев ключевые проблемы сбора и обработки промышленных данных, важно понимать, как эти данные используются для прогнозирования состояния оборудования. Качество и достоверность собранных данных напрямую влияют на эффективность применяемых методов прогнозирования. В предиктивной аналитике используется широкий спектр подходов, от традиционных статистических методов до современ-

ных алгоритмов машинного обучения. Каждый из этих методов имеет свои преимущества и ограничения, которые необходимо учитывать при выборе оптимального подхода для конкретной задачи прогнозирования. Рассмотрим основные методы прогнозирования, применяемые в предиктивной аналитике, и их особенности в контексте обработки промышленных данных.

Методы прогнозирования, применяемые в предиктивной аналитике

Методы прогнозирования, применяемые в предиктивной аналитике, представлены на **рисунке**.

Методы, основанные на знаниях. Эти методы можно разделить на три категории:

- методы, основанные на прецедентах. В идеальных случаях в учетных системах предприятия должны быть записаны различные варианты внештатных ситуаций и методы их решения. Каждый раз, когда возникает определенная внештатная ситуация, модель предлагает решение проблемы, принятое в предыдущих таких же ситуациях. Как правило, такие методы используются в совокупности с другими, так как экспертные знания зависят от квалификации эксперта. Конечно же, такая база знаний достаточно тяжело нарабатывается и документируется. Вместе с тем, когда эти данные существуют, их целесообразно применять для развития методов, основанных на анализе данных;

- методы, основанные на правилах. Модели, применяющие эти методы, предполагают перевод экспертных знаний в форму правил с логикой «ЕСЛИ-ТО». Эти правила собираются экспертами и сохраняются в базах знаний, которые при необходимости можно использовать для определения причин неисправности оборудования или его остановки;

- методы с нечеткой логикой. Модели, использующие эти методы, похожи на методы, основанные на

правилах, но в данном случае утверждения могут принимать непрерывные значения. Например, в качестве утверждений может быть представлен остаточный ресурс узла оборудования в процентах или в днях безаварийной работы, что удобно как для понимания ситуации с оборудованием, так и для предшествующей ей оценки ситуаций экспертами, особенно если применяется экспертная оценка сразу нескольких специалистов для комплекса технологического оборудования. Эти методы, как и методы, основанные на правилах, также могут применяться в совокупности с другими методами [3].

Методы, основанные на моделировании физических процессов. Эти методы используют математические модели для описания физических процессов, которые прямо или косвенно влияют на состояние оборудования. Эти модели часто применяются к механическим и структурным компонентам оборудования, поскольку существует множество физических моделей для описания процессов, связанных с деградацией материалов и компонентов. Эти подходы, как и модели, основанные на знаниях, являются специфичными для предметной области и требуют глубоких знаний как прикладной физики, так и математики, что является дорогостоящим, отнимает много времени, а необходимые знания часто недостаточны для большинства компонентов.

Методы, основанные на данных. Эти методы используют то огромное количество информации, которое собирается с различных датчиков, установленных на оборудовании и на производстве в целом. Методы, основанные на данных, могут применяться как сами по себе, но извлечение необходимых сведений из этой информации позволяет также расширить применение других вышеперечисленных методов. Подходы, основанные на данных, как и подходы к обнаружению аномалий, можно разделить на два разных типа: статистические методы и машинное обучение [3, 6].




Рисунок. Методы прогнозирования, применяемые в предиктивной аналитике [3]

Figure. Forecasting methods used in predictive analytics [3]

Именно мультимодальные подходы зачастую лучше подходят для решения сложных и комплексных задач, возникающих в современной промышленности. Например, экспертные знания о работе установки могут сочетаться со статистическими методами. Методы машинного обучения могут применяться для повышения точности физической модели, применяемой на производстве. В литературе существует несколько статистических моделей и методов, применяемых к PdM, а именно скрытые модели Маркова (HMM), модель винеровского процесса (WPM), модель гамма-процесса, модель пропорциональных рисков, авторегрессионная модель, модели скользящего среднего (ARMA) и др. Методы машинного обучения включают в себя ИНС и ее варианты, машины опорных векторов (SVM), случайные леса (RF), xGBoost, самоорганизующуюся карту (SOM) и др. [3].

Несмотря на то, что методы предиктивной аналитики развиваются, существует ряд нерешенных проблем. Зачастую модели создаются для конкретных деталей или оборудования, что не позволяет масштабировать применение созданной модели. При этом не всегда учитывается влияние изучаемой деградации одних деталей на другие узлы оборудования. Экспертные знания могут быть накоплены в большем количестве для определенных компонентов, при этом для других компонентов информации может не хватать. Данные для моделей машинного обучения могут быть синтетическими, но эффективность модели при этом может оказаться ниже, чем у модели, обученной на реальных промышленных данных. Разработчикам проще разрабатывать несложные модели для отдельных компонентов, чем сложные для больших установок и целых производственных линий. Методы машинного обучения способны представлять весьма гетерогенные и нелинейные модели, но для обучения моделей им необходимы большие объемы данных, а также высокие вычислительные мощности. Выборка данных для обучения может оказаться не совсем полной, что приведет к невозможности прогнозирования редких видов отказов оборудования, так как для этого не было обучающих данных. Также разработанные модели деградации узлов оборудования могут занижать оставшийся ресурс анализируемых агрегатов, что может привести к более раннему выводу оборудования в ремонт при отсутствии необходимости [3, 10, 11].

Вопросы архитектуры

Растущая сложность в развитии промышленных процессов и необходимость иметь дело с большими объемами разнородных данных мотивировали необходимость разработки технологий и архитектур для решения этих проблем в контексте предиктивной аналитики [12]. Разработанные подходы с течением времени претерпели несколько модификаций и изменений [13-15]. Первыми предложенными архитектурами были централизованные облачные подходы.

Обычно они используют вычислительные возможности централизованного облачного сервера для решения таких задач, как обработка данных, прогнозирование обучения или обнаружение аномалий, в то время как периферийные устройства отвечают только за сбор данных (модули мониторинга с датчиками/измерителями на оборудовании) и передачу данных в облако. Чем больше производство, тем больше требуется сенсорных датчиков, объем передаваемых на облако и обрабатываемых там данных растет. При этом от облачной инфраструктуры ожидается, что данные будут передаваться и обрабатываться без большой задержки и с высокой надежностью. К сожалению, это не всегда выполняется, к тому же стоимость работы с данными в облаке может быть высокой при больших объемах данных. По этим причинам большое внимание профильных специалистов привлекают децентрализованные подходы, где используются так называемые туманные вычисления.

Термин «туманные вычисления» появился по аналогии с облачными вычислениями и означает, что инфраструктура туманных вычислений ближе к пользователю, чем инфраструктура облачных (так как туман ближе к земле, чем облака). Применение туманных вычислений не означает, что облако теперь совсем не используется. Основное отличие заключается в том, что между периферийными устройствами и облаком появляется некоторое количество дополнительных слоев (небольших центров обработки данных, расположенных рядом с пользователем). В этих слоях происходит обработка данных в режиме реального времени и без задержек и сбоев, которые могут быть в облаке (задержки и сбои могут быть и при работе туманных центров обработки данных, но предполагается, что вероятность их возникновения ниже). Вычисления, где задержка передачи данных не так важна, или какие-либо сложные вычисления, для которых требуется продвинутая инфраструктура, могут по-прежнему выполняться в облаке.

Сложности в развитии отечественной предиктивной аналитики, выявленные на практике

В России, к сожалению, бизнес практически не готов к крупным инвестициям в значимые НИОКРы в области PdM (даже в зрелые стартапы), но при этом ждет готовых цифровых продуктов. Государство предоставляет определенные субсидии на развитие различного программного обеспечения, но зачастую это просто «капля в море», ведь на создание зрелого и сложного продукта нужны крупные финансы, требующиеся не только на стадии разработки, но еще более на стадии доработки решения под требования потенциальных заказчиков, выхода на продажи и организации производства. Таким образом, на рынке формируется «зоопарк» сырых локальных решений, неспособных запустить системное развитие сквозных технологий. Существенным препятствием для развития

отечественной предиктивной аналитики является недостаточная готовность предприятий к внедрению соответствующих систем. Данная проблема проявляется в следующих аспектах:

- отсутствие четких требований к системе PdM и как она будет использоваться в бизнес-процессах ТОиР (техническое обслуживание и ремонт). Разные требования к системе на уровне разных специалистов на одном предприятии – нет консенсуса по одному и тому же вопросу, нет одного окна для решения всех вопросов, нет четких правил реализации подходов;

- завышенные ожидания, что система PdM решит все вопросы без усилий и участия со стороны специалистов Заказчика и ответственность будет перенесена на «программы/роботов» или системы, которые создаются в помощь, а не с целью заменить экспертов;

- нет понимания того, что система PdM – это не коробочное решение, а динамичная технология, которая требует постоянного развития, обучения, настройки под конкретную задачу или объект;

- пилотные версии программного обеспечения для Заказчика выпускаются ради пилотов. Даже успешные пилоты не имеют продолжения, так как не находят своего потребителя у Заказчика. Не редки ситуации, когда пилот в одной дочерней компании не имеет никакого значения для другого предприятия этой же группы компаний;

- зачастую ключевым критерием являются специальные технические требования, а не функциональность и стоимость. Например, одним нужен LoRaWAN, у других Nb-IoT/GSM, у третьих Zeegee и т.д. Нет понимания общей картины, есть заикленность на деталях. При этом нет совокупной оценки конечной стоимости реализации и владения при тиражировании на все предприятие;

- мнимая критичность некритичных данных. Невозможность получения данных от Заказчика о работе агрегата для настройки системы даже на пилотных проектах – только разворачивание системы на сервере предприятия. Существенные проблемы при передаче данных «за забор»;

- необходимость на старте проекта соответствовать утвержденной архитектуре построения ИТ-решений, которые кратно увеличивают затраты на вход в промышленные предприятия;

- нежелание специалистов, ответственных за текущую диагностику оборудования, включаться в процессы доработки отечественных решений. Необходимо сразу готовое и прекрасно функционирующее;

- завышенные требования к количеству разработанных алгоритмов определения дефектов на борту систем PdM.

Из описанных пунктов видно, что отсутствует системный подход к внедрению систем предиктивной аналитики. А именно системность подхода и дает максимальную эффективность, когда все детали проекта складываются словно из пазла в одну общую

картину. Каким образом происходит разворачивание системы предиктивной аналитики в зарубежных успешных примерах внедрения? Основные шаги:

1. Разрабатывается инженерный проект. Идет обследование площадки и создание инженерного проекта с выработкой архитектуры.

2. Осуществляется дооснащение систем нижнего уровня. Проводится обвязка оборудования необходимыми датчиками и установка систем диагностики и анализа данных.

3. Начинается сбор и накопление данных. Организуется хранение массива исторических данных с полевых систем.

4. Создается математическая модель процессов, а на ее основе разворачивание диагностического аппарата с выдачей прогнозов на основе экспертного мнения.

5. Только после этого идет внедрение ML (машинного обучения). Несмотря на все разговоры о том, что машинное обучение якобы может решить любые проблемы, создание автоматизированного прогностического сервиса с машинным обучением происходит только после того, как уже налажена основная система предиктивной аналитики и имеются готовые математические модели для оценки состояния оборудования. Машинное обучение в этом случае гармонично дополняет созданную математическую модель и выявляет новые закономерности в правильно собранных качественных данных.

6. Идет работа предписывающего сервиса в штатном режиме. Происходит создание единого пространства оперативного контура планирования и реализации сервисных стратегий.

Некоторые проблемы развития систем предиктивной аналитики в России могут решиться достаточно просто – необходима унификация производимых модулей мониторинга и датчиков для предиктивной аналитики. Единые протоколы передачи данных и единые принципы построения баз данных и способов их обработки позволят в будущем объединить накопленные данные различных предприятий для построения более качественных моделей для снижения простоев оборудования. Стратегическое партнерство промышленных предприятий позволит также сформировать общий заказ на создание серии требуемых датчиков. В этом случае датчики будут стоить кратно дешевле, так как производственные партии будут крупными, а затраты на сервис будут также снижены за счет типизации модулей. Другие проблемы, такие как визуализация и формирование предписывающих рекомендаций, требуют непосредственного вовлечения линейного персонала, что иногда также требует значительного внимания руководства, особенно на первых шагах в построении таких систем.

Заключение

Предиктивная аналитика развивается стремительными темпами, несмотря на возникающие при

этом сложности. Одной из ключевых проблем является сложность грамотного сбора данных для предиктивной аналитики, борьба с недостоверными данными и различными аномалиями. Предварительная обработка данных позволяет довести данные до необходимого уровня их качества. Несмотря на то, что существуют различные методы прогнозирования, у всех них есть недостатки, заключающиеся в создании моделей для конкретных деталей или оборудования (особенно в замкнутых в рамках одного предприятия системах), что не позволяет масштабировать применение созданной модели. Также остается проблема, связанная с необходимостью накопления огромного количества данных и их обработки на дорогостоящей вычислительной инфраструктуре.

Как альтернатива облачным вычислениям, возникает возможность применения туманных вычислений, когда между периферийными устройствами и облаком существуют небольшие центры обработки данных, расположенные рядом с пользователем. В этих вычислительных центрах происходит обработка данных в режиме реального времени и без задержек и сбоев, которые могут быть в облаке. В России на данный момент рынок предиктивной аналитики находится на ранней стадии развития, нет как крупных частных инвестиций, так и всесторонней государственной поддержки, как это происходит в Китае. Также нет и отечественных лидеров, которые могли бы формировать заказы на написание определенных моделей, которые требуются для предприятий.

Для развития отечественной предиктивной аналитики требуется системный подход, как в области развития физической инфраструктуры для сбора данных – необходимых датчиков, устанавливаемых на оборудование, так и работы с заказчиками и их консолидации. Кроме того, актуальной проблемой является необходимость создания банков промышленных данных (с государственным участием), куда предприятия будут отдавать в обезличенном виде данные для разработки моделей предиктивной аналитики и откуда смогут сами получать эти данные без рисков для развития своего бизнеса.

Список источников

- From knowledge-based to big data analytic model: a novel IoT and machine learning based decision support system for predictive maintenance in Industry 4.0 / Rosati R. et al. // *Journal of Intelligent Manufacturing*. 2023, vol. 34, no. 1, pp. 107-121.
- Machine learning and deep learning based methods toward industry 4.0 predictive maintenance in induction motors: State of the art survey / Drakaki M. et al. // *Journal of Industrial Engineering and Management (JIEM)*. 2022, vol. 15, no. 1, pp. 31-57.
- Nunes P., Santos J., Rocha E. Challenges in predictive maintenance—A review // *CIRP Journal of Manufacturing Science and Technology*. 2023, vol. 40, pp. 53-67.
- Implementation of predictive models in industrial machines with proposed automatic adaptation algorithm / Kuric I. et al. // *Applied Sciences*. 2022, vol. 12, no. 4, p. 1853.
- Duan L., Da Xu L. Data analytics in industry 4.0: A survey // *Information Systems Frontiers*. 2021, pp. 1-17.
- Advanced predictive analytics for control of industrial automation process / Bhogaraju S.D. et al. // *Innovations in the Industrial Internet of Things (IIoT) and Smart Factory*. IGI Global, 2021. Pp. 33-49.
- Predictive maintenance in the Industry 4.0: A systematic literature review / Zonta T. et al. // *Computers & Industrial Engineering*. 2020, vol. 150, pp. 106889.
- Digital transformation in smart manufacturing with industrial robot through predictive data analysis / Kumar M. et al. // *Machine Learning for Robotics Applications*. 2021, pp. 85-105.
- Machine learning for predictive and prescriptive analytics of operational data in smart manufacturing / Lepenioti K. et al. // *Advanced Information Systems Engineering Workshops: CAiSE 2020 International Workshops*, Grenoble, France, June 8–12, 2020, Proceedings 32. Springer International Publishing, 2020. Pp. 5-16.
- Heterogeneous bi-directional recurrent neural network combining fusion health indicator for predictive analytics of rotating machinery / Chang Y. et al. // *ISA transactions*. 2022, vol. 122, pp. 409-423.
- A survey on data-driven predictive maintenance for the railway industry / Davari N. et al. // *Sensors*. 2021, vol. 21, no. 17, p. 5739.
- Industrial artificial intelligence in industry 4.0-systematic review, challenges and outlook / Peres R. S. et al. // *IEEE access*. 2020, vol. 8, pp. 220121-220139.
- Sahal R., Breslin J. G., Ali M. I. Big data and stream processing platforms for Industry 4.0 requirements mapping for a predictive maintenance use case // *Journal of manufacturing systems*. 2020, vol. 54, pp. 138-151.
- On predictive maintenance in industry 4.0: Overview, models, and challenges / Achouch M. et al. // *Applied Sciences*. 2022, vol. 12, vol. 16, p. 8081.
- Sang G. M., Xu L., de Vrieze P. A predictive maintenance model for flexible manufacturing in the context of industry 4.0 // *Frontiers in big Data*. 2021, vol. 4, p. 663466.

References

- Rosati R. et al. From knowledge-based to big data analytic model: a novel IoT and machine learning based decision support system for predictive maintenance in Industry 4.0. *Journal of Intelligent Manufacturing*. 2023;34(1):107-121.
- Drakaki M. et al. Machine learning and deep learning based methods toward industry 4.0 predictive maintenance in induction motors: State of the art survey. *Journal of Industrial Engineering and Management (JIEM)*. 2022;15(1):31-57.
- Nunes P., Santos J., Rocha E. Challenges in predictive maintenance—A review. *CIRP Journal of Manufacturing Science and Technology*. 2023;40:53-67.
- Kuric I. et al. Implementation of predictive models in industrial machines with proposed automatic adaptation algorithm. *Applied Sciences*. 2022;12(4):1853.
- Duan L., Da Xu L. Data analytics in industry 4.0: A survey. *Information Systems Frontiers*. 2021;1-17.

6. Bhogaraju S.D. et al. Advanced predictive analytics for control of industrial automation process. Innovations in the Industrial Internet of Things (IIoT) and Smart Factory. IGI Global. 2021;33-49.
7. Zonta T. et al. Predictive maintenance in the Industry 4.0: A systematic literature review. Computers & Industrial Engineering. 2020;150:106889.
8. Kumar M. et al. Digital transformation in smart manufacturing with industrial robot through predictive data analysis. Machine Learning for Robotics Applications. 2021;85-105.
9. Lepenioti K. et al. Machine learning for predictive and prescriptive analytics of operational data in smart manufacturing. Advanced Information Systems Engineering Workshops: CAiSE 2020 International Workshops. 2020;5-16.
10. Chang Y. et al. Heterogeneous bi-directional recurrent neural network combining fusion health indicator for predictive analytics of rotating machinery. ISA transactions. 2022;122:409-423.
11. Davari N. et al. A survey on data-driven predictive maintenance for the railway industry. Sensors. 2021;21(17):5739.
12. Peres R.S. et al. Industrial artificial intelligence in industry 4.0-systematic review, challenges and outlook. IEEE access. 2020;8:220121-220139.
13. Sahal R., Breslin J.G., Ali M.I. Big data and stream processing platforms for Industry 4.0 requirements mapping for a predictive maintenance use case. Journal of manufacturing systems. 2020;54:138-151.
14. Achouch M. et al. On predictive maintenance in industry 4.0: Overview, models, and challenges. Applied Sciences. 2022;12,16:8081.
15. Sang G.M., Xu L., de Vrieze P. A predictive maintenance model for flexible manufacturing in the context of industry 4.0. Frontiers in big Data. 2021;4:663466.

Поступила 10.04.2025; принята к публикации 26.08.2025; опубликована 30.09.2025
Submitted 10/04/2025; revised 26/08/2025; published 30/09/2025

Ершов Андрей Николаевич – кандидат экономических наук,
руководитель Центра предиктивного анализа и искусственного интеллекта,
ООО «Объединенная сервисная компания», группа ПАО «ММК», г. Магнитогорск, Россия.

Andrey N. Ershov – PhD (Eng.), Head of the Center for predictive analysis and artificial intelligence,
United Service Company LLC, part of PJSC “ММК” Group, Magnitogorsk, Russia.