

Краткий обзор стандарта ISO 19283:2020

В апреле 2020 года международная организация по стандартизации (ISO) приняла стандарт ISO 19283:2020 “Condition monitoring and diagnostics of machines - Hydroelectric generating units” (Обслуживание по состоянию электрических машин - гидроагрегаты), являющийся уточняющим по отношению к целому ряду действующих стандартов ISO, касающихся общих рекомендаций по обслуживанию машин по состоянию. Стандарт описывает комплексный подход к диагностике состояния гидроагрегатов на основании мониторинга и диагностики составных элементов по комплексному набору параметров.

Стандарт в первую очередь ориентирован на агрегаты установленной мощностью более 50 МВА, но отдельные его положения могут применяться и к меньшим агрегатам. Стандарт распространяется на основные элементы агрегата: генератор, вал, подшипники вала, рабочее колесо, напорный трубопровод, спиральную камеру, отсасывающую трубу. Дополнительные системы агрегата, такие как система смазки или охлаждения, вынесены за рамки стандарта.

Стандарт описывает системы мониторинга и диагностики, работающие в онлайн режиме, а также переносные (портативные) системы. Системы оффлайн мониторинга в стандарте не рассматриваются.

В стандарте выделяются основные элементы агрегата и присущие им методы мониторинга:

- генератор - мониторинг воздушного зазора и магнитного потока, анализ частичных разрядов, параметров статора (вибрация сердечника и корпуса, температура сердечника и т.п.), вибрации лобовых частей;
- вал (включая подшипники вала) - мониторинг тока и напряжения, анализ охлаждающего масла, вибрации, температуры, протечек уплотнений;
- напорный трубопровод - мониторинг вибрации шпилек поворотного затвора, состояние колонн статора, вибрации инжектора, мониторинг кавитаций и гидравлических возмущений, синхронизации рабочего колеса (для ковшовых турбин), вибрации корпуса (для капсульных турбин);
- турбина - контроль зазора между лопатками (для капсульных и поворотно-лопастных турбин), состояния лабиринтовых уплотнений (для поворотно-лопастных турбин), вибрации крышки (для поворотно-лопастных турбин), мониторинг рабочих параметров, кавитаций и гидравлических возмущений;
- отсасывающая труба - мониторинг кавитаций и гидравлических возмущений, параметров трубы (давление и вибрация).

Для контроля этих параметров стандарт выделяет ряд измерений, называемых дескрипторами. Общий перечень дескрипторов для мониторинга состояния гидроагрегата состоит из следующего:

- мониторинг воздушного зазора;
- мониторинг магнитного потока;
- анализ частичных разрядов;
- мониторинг вибрации лобовых частей;
- мониторинг зазора между лопатками (для поворотно-лопастных и капсульных турбин);
- состояние лабиринтовых уплотнений (зазор и температура, для радиально-осевых турбин);
- мониторинг производительности агрегата (КПД, мощность).

Для каждого из типов мониторинга стандарт определяет рекомендации к датчикам, измерительным системам, способам анализа.

Наряду с методами диагностики, в стандарте также отмечается важность мониторинга рабочих параметров агрегата и их корреляции с диагностическими дескрипторами. Такой анализ является важной частью выработки стратегии обслуживания агрегата по состоянию и поможет в выработке аварийных уставок для каждого агрегата и в сравнительном анализе данных нескольких агрегатов.

Важной частью выбора систем мониторинга является анализ не только собственно требований к диагностическому функционалу и возможной экономической выгоды от внедрения, но и сопутствующих требований, среди которых: защита информации, возможности интеграции в информационные системы, время, требуемое для установки, необходимость обучения обслуживающего персонала.

В стандарте также указываются направления дальнейшего развития нормативной базы по обслуживанию гидроагрегатов. В частности, отмечается разрабатываемые в настоящее время стандарты по анализу причин неисправностей и прогнозирования состояния агрегата.

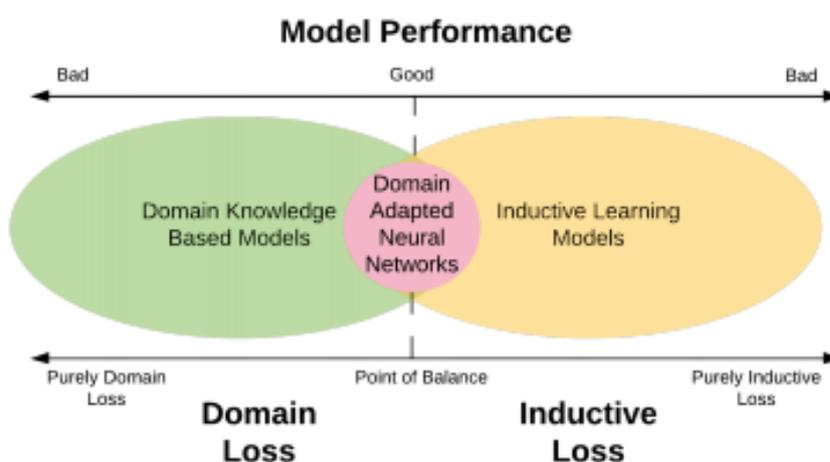
Использование машинного обучения с отраслевыми знаниями при диагностике оборудования

Развитие технологий Индустрии 4.0 открывает новые возможности во всех областях современной промышленности. В частности, в области мониторинга и диагностики состояния электрооборудования такие технологии, как цифровой двойник или модели диагностики, использующие машинное обучение, открывают новые возможности анализа состояния машин. Такие модели анализируют данные измерений различных параметров оборудования для определения аномальных данных, оценки и прогнозирования развития состояния оборудования.

Вместе с тем, индустрия диагностики оборудования базируется на действующих отраслевых стандартах, которые ставят в соответствие набору диагностических признаков оценку состояния оборудования. Это хорошо иллюстрирует, например, СТО ФСК 34.01-23-003-2019, где состояние силового трансформатора определяется по набору таких критериев, как отношение концентраций характерных газов.

При этом оба подхода существуют во многом обособленно. Традиционные компании, работающие в области мониторинга оборудования, не всегда обладают достаточными ресурсами для внедрения моделей машинного обучения, а компании, обладающие такими компетенциями, не всегда готовы погружаться в специфику отраслевой диагностики.

Очевидно, что использование комбинированного подхода смогло бы объединить в рамках одной модели сильные стороны обоих подходов. В исследовании [1] схематично показано условное преимущество от использования подобных комбинированных моделей. В общем виде, отдельные модели, использующие только отраслевую диагностику, как и модели, использующие только машинное обучение, могут давать результаты с различной достоверностью. Однако наилучшей достоверности будут достигать модели, использующие комбинированный подход, как показано на рисунке ниже.



Как же строятся модели, использующие комбинированный подход? Эта тема достаточно сложна и ей посвящаются отдельные исследования. Рассмотрим этот подход на примере нейронных сетей, которые являются одними из самых популярных из десятков существующих алгоритмов машинного обучения.

Нейронные сети принадлежат к группе алгоритмов обучения с учителем. Такие алгоритмы используют заранее подготовленные наборы данных, где указано, какие выходные данные сети должны соответствовать различным наборам входных данных. При обучении выполняется настройка параметров сети таким образом, чтобы в результате

выполнения сети получаемые выходные данные для каждого набора входов максимально близко соответствовали эталонным значениям, т.е. тем, на которых сеть обучается. Для каждой сети существует функция потерь, показывающая, насколько сильно фактические выходы сети отклоняются от эталонных. Чем выше отклонения, тем больше значение функции потерь, а задача обучения нейронной сети сводится к оптимизации значения функции потерь в зависимости от параметров сети. В целом, в качестве функции потерь нейронной сети можно использовать почти какую угодно функцию, но диапазон фактически применяемых функций достаточно стандартизован.

Подход, реализующий принцип объединения нейронных сетей и отраслевых знаний, был применён в исследовании [1]. В исследовании рассматривался абстрактный физический процесс, описываемый набором параметров. Исследователи ставили задачу моделирования параметра процесса на основе измерения набора параметров, влияющих на исследуемый. В качестве модели использовалась нейронная сеть, учитывающая знания о физической природе рассматриваемых параметров: значения параметров, могут изменяться только в пределах нижней и верхней границы, а также параметры могут иметь монотонную зависимость, т.е. при росте одного другой также должен расти. В исследовании показан процесс построения такой модели, суть которого выражалась в подборе функции потерь нейронной сети таким образом, чтобы она увеличивала своё значение в тех случаях, когда сформулированные физические зависимости между параметрами не выполнялись. Таким образом, нейронная сеть “была вынуждена” поддерживать эти зависимости в выходных данных. Результаты выполнения модели были оценены на искусственно сгенерированном наборе данных, в который намеренно были добавлены зашумлённые данные и данные с нарушениями монотонной зависимости между параметрами, а также на данных о растворимости кислорода в воде, которая зависит от температуры, солёности и давления. При тестировании такая модель давала более точные результаты, чем модель, использующая только нейронные сети.

Более сложный подход использовался в исследовании [2]. В исследовании решалась задача моделирования температуры озера на заданной глубине. Сама по себе эта величина зависит от множества процессов, таких как нагрев поверхности озера от солнечного излучения, перемешивания воды в озере, остывании озера из-за испарения. Параметры многих из этих процессов сложно или вообще невозможно контролировать, поэтому задача точного математического моделирования температуры крайне сложна. В исследовании отмечается, что достаточного уровня точности всё же удаётся добиться, используя общие модели, откалиброванные на данных, собранных с относительно небольшого количества, несколько десятков, озёр. В то же время, при попытке масштабирования модели на большое количество (тысячи) озёр, точность сильно снижается. Исследователи предложили подход, заключающийся в дополнении входных данных нейронной сети результатами общей физической модели изменения параметров озера на заданной глубине. Вторым новшеством являлось дополнение функции потерь нейронной сети данными о физических взаимосвязях между температурой и плотностью воды, а также плотностью воды от глубины измерения. В результате выполнения такой модели точность оказалось лучше точности как модели, построенной на физическом описании процесса, так и модели, основанной только на машинном обучении.

Таким образом, методики построения моделей, объединяющих в себе сильные стороны как подхода, построенного на машинном обучении, так и подхода, построенного на физическом описании рассматриваемых процессов, существуют и активно разрабатываются. Применимо к мониторингу электрооборудования, такой подход сможет избежать ситуаций, когда, либо модель машинного обучения даёт безупречный результат с точки зрения математического анализа временных рядов параметров, но бессмысленный с точки зрения отраслевых знаний об исследуемом процессе, либо модель, построенная на описании физики процесса, требует слишком большого набора параметров для получения достоверных результатов и в принципе не способна как-либо учитывать фактическое развитие состояния контролируемого оборудования. Примерами отраслевых знаний, которые можно использовать в подобном комбинированном подходе, могут являться знания о том, что с увеличением скорости вращения вала двигателя уровень вибрации на нём повышается, или о том, что с повышением нагрузки трансформатора

температура верхних слоёв масла также будет расти. Оба примера являются примерами монотонной зависимости, которая встраивалась в модель в исследовании [1].

Безусловно, дальнейшее развитие методов анализа данных будет продолжаться нарастающими темпами, но вопросы совмещения методов анализа и отраслевых знаний не будут терять актуальность. Описанные в этой статье подходы в перспективе помогут объединить оба подхода и вывести качество диагностики электрооборудования на новый уровень.

Источники

1. *Muralidhar, Nikhil & Islam, Mohammad & Marwah, Manish & Karpatne, Anuj & Ramakrishnan, Naren. (2018). Incorporating Prior Domain Knowledge into Deep Neural Networks. 36-45. 10.1109/BigData.2018.8621955.*
2. *Karpatne, Anuj & Watkins, William & Read, Jordan & Kumar, Vipin. (2017). Physics-guided Neural Networks (PGNN): An Application in Lake Temperature Modeling.*

Подходы к предиктивному обслуживанию солнечных панелей

С неуклонным ростом возобновляемой энергетики также растёт роль систем обслуживания по состоянию и предиктивной аналитики энергетических установок. В этой статье мы рассмотрим современные тенденции развития таких систем применительно к фотоэлектрическим установкам. Статья в большой степени основывается на [1] с небольшими вставками от авторов.

Исследователи в материале [1] выделяют четыре основных подхода к обслуживанию установок солнечных электростанций:

- на основе ручных измерений;
- на основе анализа видов и последствий отказов;
- на основе машинного обучения;
- на основе оперативных измерений.

Системы ручной диагностики основываются на периодических измерениях отдельных параметров солнечных панелей. К таким параметрам относят степень загрязнения поверхности панелей, вольт-амперные и температурные характеристики. Широко применяется термографирование солнечных панелей при помощи дронов. Такие измерения не позволяют реализовывать сложные методы аналитики, при этом требуя наименьших затрат на внедрение.

При подходе на основе анализа видов и последствий отказов (FMEA) определяются наиболее уязвимые компоненты на основании массивов о повреждениях и отказах существующих установок. В частности, в разных исследованиях было определено, что уязвимыми компонентами являются инвертор, система заземления, системы мониторинга и связи. На основании этих данных строится модель предиктивного обслуживания установки, позволяющая спланировать оптимальное количество запчастей, расходных материалов или обслуживающего персонала для минимизации времени простоя в случае поломок или необходимости обслуживания.

Системы мониторинга на основе машинного обучения используют алгоритмы машинного обучения для исследования и прогнозирования ключевых факторов, влияющих на производительность солнечных панелей. Среди таких факторов ключевым является уровень солнечного излучения, помимо которого также прогнозируют температуру и давление воздуха. Подход позволяет эффективнее управлять солнечными электростанциями на основе прогнозирования их производительности на отдельных временных промежутках.

Системы обслуживания на основе онлайн-измерений параметров солнечных панелей позволяют как проводить диагностику текущего состояния, так и реализовывать автоматическое управление солнечными панелями. Диапазон параметров, доступных для измерения на солнечных электростанциях достаточно обширен и включает в себя параметры генерируемой мощности, данные об ориентации панелей в пространстве, данные вспомогательных систем (система смазки, гидропривода), температурные параметры, параметры работы инверторов, данные о текущих погодных условиях. Все эти измерения позволяют выполнять диагностирование состояния солнечных панелей и реализовывать комплексные алгоритмы автоматического управления, чему способствует

также развитие технологий беспроводной передачи данных и промышленного Интернета вещей.

Объединением преимуществ двух последних подходов может считаться применение к солнечным панелям технологии цифровых двойников, в рамках которого используются данные измерений параметров панелей и современные методы анализа данных для построения полнофункциональных моделей солнечных электростанций. Коммерческие продукты такого рода уже доступны на рынке, например, SunSat от компании Reuniwatt [2] или Apollo от Pratiti Technologies [3].

Несмотря на стремительный рост солнечной генерации, методы долгосрочного планирования и управления жизненным циклом солнечных панелей часто не получает достаточного внимания. Тем не менее, дальнейшее развитие этих методов будет идти ускоряющимися темпами, чему также будет способствовать развитие сопутствующих технологий Индустрии 4.0.

Источники

1. *L. Bosman, W. Leon-Salas et al. PV System Predictive Maintenance: Challenges, Current Approaches, and Opportunities. MDPI Energies, 17 March 2020.*
2. *Reuniwatt: SunSat* <https://reuniwatt.com/en/sunsat-digital-twin/>
3. *Pratiti Technologies: Apollo* <https://www.pratititech.com/solutions/solar-energy-monitoring-software-system-using-iot>