

ПРЕДИКТИВНАЯ АНАЛИТИКА СОСТОЯНИЯ ОБОРУДОВАНИЯ В ХИМИКО-ТЕХНОЛОГИЧЕСКИХ ПРОЦЕССАХ

Р.А. Владов, В.М. Дозорцев, Р.А. Шайдуллин, О.Ю. Белоусов (АО «Хоневелл»)

Проанализированы особенности больших данных, генерируемых химико-технологическими производствами, определяющие возможность и способы применения современных инструментов мониторинга и предиктивной аналитики состояния технологического оборудования. Описана первая в своем классе производственная информационно-аналитическая платформа Honeywell Forge for Industrial, обрабатывающая большие данные, анализирующая состояние процессов и оборудования и предоставляющая рекомендации для интеллектуального управления, надежной и оптимальной эксплуатации производства. Изложены принципы сбора и подготовки данных, моделирования оборудования, предиктивного обнаружения и обработки событий, соответствующих нарушениям работы и отказам оборудования. Обсуждаются характеристики различных методов предиктивной аналитики и приводится практический пример ее использования.

Ключевые слова: большие данные, химико-технологические процессы, обслуживание по состоянию, мониторинг состояния оборудования, предиктивная аналитика, диагностические и прогностические модели, распознавание образов, наработка на отказ.

Введение

В десятые годы нового столетия технологии больших данных привлекают невероятный интерес. В 1991 г. в Web of Science¹ было размещено всего 125 статей со ссылками на большие данные, в 2015 г. — уже 2773 статьи. Согласно исследованиям PricewaterhouseCoopers, 88% командиров промышленного бизнеса признают, что анализ больших данных станет критически важным конкурентным преимуществом уже в ближайшие несколько лет. Первый прорыв произошел в нейронауках и в математической химии. В химико-технологических отраслях промышленности это проявилось не сразу и, прежде всего, там, где фундаментальные модели процессов и оборудования не работают достаточно хорошо.

Тем не менее достаточно набрать в поисковике пересечение *Big Data & Chemical Engineering* и (на декабрь 2019 г.) появится всего 1,74 млн. ссылок; при этом в отдельности на *Chemical Engineering* будет 49,9 млн., а на *Big Data* — 210 млн. ссылок. Исторически химико-технологическая индустрия была пионером компьютерного управления, где для стабильного и эффективного ведения процессов нужно контролировать тысячи переменных. Сбор и хранение данных в рассматриваемой отрасли превратились в рутинную процедуру, по факту стали стандартом обеспечения безопасного управления ТП и привели к появлению развитых платформ для сбора и анализа больших данных [1]. Но на современных заводах стало доступно так много данных, что персонал легко может в них потонуть, и большая часть информационных потоков остается непроанализированной². В то же время нет сомнений, что выделение критически важных индикаторов производства и их визуализация в реальном времени существенно облегчают принятие решений, основанное на данных и знаниях [2]. Среди задач, в решении которых уже есть заметные успехи или они не за горами, выделим мониторинг и диагностику

процессов и оборудования [1, 3], усовершенствованное управление процессами [4], в частности, построение виртуальных анализаторов [5, 6], мониторинг качества продукции [7] и мониторинг работы контроллеров [8]. Обратим особое внимание на проблему мониторинга и диагностики, поскольку появление дешевых сенсоров, беспроводных технологий и средств обработки данных облегчает сбор актуальных данных и анализ «здоровья» производственных активов, что, в свою очередь, позволяет уменьшать неопределенность при управлении, снижать незапланированные потери времени и повышать эффективность производства, детектировать узкие места технологической схемы и экономней использовать ресурсы.

К общеизвестным признакам больших данных относят так называемые 3V: Volume (объем: надо обрабатывать очень много данных), Velocity (скорость: надо принимать решение очень быстро, с минимальной задержкой после генерации данных) и Variety (разнообразие: данные очень разные, включая неструктурированные, такие как тексты, фото, аудио, видео, Web-страницы, отчеты, пр.). Иногда к этим признакам добавляют Veracity (надежность: не все данные одинаково достоверны) и Value (неодинаково ценны). Во многих химико-технологических процессах (особенно непрерывных) имеются плотные измерения с естественными корреляциями (потоки, тепло- и массообмен, базовая термодинамика). Они традиционно использовались для выявления нарушений и отказов, для чего появились разнообразные методы [1, 3]. Однако построенные на таких данных традиционные модели существенно нелинейны, обременены сложным поведением, со временем деградируют. Понятен в этой связи интерес к использованию подходов, основанных на больших данных, в том числе машинного обучения. Такие разработки начались достаточно давно, вспомним, например, результаты их применения в классическом тестовом процессе

¹ Web of Science — поисковая Internet-платформа, объединяющая реферативные базы данных публикаций в научных журналах и патентов.

² Современное производство генерирует огромные данные: от нескольких десятков терабайт до многих петабайт в одном наборе данных. Так, корпорация General Electric генерирует 5000 экземпляров данных каждые 33 мс.

Tennessee-Eastman [9]. Тогда же стало понятно, что единого решения нет; конкретные задачи в конкретных процессах нуждаются в собственных методах.

Ключевая сложность аналитики больших данных в рассматриваемой предметной области состоит в их высоком разнообразии, гетерогенности, неструктурированности, зашумленности, избыточности³. Действительно, помимо данных от киберфизических систем (сенсоров, исполнительных механизмов, видео-камер, RFID-ридеров, соединенных посредством IIoT с Internet и друг с другом⁴), генерируются огромные объемы данных в продолжении жизненного цикла производства (от начальных технических требований до обслуживания ТП и взаимодействия с потребителями), а также бизнес-данные (от структуры до коммерческих показателей предприятия), включая данные о цепочке добавленной ценности (поставки, продажи, логистика, конкуренция) и внешнем партнерстве (рынок, риски, окружение). Ранее вся эта информация использовалась на других этажах пирамиды автоматизации производства; новые методы позволяют применять их совместно с регулярными измерениями хода ТП для совместного решения задач календарного планирования (составления расписаний) и управления [10].

Дальнейшее развитие методов больших данных в отрасли сдерживается как вышеотмеченными технологическими особенностями, так и ограничениями существующей инфраструктуры сбора и подготовки данных, отсутствием эффективных платформ аналитики больших данных, позволяющих собрать и контекстуализировать разнородные данные и реализовать современные аналитические алгоритмы. Без всего этого самые передовые подходы предиктивной аналитики становятся бесполезными. В настоящей работе описывается универсальная информационно-аналитическая платформа управления производством с фокусом на мониторинг и предиктивную аналитику производственного оборудования как на наиболее прорывную технологию, опирающуюся в том числе на большие производственные данные и методы искусственного интеллекта.

Производственная информационно-аналитическая платформа Honeywell Forge for Industrial

Honeywell Forge for Industrial (HFI) — первая в своем классе производственная информационно-аналитическая платформа, которая в режиме, близком к режиму реального времени, обрабатывает большие данные, осуществляет аналитику процессов и оборудования и предоставляет результаты анализа и рекомендации для интеллектуального управления, надежной и оптимальной эксплуатации производства с помощью удобных средств визуализации (рис. 1).

³ Принципиально другая ситуация сложилась во многих сложных, но успешно разрешенных задачах аналитики регулярных данных (шахматы, го).

⁴ Во многом именно появление IIoT и облачных технологий, создав возможность «поднять» большие объемы данных в облачные хранилища, подстегнули интерес к задаче предиктивной аналитики оборудования и процессов.

Любое человеческое знание начинается с интуиции, переходит к понятиям и завершается идеями.

Э. Кант

Платформа объединяет показатели технологического процесса, состояния производственного оборудования и систем автоматизации технологических процессов, включая системы усовершенствованного управления. Объединение данных о технологическом процессе и состоянии оборудования позволяет вести всесторонний контроль производства и генерировать практические рекомендации, подкрепленные расчетом потенциальных финансовых эффектов от их реализации.

Ключевые функции HFI включают в себя:

- сервис *Control Performance Service* — мониторинг процессов на основе цифровых двойников технологических установок (в настоящий момент охватываются установки технологических лицензиаров UOP и Haldor Topsoe; в ближайшее время планируется подключение к сервису других лицензиаров технологических процессов);

- сервис *Profit Performance Services* — мониторинг эффективности систем усовершенствованного управления технологическими процессами на основе контроля, диагностики и детального анализа работы систем;

- сервис *Asset Performance and Predictive Analytics* — мониторинг состояния оборудования и предиктивной аналитики на основе цифровых двойников технологического оборудования.

Остановимся подробнее на последней из перечисленных функций.

Мониторинг состояния оборудования и предиктивная аналитика

Автоматический анализ данных о состоянии оборудования и раннее выявление и локализация потенциальных проблем и отказов — важнейшая функция оперативного управления производством. Современное технологическое оборудование уже стандартно может оснащаться встроенными средствами диагностики, но в силу постоянно растущего объема поступающих данных вовремя обнаружить или спрогнозировать отказ с помощью ручного анализа данных — практически неразрешимая задача. Автоматизация рутинного мониторинга состояния оборудования обеспечит производству снижение простоев, повышение доступности оборудования, возможность управления надежностью, переход на обслуживание по состоянию и на увеличенный межремонтный период.

Мониторинг состояния с помощью платформы HFI — это автоматическое отслеживание и оценка текущего состояния оборудования на основе всей име-

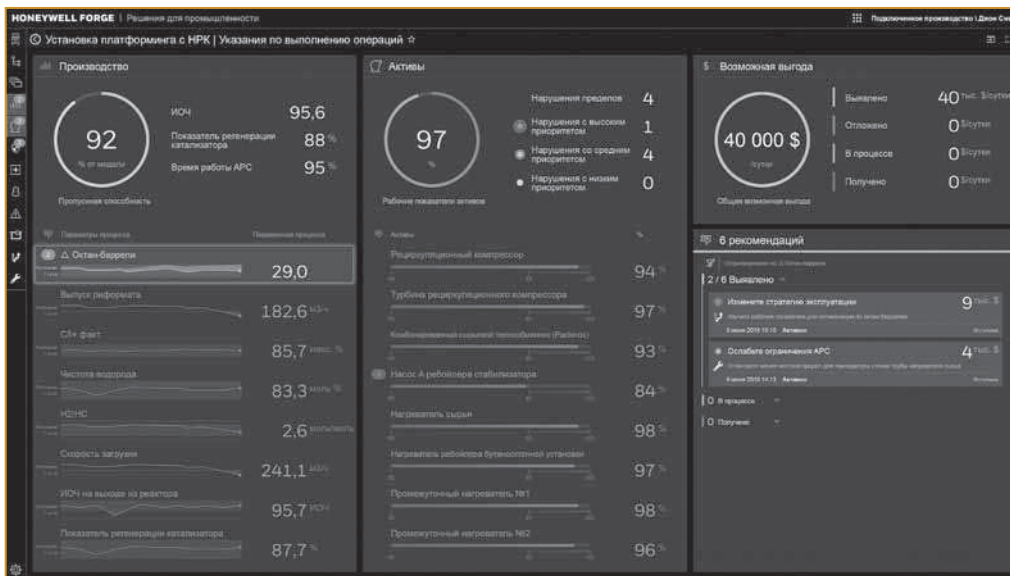


Рис. 1. Пример базового экрана платформы Honeywell Forge for Industrial

ющейся информации о нем, автоматическое обнаружение неисправностей, потенциальных остановов, снижения производительности, качества, а также уведомление ответственных специалистов и предоставление им необходимой информации для своевременного и качественного принятия решений по изменению технологического режима, обслуживанию оборудования, реализации мер безопасности. Кроме того, HFI рассчитывает потенциальные экономические потери, связанные с отказом или снижением производительности оборудования, осуществляет автоматизированную передачу информации по состоянию оборудования и отказам в систему ТОРО для

запуска необходимых процессов обслуживания. Учитывая все еще неравномерное оснащение оборудования средствами измерений, в современных условиях мониторинг состояния и предиктивная аналитика должны применяться в первую очередь к критичному оборудованию, неисправность или простой которого могут существенно повлиять на безопасность и эффективность производства, защищенность персонала и окружающей среды. Доля такого оборудования на производстве обычно составляет 5...15%. Именно для него целесообразно с помощью платформы HFI заранее обнаруживать деградацию состояния, аномальное поведение и вытекающее из них снижение надежности производства.

Таковыми типовыми объектами мониторинга в непрерывном химико-технологическом производстве являются, прежде всего, динамическое оборудование (центробежные насосы, компрессорные установки, газовые и паровые турбины, воздухоподогреватели, турбодетандеры, воздушно-холодильные установки, электродвигатели), а также статическое оборудование (теплообменники,

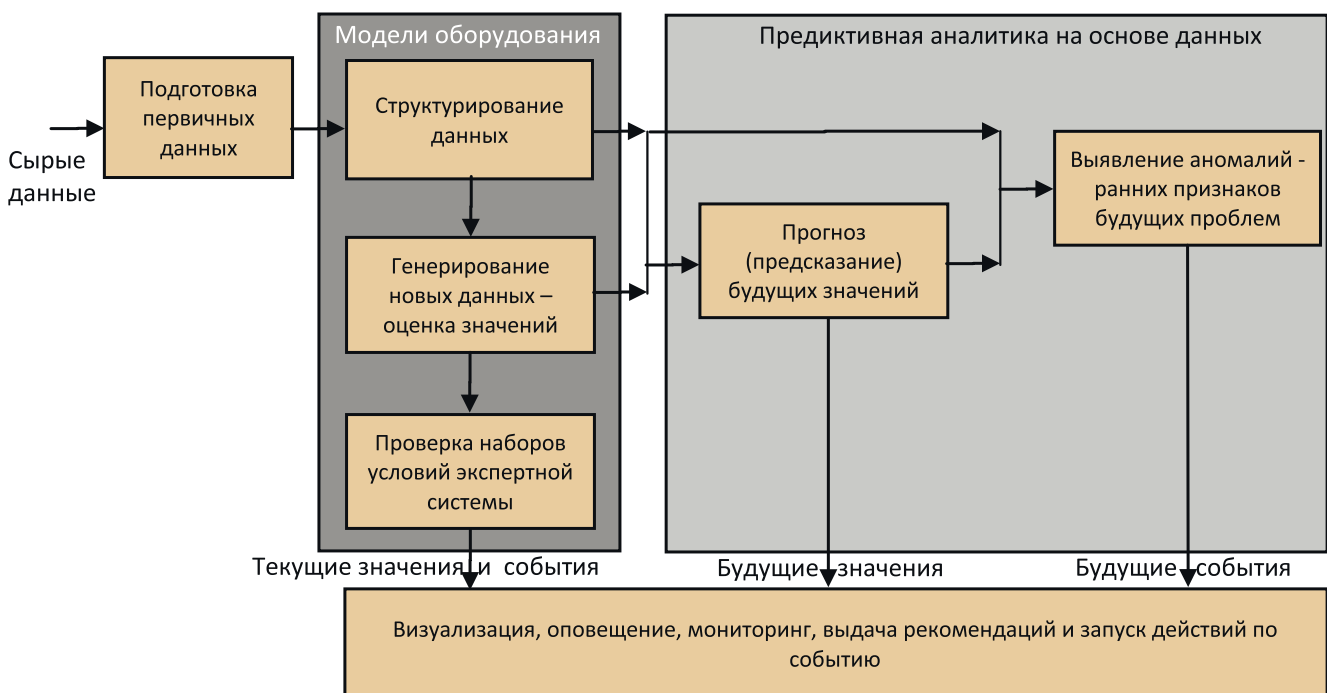


Рис. 2. Общий алгоритм обработки и анализа данных в HFI

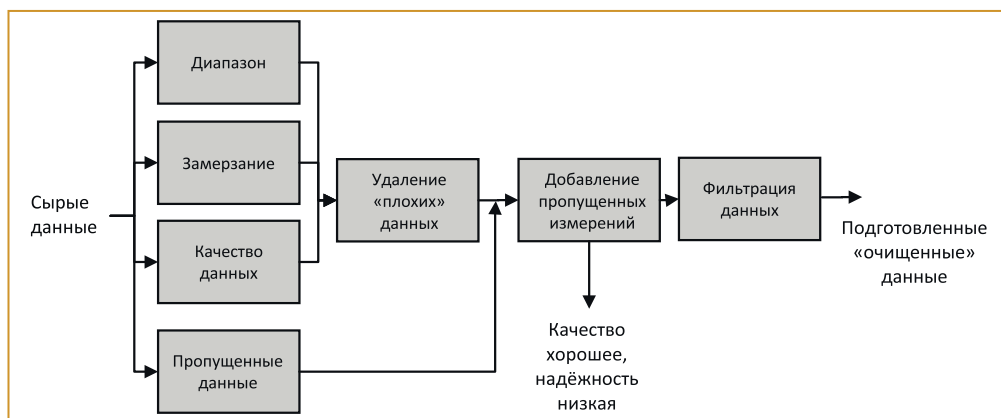


Рис. 3. Схема обработки входных данных в НФИ

фильтры, клапаны, печи). Этот список может быть дополнен и специфическим оборудованием — реакторами и колоннами нефтепереработки и нефтехимии, погружными насосами для добычи нефти, шахтным и карьерным оборудованием, мельницами и дробилками для обогащения руды или переработки целлюлозы, трансформаторами и выключателями для электроэнергетики. НФИ содержит библиотеку моделей вышеперечисленного оборудования, которая постоянно развивается и дополняется новыми элементами.

Общий алгоритм обработки и анализа данных в НФИ предусматривает выполнение последовательности обязательных действий, представленной на рис. 2 и подробно рассмотренной ниже.

На практике встречается двойное толкование термина «предиктивная аналитика» применительно к методам анализа данных:

- для получения и анализа в текущий момент времени оценок (прогнозов) значений параметров, фактические измерения которых будут получены в будущем со значительным запаздыванием;
- для прогнозирования будущего поведения объектов и предсказания будущих событий, связанных с этими объектами.

В первом случае измерения принципиально не отличаются от оценок значений параметров, которые либо не измеряются вообще, либо измеряются с запаздыванием. Другими словами, можно контролировать выход оценки за допустимые пределы точно так же, как это делается для непосредственно измеряемых параметров. Во втором случае при выявлении аномалий фактические измерения сравниваются с оценками значений параметров (ожиданиями при текущем режиме работы). Выявленные значительные отклонения свидетельствуют о наличии аномальных условий или аномального поведения.

Далее по ходу изложения будем придерживаться последнего из приведенных толкований.

Сбор и подготовка данных

НФИ может покрывать все производственное оборудование, по которому имеются данные АСУТП (температура, давление, расход, ток двигателя и т. п.),

систем вибродиагностики (например, вибрация подшипников), аудио-визуального контроля (шум, задымление и т. п.), систем управления лабораторной информацией (качество сырья и продукта), систем мониторинга коррозии (скорость общего корродирования, коэффициент питтингообразования, пр.). Принципиально, что в НФИ могут использоваться не только

данные о непосредственном состоянии оборудования, но и данные о ТП, в котором это оборудование применяется. Так, расход через антипомпажный клапан компрессора обычно не измеряется, но его можно оценить по открытию клапана, свойствам газа, температуре и давлению.

Сырые необработанные данные не подходят для алгоритмов предиктивной аналитики из-за зашумленности, погрешности измерения и прочих неопределенностей, поэтому предварительная обработка является крайне важным этапом мониторинга состояния на основе производственных данных. Когда расчеты производятся на основе неверных данных, порождается ложная информация об объекте, что может привести к неверным решениям.

НФИ содержит модуль обработки входных данных, который выполняет ряд проверок во времени, близком к реальному: валидация диапазона измерения, проверка на «замерзание» значения, проверка качества входного значения, пропущенные измерения. Принципиальная схема обработки данных представлена на рис. 3.

Некоторые проверки могут осуществляться на основе диагностических сообщений «умного» КИП (по HART-протоколу). После этого осуществляется исключение из мониторинга плохих данных, добавление пропущенных измерений (при этом помечается, что качество добавленного измерения высокое, а надежность измерения низкая, так как данные были получены алгоритмически) и фильтрация данных.

Структуры данных, оценка значений параметров и автоматизированный мониторинг с помощью моделей оборудования

НФИ структурирует данные с помощью так называемой модели активов — дерева оборудования, каждый элемент которого описывается соответствующей моделью объекта — единицы оборудования. На вход моделей оборудования поступают подготовленные данные, а на выходе получают рассчитанные оценки показателей работы оборудования, обнаруженные симптомы

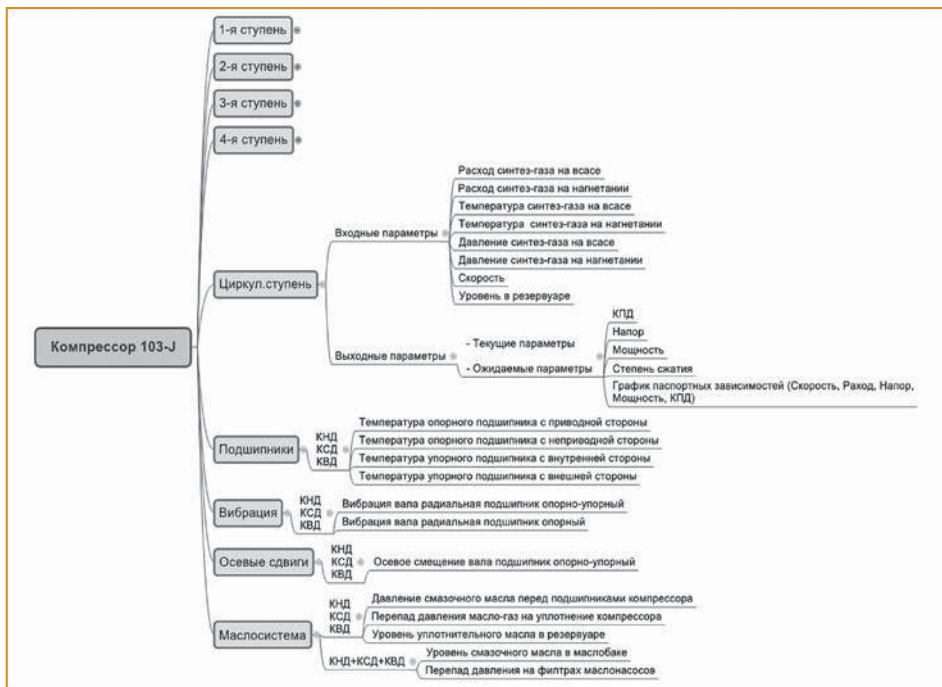


Рис. 4. Модель оборудования и его составных элементов (на примере центробежного компрессора)

отказов и неисправности (как фактические, так и прогнозные), а также генерируются тревожные сообщения, на основе которых запускаются соответствующие рабочие процедуры. Сами модели оборудования могут состоять из нескольких подмоделей составных частей оборудования, для каждой из которых осуществляется специализированный мониторинг состояния (рис. 4).

Для оборудования без диагностики или с минимальной встроенной диагностикой производятся расчеты параметров нагрузки, КПД, кривых (газо-) динамических свойств на основании статистических данных из базы данных реального времени. На основе результатов этих расчетов производится определение потенциального сбоя или нарушения работы в случае отклонения рассчитанных значений от нормативных. По большинству приведенных выше типов оборудования НФИ содержит готовые экспертные модели, определяющие декомпозицию подсистем целевого оборудования, необходимые входные параметры, расчеты показателей эффективности и правила определения отказов по симптомам.

Вычисление параметров производительности

НФИ распознает потенциальные отказы и возможные источники снижения производительности, отличая ухудшение работы оборудования от его неэффективной работы. Фактическая производительность оборудования может быть замаскирована изменениями процесса вследствие флуктуаций условий окружающей среды, состава потоков, рабочих условий и других изменений в ТП. Мониторинг производительности на основе строгой инженерной модели может учитывать изменения в ТП и изменения режима работы, подачи сырья. При этом мониторинг не фокусируется на отдельных элемен-

тах оборудования, а позволяет точно сравнивать фактические и проектные характеристики, а также определяет термодинамическую эффективность контролируемого оборудования.

Технологические параметры, такие как поток, температура и давление, измеренные на входе/выходе оборудования, используются для постоянного анализа производительности и повышения эффективности работы. НФИ выходит за рамки традиционного мониторинга процесса и состояния оборудования, и использует надежные модели для прогнозирования эксплуатационных характеристик, обнаружения и диагностики отказов. Платформа использует модели, настроенные по данным производителей оборудования, сопоставляя текущие параметры работы с ожидаемыми для контроля

эксплуатационных характеристик (например, коэффициента полезного действия) и мониторинга состояния в целях сохранения максимальной производительности и обеспечения раннего предупреждения о неисправностях. НФИ осуществляет сравнение текущей производительности:

- с прогнозируемым или ожидаемым значением;
- со статическими или динамическими (зависящими от режима) пределами;
- с результатами статистического анализа исторических данных;
- с паспортными значениями.

Переменные процесса вычисляются на основе измеренной информации, объединенной со знаниями о процессе. Для повышения точности могут использоваться системы высокоточного моделирования технологических процессов (например, UniSim Design), где расчеты производятся с помощью статических и динамических моделей оборудования на основе строгих физико-химических зависимостей.

Результатом расчетов могут являться ключевые показатели эффективности (КПЭ) оборудования, используемые внешними системами (управление ТОРО, надежностью), значения, необходимые для оценки состояния оборудования и визуализации его состояния (рис. 5), а также параметры, используемые для предиктивной аналитики состояния.

Предиктивная аналитика оборудования

Симптоматические модели

Один из подходов, используемых в НФИ для определения конкретных причин отказов оборудования, ос-



Рис. 5. Визуализация состояния оборудования в HFI

нован на моделях симптомов и отказов. Модель состоит из нескольких отказов, для каждого из которых может быть задан один или несколько симптомов (рис. 6). При этом отказ идентифицируется по наступлению хотя бы одного симптома, нескольких (например, двух из трех) или всех одновременно. Для проектирования набора симптомов и отказов можно воспользоваться следующими методами и источниками:

- использовать специфические знания эксплуатационного персонала, технологов, механиков, основанные




Рис. 6. Иерархия отказов и симптомов

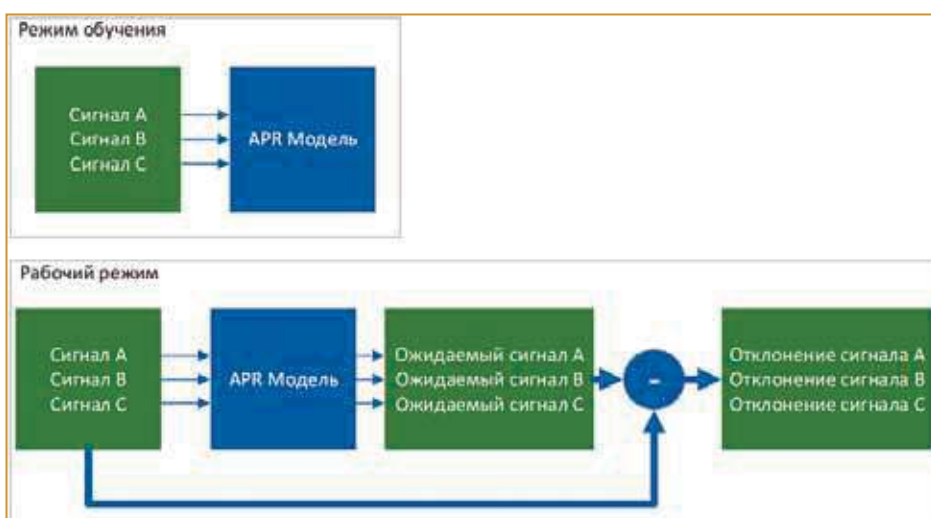


Рис. 7. Алгоритм распознавания образов в HFI

на истории работы конкретной единицы оборудования и истории ее отказов (сравните с упомянутыми выше экспертными моделями);

- осуществить анализ всех возможных причин отказов, которые могут привести к поломке оборудования, их механизмов, зависимостей и иерархической структуры;
- использовать имеющуюся документацию по оборудованию: паспорт, регламент, карту обслуживания и т. п.,
- HAZOP (Hazard and Operability Study) — анализ опасности и работоспособности;
- таблицы причин и следствий (Cause & Effect) системы ПАЗ.

Для симптомов и отказов задаются приоритеты и степени последствий, необходимые для приоритизации действий пользователя системы мониторинга как при обнаружении неполадок (на что в первую очередь обращать внимание), так и при планировании дальнейших действий (что в первую очередь требует ремонта/обслуживания).

Для сокращения числа ложных срабатываний модель симптомов и отказов погружена в контекст производства, то есть способна отличать один режим работы от другого и не генерировать тревожные сообщения, когда оборудование находится в плановом останове, находится на обслуживании или в процессе штатного выхода на режим.

Диагностические модели на основе распознавания образов

Трудности применения инструментов предиктивной аналитики оборудования в химико-технологических производствах обусловлены гетерогенностью и зашумленностью измеряемых данных. К этому надо добавить недостаток данных об отказах оборудования, которые могут случаться очень редко, и проблему масштаба: на производстве может эксплуатироваться огромное число экземпляров оборудования (например, насосов) и на переобучение моделей




Рис. 8. Симптом неисправности по APR-модели

диагностики (после обслуживания, ремонта или изменения режимов работы) могут потребоваться огромные ресурсы.

Один из автоматических методов предиктивной аналитики HFI — распознавание образов с использованием APR-модели (Advanced Pattern Recognition), рис. 7. Для идентификации модели необходимо обучение на истории фактической эксплуатации оборудования, из которой выделяются диапазоны времени, где оборудование корректно выполняло свои технологические функции (работало в штатном режиме). При этом в одной модели могут быть увязаны параметры самых разных технологических подсистем.

Модель имеет собственный диапазон нормальных значений прогнозируемых параметров, построенный на взаимосвязи показателей работы оборудования, поэтому в момент генерации симптома неисправности по APR-модели (нарушение указанного диапазона) параметры оборудования могут находиться в допустимых с точки зрения системы управления пределах значений (рис. 8).

Помимо обнаружения аномалий как таковых необходимо правильно диагностировать их причину, чтобы ее можно было устранить. Платформа HFI автоматизирует соответствующую диагностическую функцию, используя модель Bayesian Belief Network. Модель обучается на истории поведения, предварительно оцененного персоналом как конкретные нарушения, и в дальнейшем в режиме реального времени автоматически интерпретирует аномалии, определяя наиболее вероятную причину неисправности. Такой подход актуален при наличии сложных неисправностей с перекрываю-

щимися симптомами или при множественных неисправностях, возникающих одновременно.

Прогностические модели наработки на отказ

При организации работ по техническому обслуживанию и ремонту, как и при оценивании целостности и надежности оборудования, наряду с ранним диагностированием возможных неисправностей актуальна задача достоверной оценки срока службы оборудования, оставшегося до функционального отказа (Remaining Useful Life, RUL). Эта информация необходима для корректной оценки текущих рисков, эффективной приоритизации, координации и планирования работ, что ведет к уменьшению затрат на ТОРО, снижению деградации и увеличению коэффициента готовности оборудования.

В платформе HFI применяется набор методов, наиболее удобных для использования на реальном производстве.

- Прогностические модели надежности на основе оценки средней наработки на отказ (Mean time between failures, MTBF) для усредненного/неспецифичного оборудования целевого типа, без учета условий эксплуатации. Для создания такой прогностической модели используются либо показатели MTBF от производителя оборудования, либо Вейбулл-анализ [11] для построения распределения вероятности отказа в определенный момент времени по историческим данным наработок на отказ при усредненных условиях эксплуатации.

- Прогностические модели, основанные на стрессовых факторах. В таких моделях оценка средней наработки на отказ получается с учетом специфичных условий эксплуатации (температуры, нагрузки, вибрации и т.д.) для усредненного/неспецифичного оборудования целевого типа. При этом показатель MTBF, полученный на основе распределения Вейбулла, корректируется по значениям влияющих стрессовых факторов согласно модели пропорциональных рисков (Proportional Hazards Model) [12]. Например, если работа оборудования при высокой температуре снижает MTBF, то модель будет определять срок службы до отказа (RUL) на основе распределения Вейбулла, общего числа часов работы и часов работы при высокой температуре.



Рис. 9а. Прогноз RUL, построенный по изначально доступным данным

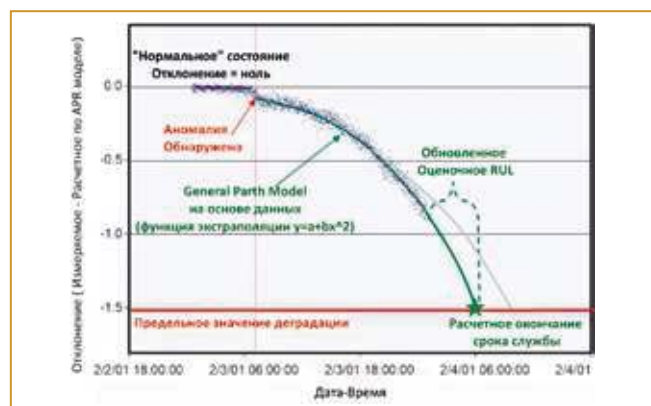


Рис. 9б. Обновление/уточнение прогноза RUL по дополнительно появляющимся данным




Рис. 10. Прогнозное (красным) и фактическое (синим) значение температуры подшипника насоса (слева) и вибрации двигателя компрессора (справа)

- Прогностические модели, основанные на данных деградации оборудования. В этих методах значение RUL конкретного элемента в конкретной среде вычисляется с учетом измеряемой или предполагаемой деградации. Мерой деградации служит расчетная скалярная или векторная величина, характеризующая текущую способность надлежащего выполнения заданных функций. Ее численное значение коррелирует с вероятностью отказа в конкретный момент времени. Значение степени деградации экстраполируется до достижения определенного критического значения, соответствующего событию отказа. Для решения этой задачи в HFI используется алгоритм General Path Model, отслеживающий деградацию в режиме реального времени, постоянно обновляющий линию тренда и прогнозирующий время, оставшееся до наступления предельного состояния. В такой модели в качестве входов могут использоваться все типы сигналов, в том числе наблюдаемые, рассчитанные и прогнозируемые (рис. 9а, 9 б).

Практическая реализация методов предиктивной аналитики

На рис. 10 приведен пример применения методов предиктивной аналитики с использованием платформы HFI для обнаружения неисправностей динамического оборудования на нефтеперерабатывающем заводе в Европе. В частности, диагностическая модель насоса обнаружила отклонение прогнозного значения температуры подшипника от фактического за 5 дней до аварии, а модель компрессора выявила аномалии в вибрации за 15 дней до аварии (рис. 10). Триггер

аномалии сработал, когда прогнозное значение, полученное на основе APR-модели, было значительно больше фактического значения (эти моменты выделены на рисунке красными овалами; отсутствие измерения правее овалов соответствует наступлению аварии).

Регламент обработки событий

HFI поддерживает процесс обработки сообщений о неполадках и отказах, при котором информация обо всех обнаруженных неисправностях и отклонениях направляется пользователям и приложениям (рис. 11).

Такой подход позволяет реализовать управление по событию/отклонению и автоматизацию рутинных рабочих процессов, что является следующим шагом на пути построения вертикально-интегрированного решения. Предупреждения, основанные на моделях неисправностей, доступны для соответствующего персонала непосредственно на площадке или удаленно. Управление по событию позволяет вести оперативный контроль из дистанционных центров поддержки и эффективно использовать опыт и знания экспертов, расположенных в этих центрах. Кроме того, систему мониторинга можно настроить для создания уведомлений или запуска рабочих процессов в других системах, например, в управления техобслуживанием и ремонтами, мобильном обходчике и др.

Для обнаружения симптомов неполадок могут использоваться как собственные средства диагностики от Honeywell, основанные на строгих моделях и моделях на основе больших данных, так и инструменты сторонних производителей. При этом принцип работы не изменится для любых технологий диагностики и прогнозирования (рис. 12). Модели мониторинга и предиктивной аналитики HFI достаточно гибки и позволяют легко задавать контекст, отвечающий текущему состоянию оборудования. Платформа позволяет сократить влияние человеческого фактора и необходимость трудоемкой интерпретации технологических данных и различных аварийных сигналов для выяснения, исправно ли оборудование. Более того, HFI рекомендует действия, позволяющие скорректировать отклонения от регламента до того, как наступит поломка оборудования или произойдет остановка производства.



Рис. 11. Рабочий процесс мониторинга состояния оборудования

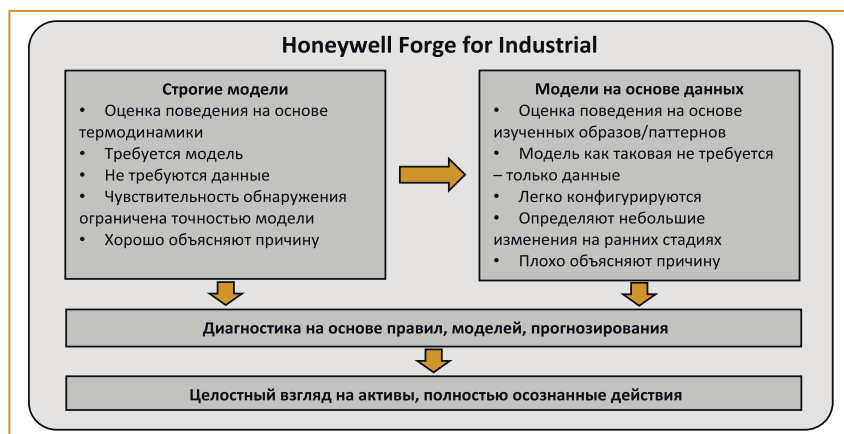


Рис. 12. Мониторинг состояния оборудования в HFI

Заключение

Описанный в работе подход основан на 10-летнем опыте корпорации Honeywell в использовании технологии мониторинга состояния оборудования для повышения надежности и безопасности производства в целом. Платформа HFI обеспечивает сокращение времени плановых и внеплановых простоев, объема работ и затрат времени и ресурсов на обслуживание оборудования, оптимизацию работы оборудования и процессов. Сопутствующими эффектами автоматизации мониторинга являются повышение эффективности работы технолога, инженера по обслуживанию и обеспечению надежности благодаря интеграционным инструментам и предоставлению своевременного доступа к информации из одной точки.

Предиктивная аналитика состояния оборудования HFI, основанная в том числе на продвинутых методах обработки больших данных, обеспечивает раннее обнаружение изменений в работе, что оставляет больше времени для планового обслуживания или внесения оперативных изменений по снижению нагрузки на контролируемое оборудование. Рекомендации платформы помогают персоналу в определении оптимальных режимов работы и интервалов обслуживания для восстановления «пиковой» производительности, выявлении причинно-следственных связей, внесении изменений в технологический процесс для предотвращения поломок и увеличения среднего времени безотказной работы оборудования.

Не случаен в этой связи интерес рынка к флагманскому решению HFI, доказательством чему стал десятилетний контракт на мониторинг и предиктивный анализ технологического оборудования, заключенный

с группой ADNOC, мировым энергетическим и нефтехимическим лидером.

В наступившую эру больших данных нередки обвинения аналитических технологий в выявлении «мифических» связей и фейковых «образов», что бывает в исследованиях, проводимых вне содержательного контента, особенно в столь сложной предметной области, как химико-технологические процессы. Представленное в работе решение лишено этого недостатка благодаря сочетанию в предиктивном анализе моделей больших данных и традиционных моделей процессов и оборудования (фундаментальных, симптоматических, диагностических, прогностических и пр.).

Список литературы

1. Qin SJ. 2012. Survey on data-driven industrial process monitoring and diagnosis // Annu. Rev. Control 36(20): 220-34.
2. Colegrove L. 2015. Data initiative improves insights // Chemical Processing, March 12.
3. Severson K., Chaiwatanodom P., Braatz RD. 2015. Perspectives on process monitoring of industrial systems // IFAC-Papers Online 48(2): 931-39.
4. Lee JH, Lee JM. 2014. Progress and challenges in control of chemical process // Annu. Rev. Chem. Biomol. Eng. 5: 383-404.
5. Kano M., Fujiwara K. 2013. Virtual sensing technology in process industries: trends and challenges revealed by recent industrial applications // J. Chem. Eng. Jpn. 46(3):1-17.
6. Kordon A., Chiang L., Stefanov Z., Castillo I. 2014. Consider robust inferential sensors // Chemical Processing, Oct. 2.
7. Bauer M., Horch A., Xie L., Jelali M, Thornhill N. 2016. The current state of control loop performance monitoring – a survey of application in industry // J. Process Control 38: 1-10.
8. Paulonis MA, Cox JW. 2003. A practical approach for large-scale controller performance assessment, diagnosis, and improvement. J. Process Control 13(2): 155-68.
9. Downs JJ, Vogel EF. 1993. Plant-wide industrial process control problem // Comput. Chem. Eng. 17(3):245-55.
10. Wassick JM, Agarwal F., Akiya N., Ferrio J., Bury S., You F. 2012. Addressing the operational challenges in the development, manufacture, and supply of advanced materials and performance products // Comput. Chem. Eng. 47:157-69.
11. Weibull W. 1951. A statistical distribution function of wide applicability // J. Appl. Mech.-Trans. ASME T. 18 (3): 293-297.
12. Bagdonavicius V., Levuliene, R., Nikulin, M. 2010. Goodness-of-fit Criteria for the Cox model from Left Truncated and Right Censored Data // Journal of Mathematical Sciences. 167 (4): 436-443.

Владов Роман Александрович – директор по развитию высокотехнологичных решений и консалтинга (СНГ и страны Каспийского региона), **Дозорцев Виктор Михайлович** – д-р техн. наук, проф., директор по стратегии и развитию бизнеса высокотехнологичных решений, **Шайдуллин Ренат Анварович** – старший консультант по высокотехнологичным решениям, **Белюсов Олег Юрьевич** – консультант по высокотехнологичным решениям АО «Хоневелл». Контактный телефон +7 (495) 761-02-09.