

ИСПОЛЬЗОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРЕДИКТИВНОГО АНАЛИЗА ПРИ ЭКСПЛУАТАЦИИ ПРОИЗВОДСТВЕННЫХ СИСТЕМ

Потехин Вячеслав Витальевич,

кандидат технических наук, доцент, Санкт-Петербургский политехнический университет

Петра Великого, e-mail: Slava.Potekhin@mail.ru

Лядский Даниил Дмитриевич,

Санкт-Петербургский политехнический университет Петра Великого,

e-mail: danillyadskiy@gmail.com

Болотов Сергей Владимирович,

Межгосударственное образовательное учреждение высшего образования

«Белорусско-Российский университет» (Республика Беларусь)

Введение

Современные производственные предприятия нуждаются в получении все большего количества оперативных данных для увеличения производственных мощностей и снижения затрат. Сегодня существуют системы сбора данных типа MES, но нет широко распространенных приложений и практических примеров внедрения систем с возможностями прогнозирования и управления на базе полученных прогнозов. Решением этой проблемы в ближайшем будущем должно стать совместное использование технологий промышленного интернета вещей (IIoT) и машинного обучения на базе MES-систем. Ожидаемый эффект от внедрения таких систем мониторинга и аналитики:

- Снижение процента некачественной продукции;
- Выявление основных факторов, влияющих на появление некачественной продукции;
- Повышение производительности технологических процессов за счет оптимизации энергоресурсов и снижения влияния человеческого фактора на производственный процесс;
- Большая наблюдаемость и предсказуемость всего технологического процесса;
- Снижение стоимости ремонта за счет мониторинга состояния технологического оборудования;

В данной статье рассматриваются основные концепции и практики, применяемые для построения прогнозных и аналитических систем современных производственных предприятий.

Концепция

Целями создания систем на базе технологий IIoT являются [1]:

- Интеграции с системами управления производством на уровне данных;
- Интеграция диагностических моделей и алгоритмов управления надежностью в виде приложений IIoT-среды;
- Мониторинг оборудования;

Основные функции таких систем:

- Формирование динамической модели объекта;
- Формирование диагностических моделей;
- Исполнение модели объекта в режиме реального времени и с ускорением/замедлением;
- Формирование выходных сигналов технического состояния объекта;
- Измерение сигналов с помощью IIoT-устройств;
- Управление режимом мониторинга и диагностирования с помощью локального интерфейса оператора;
- Межсетевое взаимодействие по IIoT-протоколам;
- Обработка данных (EDGE-аналитика);
- Выполнение программной логики обработки данных и формирования выходных сигналов;
- Мониторинг и глубокая аналитика.




Рис. 1. Типовая архитектура умного производства на базе IIoT

MES и машинное обучение

Машинное обучение (ML) – мощный инструмент, который можно использовать для анализа всех форм данных, которые будут получены в процессе производства. Известно, что с помощью MES можно проводить обучение, применимое к широкому спектру производственных процессов. Вместе ML и MES можно комбинировать для извлечения различных данных и, анализируя их, они могут находить закономерности и алгоритмы, которые можно использовать для оптимизации производства [2].

Одним из многочисленных методов машинного обучения являются нейронные сети (НС) [3]. Более ранний способ – это классическое машинное обучение, которое строится на классических статистических алгоритмах и решает вопросы, связанные с принятием решений на основе данных. В классическом машинном обучении применяются такие методы, как метод наименьших квадратов, метод главных компонент и т.д. Основное отличие нейронных сетей от классического машинного обучения состоит в том, что первые самообучающиеся. Нет необходимости человеку писать определенный алгоритм, например алгоритм поиска скрытых закономерностей. У нейронной сети есть определенный принцип, по которому происходит ее обучение, задача человека состоит в том, чтобы предоставить ей определенную выборку для того, чтобы она сама обучалась.

Машинное обучение также можно использовать для обнаружения нарушений в производстве. И таким образом мы можем оценить качество продукта путем интеграции данных производства, контроля и послепродажного обслуживания [4].

Промышленный Интернет вещей (IIoT)

Современные тенденции и вызовы в развитии высокотехнологичных производств связаны с развитием инфраструктуры и сложностью современных производств, их территориальным размещением и разнообразием функционального назначения, что приводит к существенным проблемам при выполнении задач управления [5]. Промышленный Интернет

вещей (ПоТ) – единая концепция, направленная для решения таких задач. ПоТ представляет собой набор технологий для реализации информационной и управляющей систем предприятия, формирующаяся как объединяющая альтернатива:

- Технологий автоматизации – АТ,
- Информационных технологий – ИТ,
- Операционных технологий – ОТ.

Операционные технологии, интегрирующие оперативный и обслуживающий персонал в контуры управления производством, входящие в периметр ПоТ, трансформируются в цифровую рабочую среду, включая носимые устройства, человеко-машинные интерфейсы и приложения систем, поддерживающих принятие решений.

В результате внедрения ПоТ на предприятии создается кросс-функциональная, интероперабельная среда управления, что позволяет повысить эффективность решения основных задач управления производством. При этом для всех задач управления остается часть функций, реализация которых на данном этапе и для конкретного предприятия может быть эффективно реализована с помощью существующих технологий без перехода на технологию ПоТ. Как показывает предварительный анализ, для систем технической диагностики и управления надежностью диапазон применимости технологий ПоТ является одним из самых значительных.

Это определяется следующими факторами:

- Для качественной диагностики и непрерывного мониторинга состояния оборудования, помимо первичных датчиков, входящих в состав системы управления технологическим процессом, часто требуется установка дополнительных датчиков, интеграция которых в систему управления процессом будет неэффективна как с точки зрения стоимости добавления одного канала, так и с точки зрения его дальнейшего обслуживания;
- Построение моделей для прогнозирования технического состояния, расчета остаточного ресурса, анализа причин отказов и пр. требует накопления и обработки больших массивов непрерывных данных, что неэффективно решать как средствами системы управления технологическим процессом, так и стандартными средствами MES, поскольку функции этих систем характеризуются другими значениями дискретизации, глубиной хранения и объемами данных;
- Информация, необходимая для диагностики и управления надежностью, формируется как на уровне АСУТП, так и на уровне MES;
- В задачах технической диагностики и управления надежностью значительный объем операций выполняется персоналом, деятельность которого слабо автоматизирована и плохо интегрирована в информационные системы.

Несмотря на все разговоры о четвертой промышленной революции, некоторые компании до сих пор приобретают и используют промышленное оборудование без использования технологии ПоТ для подключения его к ИТ-системам. Проблема заключается в том, что, когда компании запускают проекты, направленные на подключение промышленного ОТ-оборудования к ИТ-системам, эти проекты часто оказываются в тупике, о чем свидетельствует исследование Cisco, согласно которому три четверти проектов IoT терпят неудачу. Либо в процессе разработки концепции приложения ПоТ (РОС), либо позже, когда эти компании пытаются вывести свои приложения ПоТ из лаборатории в поле. Компании часто сталкиваются с трудностями, которые мешают им разработать или внедрить

приложение. Одна из основных проблем, приводящих к неудаче этих проектов, является сложность создания инфраструктуры ПоТ, необходимой для преодоления разрыва, отделяющего ОТ от ИТ. разрыв, отделяющий ОТ от ИТ [6]. С помощью мобильных и веб-приложений компании могут использовать общие навыки кодирования для создания приложения в облаке, а затем предоставить его пользователям на их уже подключенных смартфонах и ноутбуках. Для разработки и развертывания приложений ПоТ, компании должны построить свой собственный мост между ИТ-системами и конечными точками ОТ-оборудования.

Для этого им необходимо:

- использовать различные коммуникационные протоколы для интеграции встроенных модулей, шлюзов и других периферийных устройств в промышленное оборудование;
- подключать эти периферийные устройства к беспроводным сетям и затем управлять этими подключениями для минимизации затрат на передачу данных и, для периферийных устройств с батарейным питанием, потребления энергии;
- создание API, позволяющих интегрировать данные периферийных устройств в облачные ИТ-системы;
- обеспечение защиты данных путем внедрения политики кибербезопасности и шифрования данных (как на стороне сервера, так и на стороне клиента, а также шифрование при транспортировке) шифрование как на стороне сервера, так и на стороне клиента, а также транспортное шифрование) [7].

Примеры предиктивного анализа

Одним из примеров использования накопленной статистики является разработка прогностических моделей. Это довольно востребованная задача по ряду причин; во-первых, грамотно спроектированная модель способна прогнозировать период износа модели, что позволит более точно планировать время обслуживания, избегая ненужных или внеплановых простоев оборудования. Во-вторых, отсутствие необходимости знания предметной области моделируемого объекта снизит степень квалификации рабочего персонала или затраты на вызов специалистов.

Первый этап подготовки сырых данных – удаление или импутация неопределенных значений и пропусков в данных. Несмотря на то, что многие модели допускают использование неопределенных данных (NA) и пропусков в наборах, лучше удалить их до выполнения основных манипуляций. Эта операция проводится на полном наборе данных и независимо от используемой модели.

Если связь между начальным и конечным диапазонами выражается линейной функцией, то нормирование является линейным. Если используется нелинейная функция (например, экспонента), то нелинейным. При нормировании в данном исследовании ориентировались при нормировке на экстремальные (граничные) значения:

$$\hat{x}_i = \frac{x_i - x_{i,mean}}{x_{i,max} - x_{i,min}} \quad (1)$$

В статистических терминах используется корреляция для обозначения связи между двумя количественными переменными. Также предполагается, что связь является линейной, что одна переменная увеличивает или уменьшает фиксированную величину для увеличения

или уменьшения единицы в другой. Другим методом, который часто используется в этих обстоятельствах, является регрессия, которая включает в себя оценку наилучшей прямой линии для подведения итогов ассоциации.

Степень ассоциации измеряется коэффициентом корреляции, обозначаемым как r . Его иногда называют коэффициентом корреляции Пирсона после его инициатора и является мерой линейной ассоциации [8]. Если для выражения взаимосвязи требуется изогнутая линия, следует использовать другие и более сложные меры корреляции.

Коэффициент корреляции измеряется по шкале, которая варьируется от 1 до 0. Когда одна переменная увеличивается по мере увеличения другой, корреляция является положительной. Полное отсутствие корреляции представлено 0.

Вычисление коэффициента корреляции происходит следующим образом: x представляет значения независимой переменной а y представляет значения зависимой переменной. Используемая формула:

$$r = \frac{\sum(x-\bar{x})(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2 \sum(y-\bar{y})^2}} \quad (2)$$

Метод скользящего среднего – это способ сглаживания временных рядов с целью исключения влияния случайной составляющей. Как правило, метод используется для предварительной обработки исходных данных при прогнозировании и других видах анализа.

Суть этого метода заключается в том, что вместо фактического значения члена ряда подставляется среднее арифметическое значение нескольких ближайших к нему членов. Набор усредняемых значений представляет собой «окно скольжения». Член ряда, фактическое значение которого заменяется на среднее арифметическое, занимает в окне срединное положение [9].

Простое сглаживание представляет собой обычную замену значений членов ряда на среднее арифметическое в рамках соответствующего окна:

$$\bar{X}(k) = \frac{1}{n} \sum_{t=k}^{n+k} X(t), \quad (3)$$

где n – размер окна (период сглаживания), k – номер члена ряда, значение которого заменяется средним.

Базовым методом машинного обучения является метод наименьших квадратов (МНК) – математический подход для оценки параметров моделей (например, регрессионной) на основании экспериментальных данных, содержащих случайные ошибки [10].

Если данные известны с некоторой погрешностью, то вместо неизвестного точного значения параметра модели, используется приближенное. Поэтому параметры модели должны быть рассчитаны так, чтобы минимизировать разницу между экспериментальными данными и теоретическими (вычисленными при помощи предложенной модели).

Мерой рассогласования между фактическими значениями и значениями, оцененными моделью в методе наименьших квадратов, служит сумма квадратов разностей между ними, т.е.:

$$\delta_i = (\varphi(x_i) - y_i)^2, \quad (4)$$

где $\varphi(x_i)$ – оценка, полученная с помощью модели, y – фактическое наблюдаемое значение. Очевидно, что лучшей будет та модель, которая минимизирует данную сумму. Для случая уравнения прямой эта сумма равна:

$$S = \sum_{i=1}^m \delta_i^2 = \sum_{i=1}^m [(a_0 + a_1 x_i) - y_i]^2. \quad (5)$$

Для нахождения минимума функции S необходимо приравнять нулю ее частные производные. В результате получим систему уравнений:

$$\begin{cases} \frac{\partial S}{\partial a_0} = 0 \\ \frac{\partial S}{\partial a_1} = 0 \end{cases} \quad (6)$$

Подобным образом функцию можно распространить на полином степени n [11]. Для решения задачи аппроксимации также можно использовать приближенный метод градиентного спуска. Градиентный спуск – метод численной оптимизации, который может быть использован во многих алгоритмах, где требуется найти экстремум функции – нейронные сети, SVM, k-средних, регрессии. Используя метод градиентного спуска и (5) можно получить формулу для нахождения неизвестных параметров:

$$a_j^{n+1} = a_j^n - h \frac{\partial S}{\partial a_j^n} = a_j^n + h \sum_{i=0}^k (\varphi(x^i) - y^i) x_j^i \quad (7)$$

Взяв шаг h достаточно маленьким и большое количество циклов n , получим результаты, близкие к точным вычислениям (6). Данный метод будет использоваться нейронной сетью, с поправкой на то, что вместо коэффициентов линейного уравнения a , будут пересчитываться веса нейронной сети w , благодаря методу обратного распространения ошибки.

Одним из многочисленных методов машинного обучения являются нейронные сети (НС) [12]. Основное отличие нейронных сетей от классического машинного обучения состоит в том, что первые самообучающиеся. Нет необходимости человеку писать определенный алгоритм, например алгоритм поиска скрытых закономерностей. У нейронной сети есть определенный принцип, по которому происходит ее обучение, задача человека состоит в том, чтобы предоставить ей определенную выборку для того, чтобы она сама обучалась. Увеличивая количество слоев в нейронной сети, усложняется ее архитектура, увеличивается количество весов – такой тип сети относится к методам глубокого обучения.

Разработка двухнедельных прогнозных моделей уровня концентраций кислородсодержащих газов осуществлялась на основе переданной статистики 39 масляных трансформаторов. Для решения этой задачи использовались методы анализа и машинного обучения, описанные выше. В первую очередь из массива данных были отобраны трансформаторы с более полной накопленной статистикой и сопоставлены данные двух систем мониторинга, отвечающих за масляные и электрические параметры. Кроме того, обработка необработанных данных была выполнена путем стандартизации данных и удаления выбросов. Путем анализа данных была найдена зависимость прогнозируемых параметров (концентрация газа) от технологических параметров (температура, влажность, токи нагрузки) и получен основной прогнозный коэффициент.




Рис. 2. Расчет коэффициентов корреляции Пирсона

Важно отметить, что прогнозирование концентраций газов не должно происходить по временному ряду, т.е. прогнозирование концентрации не должно происходить по времени. Т.к. в этом случае все предварительные исследования бессмысленны, а концентрация выступает в роли случайной величины и хорошую точность в таком случае получить невозможно.

В ходе анализа было выяснено, что концентрации газов в наибольшей степени зависят от температуры окружающей среды и зависимость эта нелинейная. Далее был предложен алгоритм прогнозирования на основе кусочно-линейных функций. Идея метода заключается в том, чтобы разбить параметр температуры на несколько линейных сегментов и использовать их для предсказания концентрации газов. Зная характер нелинейной зависимости температуры от концентраций, был написан алгоритм подстановки кусочно-линейной функции вместо нелинейного участка прогнозирования. Температура прекрасно подходит для этой цели еще и тем, что имеет строго периодический характер. Так как полученные модели описывают зависимости концентрации от температуры, то для того, чтобы спрогнозировать концентрацию линейно-кусочной функцией, необходимо знать прогноз температуры. Сделать это можно двумя способами: либо математическими методами, либо с помощью прогноза погоды на территории, на которой находится трансформатор. Когда получен прогноз температуры, можно завершить весь проделанный цикл и спрогнозировать концентрацию.




Рис. 3. Прогноз концентрации CO_2 с помощью

Кроме того, модель, полученная на одном трансформаторе, может быть перенесена на прогноз другого трансформатора. Таким образом, можно сказать, что предложенный алгоритм работает успешно. Кроме того, он также успешно используется для прогнозирования других газов (CO , CO_2).

Концентрация газов зависит не только от температуры, но и от других газов, влажности, нагрузки на сеть. При использовании данной методики не учитывается влияние этих параметров, что может сильно повлиять на точность прогноза. Чтобы компенсировать этот недостаток был использован метод нейронных сетей (НС).




Рис. 4. Прогноз концентрации азота по нескольким параметрам с помощью НС

В результате были разработаны и применены методики, основанные на методах машинного обучения, для прогнозирования загазованности 39 масляных трансформаторов, как аналог классических методов анализа растворенных газов [13]. Такой подход позволяет создавать модели (цифровые двойники) производственных объектов, в данном случае масляных трансформаторов, что полностью автоматизирует мониторинг состояния объекта, а также строит прогнозные модели состояния объекта на некоторое время вперед. Такой подход позволит снизить требования к квалификации сотрудников, а также организовать плановые ремонтные работы на объекте.

Заключение

Проблемой современных киберфизических систем управления является неэффективное использование и обработка получаемой информации. Проблемы решаются за счет использования технологий ПоТ для сбора данных и технологий машинного обучения для обработки данных. В результате изучения и выполнения ряда практических задач были разработаны: целевая архитектура систем ПоТ и предиктивная модель анализа данных. Машинное обучение и ПоТ станут инструментами, которые помогут MES стать более эффективной. Эта система будет проще в использовании, чем другие системы, доступные в настоящее время, и это позволит контролировать производство.

Положительными результатами реализации предложенных идей будут:

- накопление и обработка знаний о промышленных объектах;
- снижение затрат на модернизацию производства;
- снижение затрат на ремонт оборудования.

Список литературы:

1. Kostenko, Dmitry & Kudryashov, Nikita & Maystrishin, Mihail & Onufriev, Vadim & Potekhin, Vyacheslav & Vasilev, Aleksey. (2018). Digital Twin Applications: Diagnostics, Optimisation and Prediction. 10.2507/29th.daaam.proceedings.083.
2. Potekhin, Vyacheslav & Bahrami, AH & Katalinič, B. (2020). Developing manufacturing execution system with predictive analysis. IOP Conference Series: Materials Science and Engineering. 966. 012117. 10.1088/1757-899X/966/1/012117.
3. Круг П. Г., Нейронные сети и нейрокомпьютеры: Учебное пособие по курсу «Микропроцессоры». – М.: Издательство МЭИ, 2002. – 176 с.
4. Ko, Taehoon & Lee, Je & Cho, Hyunchang & Cho, Sungzoon & Lee, Wounjoo & Lee, Miji. (2017). Machine learning-based anomaly detection via integration of manufacturing, inspection and after-sales service data. Industrial Management & Data Systems. 117. 10.1108/IMDS-06-2016-0195.
5. Katalinič, Branko & Kostenko, Dmitry & Onufriev, Vadim & Potekhin, Vyacheslav. (2020). Cyber-Physical Systems in Complex Technologies and Process Control. 10.1007/978-3-030-34983-7_5.
6. Jo, Ohyun & Kim, Yong-Kyu & Kim, Juyeop. (2017). Internet of Things for Smart Railway: Feasibility and Applications. IEEE Internet of Things Journal. PP. 1-1. 10.1109/JIOT.2017.2749401.
7. Gastermann, Bernd & Stopper, Markus & Kossik, Anja & Katalinic, Branko. (2015). Secure Implementation of an On-premises Cloud Storage Service for Small and Medium-sized Enterprises. Procedia Engineering. 100. 10.1016/j.proeng.2015.01.407.

8. Гмурман В. Е. Теория вероятностей и математическая статистика: Учебное пособие для вузов. – 10-е издание, стереотипное. – Москва: Высшая школа, 2004. – 479 с.
9. Грешилов А. А., Стакун В. А., Стакун А. А. Математические методы построения прогнозов. – М.: Радио и связь, 1997. – 112 с.
10. Магнус Я. Р., Катышев П. К., Пересецкий А. А., Эконометрика. Начальный курс. – М.: Дело, 2007. – 576 с.
11. Кремер Н. Ш., Путко Б. А. Эконометрика. – М.: Юнити-Дана, 2003—2004. – 329 с.
12. Nikhil Buduma, Nicholas Locascio. Fundamentals of Deep Learning: Designing Next-generation Machine Intelligence Algorithms – O'Reilly Media, 2017. – 283 с.
13. Методические указания по техническому диагностированию развивающихся дефектов маслонаполненного высоковольтного электрооборудования по результатам анализа газов, растворенных в минеральном трансформаторном масле. – стандарт организации ПАО «РОССЕТИ», 2019. – 63 с.