



Внедрять нельзя игнорировать: дилемма предиктивной диагностики на производстве

Николай Лунцев, технический директор ООО «СЦР»

Развитие информационных технологий стало катализатором четвёртой промышленной революции. По оценке Клауса Шваба, основателя Всемирного экономического форума в Давосе, её отличительная черта – экспоненциальный, а не линейный темп развития. Тем не менее системы предиктивной диагностики, являющиеся частью этой концепции, пока не получили широкого распространения на промышленных предприятиях. Возникает вопрос: что препятствует их внедрению и почему ожидания от их использования часто не оправдываются? В статье обобщён опыт внедрения таких систем на предприятиях РФ – материал будет полезен техническим руководителям промышленных компаний.

Введение

Наша команда имеет значительный опыт внедрения систем предиктивной диагностики на промышленных предприятиях с использованием собственного программного комплекса – СППР Sdisol PAD (включён в Единый реестр российских программ для электронных вычислительных машин и баз данных).

В предыдущих публикациях (СТА 3'25, СТА 4'25, СТА 1'26, СТА 2'26) мы подробно рассматривали методы анализа, применяемые в нашей системе.

На практике внедрение таких систем сдерживают не технологические ограничения, а четыре группы взаимосвязанных проблем:

- **технические сложности** (качество и доступность данных);
- **организационное сопротивление** (неопределённость окупаемости, завышенные ожидания, недоверие);
- **кадровые проблемы** (дефицит квалифицированных специалистов);
- **«последняя миля» до бизнеса** (интеграция в бизнес-процессы предприятия).

При этом технические сложности решаются проще и быстрее всего, организационное сопротивление преодолеть

труднее, а кадровые проблемы и интеграция с бизнесом – самые труднопреодолимые барьеры.

Технические сложности

Современные промышленные предприятия Российской Федерации характеризуются высокой степенью автоматизации и оснащены системами АСУ ТП. Это создаёт необходимую техническую базу для централизованного сбора и хранения исторических значений контролируемых параметров. Указанные данные служат основой для проведения аналитических исследований, построения математических и ML-моделей. На базе этих моделей впоследствии можно реализовать непрерывный мониторинг данных от АСУ ТП, позволяющий выявлять и оценивать риски отказов технологического оборудования.

Несмотря на это, значительная часть российских предприятий не ведёт долгосрочного архива исторических данных: либо хранит их кратковременно, либо вовсе обходится без истории, опираясь при управлении технологическим процессом лишь на текущие значения параметров.

Среди технических сложностей, препятствующих централизованному сбору и хранению исторических данных, можно выделить следующие.

- **Разрозненность и несовместимость данных.** Различные промышленные информационные системы (АСУ ТП, ПАЗ, АСПС КЗ и ПТ) часто не интегрированы между собой. Данные хранятся в разных местах, что затрудняет их комплексный анализ. Кроме того, на многих предприятиях используется оборудование разных производителей, и его объединение в единую базу данных технически сложно.
- **Низкое качество данных.** Датчики в промышленной среде часто работают в сложных условиях: вибрации, высокие температуры, агрессивные среды – всё это может искажать показания. Это приводит к появлению шумов, ошибок или пропусков в данных.
- **Дополнительные требования к информационной инфраструктуре.** Современные промышленные объекты генерируют огромные массивы информации, которые нужно непрерывно собирать, передавать и обрабатывать. Хранение данных требует

больших объёмов памяти и сложной инфраструктуры с учётом требований безопасности.

- **Лицензионные ограничения.** Ряд существующих промышленных информационных систем, уже развёрнутых на объектах, предусматривают лицензионные ограничения на передачу данных во внешние системы. Для организации экспорта данных из таких систем в централизованное хранилище зачастую требуется приобретение дополнительных лицензий или заключение специальных соглашений с поставщиками ПО.

Большинство зарубежных распределённых систем управления при интеграции с внешними системами опираются на протокол OPC DA. Поскольку он базируется на проприетарной технологии DCOM, доступной исключительно в операционных системах семейства Windows, это создаёт существенные ограничения для интеграции с Unix-системами, такими как Linux и FreeBSD.

При реализации одного из проектов мы столкнулись с необходимостью читать данные из разных систем; одной из них оказалась Honeywell PHD, в которой для интеграции с внешними системами предусмотрен протокол OPC DA.

Требования заказчика предусматривали использование ПО исключительно из Единого реестра российских программ, допуская импортные решения лишь при отсутствии отечественных аналогов. Из-за этого мы не могли применить ОС Windows.

Проблему удалось решить развёртыванием программного комплекса на «Альт Сервере» (Linux) с выделенным контейнером, содержащим среду Windows. В этот контейнер мы установили OPC-конвертер (OPC DA → OPC UA). Этот подход оправдан отсутствием в реестре решений с поддержкой технологии DCOM под Linux.

В процессе работы с OPC-сервером Honeywell PHD возникла проблема чтения значений OPC-тегов. Клиент успешно получал список доступных OPC-серверов и перечень OPC-тегов, однако попытка считывания значений приводила к ошибке 0x80040154 (Class not registered).

Анализ ситуации показал, что Honeywell PHD возвращал некорректный CLSID для каждого доступного OPC-сервера – идентификатор не соответствовал реальному CLSID, зарегистрированному на сервере. Предположи-




Рис. 1. Схема организации связи с сервером Honeywell PHD

тельно, это обусловлено особенностями реализации OPC-сервера в Honeywell PHD: он либо намеренно маскирует CLSID, либо использует нестандартный механизм идентификации при перечислении доступных серверов.

Проблема была устранена путём ручного указания корректного CLSID в настройках OPC-конвертера на стороне клиента, что позволило организовать стабильное считывание значений OPC-тегов. На рис.1 представлена схема организации чтения данных с сервера Honeywell PHD.

Внедрение систем предиктивной диагностики осложняется не только интеграционными трудностями, но и низким качеством данных. Для построения моделей машинного обучения используются исторические данные, которые перед обучением необходимо подготовить:

- определить, какие параметры необходимы для построения точных моделей;
- разметить данные (выделить периоды нормальной работы и аномальные ситуации), что критически важно для обучения ML-моделей;
- нормализовать данные – привести числовые параметры к единому масштабу.

Без этих шагов прогнозы моделей окажутся неточными или вовсе ошибочными. За эту работу в нашей команде отвечают специалисты, сочетающие глубокие знания в области математики и DataScience и опыт работы на промышленных предприятиях и внедрения АСУ ТП. Это критически важно при внедрении предиктивной диагностики, так как они обеспечивают успешную интеграцию технологий, учитывают специфику производства и минимизируют риски ошибок.

Их знания и опыт позволяют адаптировать системы к реальным условиям.

Во всех полученных от заказчиков архивных данных мы выявляли недостатки:

- неравномерность измерений (параметры фиксировались через разные промежутки времени);
- пробелы в информации (часто отсутствовали важные показатели);
- неточные данные за время ремонта оборудования (не были указаны периоды простоя).

Проблемные участки данных с проблемами можно либо удалить, либо заполнить их расчётными значениями, опираясь на известные данные. Проблему неравномерности измерений можно решить либо усреднением (берём самые редкие измерения за основу и сглаживаем остальные), либо дополнением (используем самые частые измерения и заполняем пропуски расчётными значениями). Однако выбор стратегии нормализации данных – это задача, которая может быть качественно решена только квалифицированными специалистами, имеющими значительный практический опыт работы на производстве, глубокое понимание промышленных информационных систем и умеющими эффективно использовать технологии DataScience.

На одном из предприятий при анализе исторических данных наши специалисты выявили ошибку: во время ремонта компрессорной установки перепутали шлейфы двух датчиков виброперемещения вала компрессора (измеряющих вибрацию в двух взаимоперпендикулярных плоскостях с одной стороны вала). Поскольку вибрация – ключевой параметр исправности динамического оборудования, игнорирование этой ошибки сделало бы невоз-




Рис. 2. Блок-схема причинно-следственных связей факторов, негативно влияющих на управленческие решения

можным обучение точной прогнозной модели.

Мы также сталкивались и с лицензионными ограничениями: на предприятии с распределённой системой управления Emerson DeltaV возникла проблема интеграции СППР Sdisol PAD – лицензия ограничивала число точек подключения по протоколу OPC DA, свободных слотов не было, а докупить лицензию из-за санкций оказалось невозможно.

Мы предложили решение: заменить один из существующих клиентов на СППР Sdisol PAD с OPC-клиентом (для чтения данных из DeltaV) и OPC-сервером (для экспорта данных в другие системы). В итоге в СППР Sdisol PAD были настроены серверы OPC DA и OPC UA, что позволило существенно расширить интеграционные возможности, а благодаря большей глубине архива в нашей системе клиенты получили доступ к историческим данным, недоступным в DeltaV.

Организационное сопротивление

Как уже было сказано, помимо технических сложностей, внедрение систем предиктивной диагностики в большинстве случаев сопровождается организационным сопротивлением, которое сводится к трём аспектам:

- **неопределённость окупаемости;**
- **завышенные ожидания;**
- **недоверие.**

На этапе принятия решения внедрения предиктивной диагностики очень

сложно чётко оценить возврат инвестиций (ROI), что вызывает сомнения в целесообразности затрат. Внедрение любой предиктивной диагностики часто подразумевает долгий горизонт окупаемости.

Эффект (снижение количества отказов оборудования, экономия на ремонтах и т.д.) проявляется через 1–3 года, а затраты требуются сразу. Более того, качественно оценить сам эффект от внедрения сложно:

- трудно измерить сокращение внеплановых простоев;
- сложно оценить продление срока службы оборудования;
- непросто посчитать экономию на запчастях и ремонтах;
- тяжело учесть снижение рисков аварий и штрафов.

К тому же мало отраслевых данных по ROI для того, чтобы можно было провести сравнительный анализ со своим производством.

Помимо этого, существуют негативные кейсы внедрения предиктивной диагностики, большая часть которых связана с завышенными ожиданиями от внедрения, которые, в свою очередь, являются следствием маркетинга недобросовестных вендоров (идеальные кейсы без упоминания сложностей), а также недостатка экспертизы у лиц, принимающих решения (вера в то, что ИИ «сам всё поймёт», и ожидание мгновенного эффекта после внедрения).

Всё это только усиливает сомнения руководителей в целесообразности внедрения и приводит:

- к отказу в выделении бюджета;
- сокращению масштабов проекта;
- требованию нереалистично коротких сроков окупаемости;
- приоритету текущих задач над стратегическими инвестициями;
- пересмотру бюджета в процессе внедрения.

На рис. 2 представлена блок-схема, иллюстрирующая причинно-следственные связи негативных факторов, влияющих на управленческие решения при внедрении систем предиктивной диагностики. Обратите внимание, что недобросовестный маркетинг и следующие за ним завышенные ожидания отмечены зелёным цветом, так как первоначально они способствуют положительным управленческим решениям касательно внедрения систем предиктивной диагностики. Однако, как ранее указывалось, впоследствии они приводят к негативным кейсам.

Наш опыт показывает, что для преодоления сомнений руководства необходимо:

- **предусмотреть пилотное внедрение и разделить риски.** В рамках политики распространения СППР Sdisol PAD мы предусматриваем бесплатное внедрение системы в опытную эксплуатацию на одной из установок Заказчика сроком на 1 год. По завершении опытной эксплуатации Заказчик принимает решение о покупке системы;
- **использовать сценарное планирование.** Очень важно сразу донести до Заказчика все сценарии внедрения

(пессимистичный и оптимистичный варианты) – это помогает сформировать реалистичные ожидания от внедрения;

- **включить в расчёт косвенные выгоды.** Помимо предиктивных функций, СППР Sdisol PAD предоставляет дополнительные преимущества: интеграционные возможности (как в кейсе с DelataV), оценку эффективности работы сменного персонала, что повышает эффективность оперативного управления оборудованием. Более того, СППР Sdisol PAD позволяет организовать на предприятии удалённый доступ (web-доступ) к историческим данным, а некоторые инженеринговые компании позиционируют это как полноценную MES-систему, что, конечно же, неверно.

При презентации нашего продукта потенциальному заказчику мы всегда проводим демонстрацию работы системы на примере обезличенных архивных данных реального предприятия – это необходимо для того, чтобы у заказчика сложилось максимально точное представление о том, что он получит.

После того как удаётся убедить руководство предприятия в преимуществах внедрения предиктивной диагностики, необходимо преодолеть сопротивление эксплуатирующего персонала, которое проявляется в недоверии к системе. Причины недоверия могут быть разными:

- опасения, что система снизит их экспертную ценность;
- отсутствие доверия «чёрному ящику» без понимания логики;
- отношение к системе как к инструменту контроля и дополнительной нагрузке;
- страх ответственности за ошибки системы;
- отсутствие понимания, как интерпретировать результаты.

Нередко эксплуатирующий персонал саботирует использование системы, игнорируя её рекомендации. Если не преодолеть такое сопротивление, то результат внедрения гарантированно будет негативным – ожидания Заказчика не будут оправданы.

Самым эффективным способом преодоления сопротивления эксплуатирующего персонала является его вовлечение в процесс внедрения системы на ранних этапах. Необходимо организовать обучение работе с системой и принципам предиктивного анализа; это требуется, чтобы обеспечить про-

зрачность работы алгоритмов для эксплуатации.

Непосредственно после внедрения необходимо организовать механизм обратной связи для учёта замечаний персонала; это важно и для развития системы в целом. Нелишним будет договориться с руководством Заказчика оощении тех, кто активно использует систему. Важно добиться отношения к системе как к удобному инструменту – это обязательное условие успешного внедрения предиктивной диагностики.

Кадровые проблемы

Дефицит квалифицированных кадров – один из ключевых барьеров, препятствующих внедрению предиктивной диагностики; он связан с несколькими факторами:

- быстрое развитие сферы. Предиктивная аналитика – относительно новая и быстро развивающаяся область. Рынок кадров не успевает подстраиваться под запросы компаний, что затрудняет оценку уровня соискателей;
- высокие требования к навыкам. Для работы с предиктивной диагностикой нужны специалисты с сочетанием компетенций: понимание предметной области (технологии и механики процессов), а также знание статистики и математики, владение методами машинного обучения, навыки программирования, умение работать с данными (сбор, очистка, обработка);
- неэффективность традиционных образовательных систем. Цикл внедрения образовательных программ в вузах и колледжах занимает несколько лет, а технологии меняются быстрее. Имеется дефицит преподавателей с актуальным практическим опытом в области промышленного AI и ML;
- конкуренция с другими секторами. Промышленные компании часто не могут конкурировать с IT-гигантами по уровню заработной платы, что приводит к оттоку специалистов в финтех и другие высокодоходные сферы.

Особенность дефицита кадров в том, что требуются специалисты высокой квалификации (middle или senior), а не начального уровня (junior), которым даже при наличии математической базы требуется опыт работы с реальными (часто неструктурированными) данными и глубокое понимание контекста производства.

Отдельно стоит отметить двойной разрыв компетенций, который наблюдается в отношении систем предиктив-

ной диагностики на промышленных предприятиях. Проблема возникает из-за расхождения профессиональных компетенций и подходов к работе у разных поколений сотрудников.

Старшее поколение – это опытные технологи и механики, которые традиционно работали «по ощущениям» и полагались на собственный опыт. Процесс цифровизации требует от них освоения принципиально новых инструментов – облачных систем мониторинга, дашбордов, работы с экранами вместо физического контакта с оборудованием.

Молодые специалисты, напротив, владеют IT-инструментами, но не имеют глубоких знаний о физике технологических процессов и механике промышленного оборудования. Они не понимают, как работает насос или компрессор, что критически важно для корректной интерпретации данных предиктивной диагностики.

Это создает ситуацию, когда ни одна из групп в отдельности не готова к эффективной работе с системами предиктивной диагностики.

Двойной разрыв компетенций – это не просто нехватка кадров, а структурное несоответствие между тем, что умеют разные группы персонала, и тем, что требуется для эффективной работы с системами предиктивной диагностики. Он делает невозможным качественное внедрение, пока не будет налажен механизм передачи знаний между поколениями и дисциплинами. Успех проекта зависит не от выбора лучшей ML-модели, а от способности предприятия соединить интуитивный опыт старшего поколения и аналитический потенциал младшего.

Для преодоления кадровых сложностей промышленные предприятия могут предпринять следующие шаги:

- **развивать образовательные программы:** наладить сотрудничество с вузами, организовать специализированные курсы и тренинги для подготовки соответствующих специалистов, организовать привлечение студентов и молодых специалистов на стажировки с последующим развитием их компетенций на реальных проектах;
- **организовывать центры компетенций:** сформировать внутренние подразделения, которые будут заниматься поддержкой и развитием систем предиктивной аналитики, а также проводить коммуникационные кам-

пании для объяснения преимуществ новых систем, вовлекать ключевых сотрудников в процесс внедрения, работать с сопротивлением;

- **привлекать внешних экспертов и налаживать партнёрство с ИТ-компаниями**, что может помочь компенсировать недостаток внутренних компетенций.

При внедрении предиктивной диагностики мы уделяем особое внимание обучению эксплуатирующего персонала, в которое входит не только получение практических навыков работы с СППР Sdisol PAD, но и минимальная математическая база для понимания принципов предиктивной диагностики. В течение первого года эксплуатации системы мы совместно с эксплуатационным персоналом принимаем участие в анализе прогнозов, сформированных системой, – это позволяет вовремя выявить некорректную интерпретацию данных и объяснить, в чём заключается ошибка.

Дефицит квалифицированных кадров – это глобальная проблема, которая может быть решена только комплексно совместными усилиями государства, образовательных учреждений и бизнеса. Только системный подход позволит обеспечить промышленность и другие отрасли необходимыми специалистами.

«Последняя миля» до бизнеса

«Последняя миля» – это разрыв между моментом, когда система предиктивной диагностики сформировала прогноз («Вероятность отказа подшипника насоса № 3 – 87% в течение 120 часов»), и моментом, когда это предсказание превратилось в реальное управленческое действие (остановка насоса, заказ запчастей, вывод в ремонт).

Часто именно на этом этапе возникают наибольшие сложности: система может выдавать идеальные прогнозы, но, если они не доходят до ответственных лиц и не превращаются в конкретные действия, ценность системы равна нулю. Это не техническая проблема, а организационно-поведенческая проблема.

Среди ключевых барьеров на «последней миле» можно выделить:

- **проблема ложных прогнозов.** Даже 5% ложных прогнозов приводят к потере доверия к системе. Механик, который получил 10 ложных предупреждений, на 11-й раз проигнорирует уже реальное предупреждение о

риске аварии. Это классическая проблема усталости от «алармов»;

- **проблема «размытой ответственности».** От системы поступил прогноз, но ни один конкретный человек не назначен ответственным за его обработку. Каждый предполагает, что «это чья-то другая работа». Оператор считает, что его дело – следить за режимом, механик ориентируется на ППР, начальник цеха считает, что системой занимается ИТ-отдел, который, в свою очередь, убеждён, что в его обязанности входит только обеспечение работы ПО, а решения принимает производство;
- **проблема «конфликта с KPI».** Производство измеряется по выполнению плана, а не по предотвращению аварий. Остановить оборудование по прогнозу предиктивной диагностики – значит не выполнить план, лишиться премии и подвести смену;
- **проблема отсутствия петли обратной связи.** Это одна из самых коварных проблем на «последней миле». Прогноз сделан, но никто не фиксирует, подтвердился он или нет, также не фиксируются отказы оборудования, по которым система не формировала прогнозов. Промышленные процессы не статичны. Меняются: режимы работы, сезонность, сырьё, износ оборудования. Всё это будет приводить к снижению точности прогнозов. Если не фиксировать неточ-

ные и ошибочные прогнозы и не учитывать эти данные при дообучении, то модели, обученные на исторических данных, актуальность которых непрерывно снижается, перестанут отражать текущую реальность.

«Последняя миля» – это не доработка алгоритма. Это проектирование организационного поведения. Если не решить вышеуказанные проблемы на «последней миле», внедрённая система, по сути, будет являться дорогим генератором отчётов, которые никто не читает, а не инструментом, который реально снижает аварийность и повышает надёжность.

Для успешного прохождения «последней мили» необходимо сместить фокус с самой технологии предиктивной диагностики (как это часто бывает на старте) на перестройку человеческого поведения и системы принятия решений. Инструмент должен быть встроен не просто в ИТ-ландшафт, а в организационную структуру и бизнес-процессы.

В первую очередь, требуется назначить «владельца прогноза» и, в случае отсутствия с его стороны реакции на новый прогноз в течение заданного времени, предусмотреть автоматическую отправку уведомления вышестоящему руководителю; при отсутствии реакции на уведомление этого руководителя – отправлять уведомление на более высокий уровень, вплоть до главного инженера или директора предприятия.




Рис. 3. Жизненный цикл прогноза с петлёй обратной связи

Также необходимо пересмотреть систему мотивации. Если премия оператора зависит только от тонн продукции, он никогда не даст остановить установку по прогнозу. Необходимо вводить KPI надёжности: «Количество предотвращённых отказов» или «Время реакции на прогноз».

При внедрении предиктивной диагностики наша команда всегда предусматривает автоматический расчёт метрик эффективности работы персонала; в СППР Sdisol PAD для этого предусмотрены функции расчёта интегральных оценок (подробно о методах оценки эффективности работы персонала рассказывалось в предыдущей статье, СТА 2'26).

Не менее важно замкнуть «петлю обратной связи». Проблема отсутствия «петли обратной связи» всегда приводит к ложным прогнозам. Наш опыт показывает, что фиксация результатов прогнозов должна осуществляться назначенным «владельцем прогноза».

Ранее было указано, что наша команда в первый год после внедрения предиктивной диагностики принимает участие совместно с эксплуатацией в анализе прогнозов – это делается ещё

и для того, чтобы сформировать у эксплуатирующего персонала культуру замыкания «петли обратной связи».

Схематичное изображение жизненного цикла прогноза с петлёй обратной связи представлено на рис. 3.

Вывод

Предиктивная диагностика – это не просто очередной технологический тренд, а инструмент, способный принципиально изменить подход к управлению промышленным оборудованием: от реактивного устранения отказов к проактивному предотвращению аварий. Однако, как показывает наш опыт, сама по себе технология – даже самая совершенная – не гарантирует успеха.

Ключевой вывод, который мы вынесли, звучит парадоксально: технические проблемы – самые лёгкие. Качество данных, интеграционные сложности, несовместимость протоколов – всё это решается, хотя порой и нетривиальными способами. Настоящие барьеры лежат в другой плоскости. Организационное сопротивление, дефицит квалифицированных кадров (особенно усугублённый «двойным разрывом

компетенций») и, наконец, пресловутая «последняя миля» до бизнес-процесса – вот где внедрения буксуют или терпят неудачу. Поэтому главный урок, который мы усвоили: внедрение предиктивной диагностики – это не IT-проект. Это проект организационной трансформации. Успех зависит не от выбора лучшей ML-модели, а от способности предприятия:

- соединить интуитивный опыт старшего поколения с аналитическими навыками молодых специалистов;
- пересмотреть KPI персонала, чтобы проактивные действия стали выгоднее «тушения пожаров»;
- замкнуть «петлю обратной связи», превратив прогнозы в часть ремонтного цикла;
- назначить «владельца прогноза», закрепив ответственность за каждым прогнозом системы.

«Узкое горлышко» сегодня – это люди, процессы и культура производства. И пока компании это не осознают и не начнут инвестировать в «человеческий фактор» с тем же усердием, что и в «цифру», дилемма «внедрять нельзя игнорировать» так и останется нерешённой. ●





ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В ПРОМЫШЛЕННЫХ РЕШЕНИЯХ BOXER-8110AI НА БАЗЕ NVIDIA

- Самообучающиеся роботы
- Магазины самообслуживания
- Интеллектуальное видеонаблюдение
- Контроль доступа



BOXER-8110AI



ОФИЦИАЛЬНЫЙ ДИСТРИБЬЮТОР

(495) 234-0636
INFO@PROSOFT.RU

WWW.PROSOFT.RU

