

РАЗРАБОТКА НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ ОЦЕНКИ «ИНДЕКСА ЗДОРОВЬЯ» ТРАНСФОРМАТОРНОГО ОБОРУДОВАНИЯ

К.Н. Канатьев, Нижегородский государственный университет им. Н.И. Лобачевского, basket-player@yandex.ru;

С.Р. Шишкин, Московский технический университет связи и информатики, sergeyshishkin62@gmail.com;

И.С. Дорофеев, Московский государственный технический университет им. Н.Э. Баумана, ildorof@yandex.ru.

УДК 621.314

Аннотация. В данной работе представлена разработка нейросетевой модели, направленной на оценку «индекса здоровья» трансформаторного оборудования в энергетических системах. Традиционные подходы к диагностике и мониторингу трансформаторов часто не позволяют своевременно выявлять начинающиеся неисправности, что может привести к серьезным последствиям. В ответ на эти вызовы, в работе исследуются возможности применения современных методов искусственного интеллекта и машинного обучения, включая обучение с учителем, обучение без учителя и обучение с подкреплением, для создания комплексной системы оценки состояния оборудования. Разработанная модель предназначена для анализа данных с датчиков, установленных на трансформаторах, и способна предсказывать потенциальные неисправности, оптимизировать процессы технического обслуживания и повысить надежность энергосистем.

Ключевые слова: трансформаторное оборудование; искусственный интеллект машинное обучение; нейросетевая модель; оценка состояния; диагностика неисправностей; мониторинг оборудования.

DEVELOPMENT OF A NEURAL MODEL FOR ASSESSING THE HEALTH INDEX OF TRANSFORMER EQUIPMENT

Konstantin Kanatjev, Lobachevsky Nizhny Novgorod State University;

Sergey Shishkin, Moscow Technical University of Communications and Informatics;

Iliia Dorofeev, Bauman Moscow State Technical University.

Annotation. This paper presents the development of a neural network model aimed at assessing the health index of transformer equipment in power systems. Traditional approaches to diagnostics and monitoring of transformers often fail to timely detect emerging faults, which can lead to serious consequences. In response to these challenges, this work explores the possibilities of applying modern artificial intelligence and machine learning methods, including supervised learning, unsupervised learning, and reinforcement learning, to create a comprehensive system for assessing the condition of the equipment. The developed model is designed to analyze data from sensors installed on transformers and is capable of predicting potential faults, optimizing maintenance processes, and increasing the reliability of power systems.

Keywords: transformer equipment; artificial intelligence; machine learning; neural network model; condition assessment; fault diagnosis; equipment monitoring.

Введение

Трансформаторное оборудование играет важнейшую роль в распределительных сетях, обеспечивая необходимое преобразование электроэнергии для ее эффективной передачи и потребления. Однако, из-за своей

критической роли и высоких требований к бесперебойной работе, трансформаторы становятся уязвимыми звеньями системы, где любой сбой может привести к серьезным последствиям, включая экономические потери и риски для безопасности.

Традиционные методы диагностики и мониторинга трансформаторов основаны на регулярных физических осмотрах и анализе рабочих параметров, таких как температура, уровень изоляционного масла и электрические характеристики. Хотя эти методы оказались эффективными в определенных аспектах, они не всегда могут своевременно выявить начинающиеся неисправности или предсказать вероятность будущих отказов.

В последние годы значительные достижения в области искусственного интеллекта и машинного обучения открыли новые возможности для совершенствования систем мониторинга и диагностики. Использование нейронных сетей для анализа данных с датчиков позволяет не только обнаруживать сложные шаблоны и аномалии, которые могут указывать на потенциальные неисправности, но и предсказывать будущие события на основе обработки больших объемов исторических данных.

Целью данного исследования является разработка инновационной нейросетевой модели, способной анализировать разнообразные данные о состоянии трансформаторного оборудования для оценки его «индекса здоровья». Этот подход предполагает создание комплексной системы, которая будет способствовать не только предотвращению возможных неисправностей и снижению риска аварийных ситуаций, но и оптимизации процессов технического обслуживания, повышению эффективности использования оборудования и, в конечном итоге, улучшению качества и надежности электроснабжения.

Выбор архитектуры модели

Для достижения поставленных целей было решено рассмотреть несколько типов нейронных сетей, каждая из которых обладает своими преимуществами в обработке временных рядов и многомерных данных. В итоге, внимание было сосредоточено на следующих архитектурах:

- Сверточные нейронные сети (*CNN*)

Благодаря своей способности выявлять иерархические шаблоны в данных, эти сети идеально подходят для анализа изображений и могут быть применены для обработки временных рядов, представленных в виде «изображений» активности параметров оборудования.

- Рекуррентные нейронные сети (*RNN*) и сети с долгой кратковременной памятью (*LSTM*)

Эти архитектуры показывают высокую эффективность в анализе временных рядов благодаря своей способности сохранять информацию из предыдущих шагов, что критически важно для отслеживания динамики изменений в работе трансформаторов.

В табл. 1 приведен анализ нейронных сетей.

Таблица 1.

Тип нейронной сети	Преимущества	Подходит для
Сверточные нейронные сети (<i>CNN</i>)	Идеально подходят для анализа изображений и могут быть применены для обработки временных рядов, представленных в виде	Анализа изображений, обработки временных рядов в формате изображений.

Тип нейронной сети	Преимущества	Подходит для
	«изображений» активности параметров оборудования.	
Рекуррентные нейронные сети (<i>RNN</i>)	Эффективны в анализе временных рядов, могут обрабатывать данные с временными зависимостями, благодаря способности возвращать информацию на предыдущие шаги.	Анализа временных рядов с короткими временными зависимостями.
Сети с долгой кратковременной памятью (<i>LSTM</i>)	Подобно <i>RNN</i> , но с улучшенной способностью к сохранению информации на длительные периоды без затухания, что критически важно для отслеживания динамических процессов.	Анализа временных рядов с длительными временными зависимостями и комплексной динамикой.

Данная таблица подчеркивает уникальные характеристики каждой архитектуры нейронной сети и их пригодность для определенных видов анализа данных. В контексте мониторинга и диагностики трансформаторного оборудования, выбор между этими архитектурами будет зависеть от специфики задачи, доступности данных и желаемой точности предсказаний.

Методы обучения

В разработке модели были применены следующие подходы к обучению:

- Обучение с учителем. Данная методика была выбрана для первоначального обучения модели на основе исторических данных, содержащих аннотации о состоянии оборудования. Это позволило эффективно настроить параметры модели для распознавания специфических шаблонов, ассоциируемых с различными состояниями трансформаторов.
- Обучение без учителя. Для дальнейшего уточнения модели и выявления неизвестных или ранее не встречавшихся шаблонов поведения оборудования применялся подход без учителя. Это позволило обнаружить скрытые корреляции и аномалии в данных, которые могут указывать на начинающиеся неисправности.
- Обучение с подкреплением. В качестве экспериментальной методики рассматривалось обучение с подкреплением для оптимизации процесса принятия решений моделью в реальном времени. Этот подход предполагает корректировку поведения модели на основе обратной связи от энергетической системы, что позволяет постоянно совершенствовать качество предсказаний.

Сбор и подготовка данных для нейросетевой модели

В основе успешного создания и функционирования нейросетевой модели для оценки «индекса здоровья» трансформаторного оборудования лежит качественно подготовленный и всесторонний набор данных. Важность этого этапа обусловлена необходимостью обучения модели распознаванию широкого спектра условий работы оборудования, включая нормальные рабочие параметры и признаки потенциальных неисправностей.

Данные для обучения и тестирования модели могут быть собраны из различных источников:

- *Исторические данные.* Архивные записи о работе трансформаторного оборудования, включая отчеты о неисправностях, данные о регулярных

технических осмотрах, анализы изоляционного масла и результаты электрических измерений.

- *Данные с датчиков.* Современное трансформаторное оборудование обычно оснащено множеством датчиков, собирающих реальные данные во время эксплуатации. Это могут быть показатели температуры, давления, уровня изоляционного масла, параметры электрической нагрузки и многие другие.

Подготовка данных включает несколько ключевых этапов, каждый из которых играет важную роль в создании эффективной модели:

- *Очистка данных.* На этом этапе данные очищаются от аномалий, ошибок измерений и прочих артефактов, которые могут исказить результаты обучения. Это включает удаление или коррекцию выбросов, а также обработку пропущенных значений.
- *Нормализация.* Данные из различных источников и с разных датчиков могут иметь различный масштаб, что может негативно сказаться на процессе обучения. Нормализация данных помогает привести все показатели к единому масштабу, облегчая тем самым задачу для нейросети.
- *Преобразование данных.* В зависимости от выбранной архитектуры нейросети, может потребоваться преобразование собранных данных в определенный формат. Например, для *CNN* временные ряды могут быть преобразованы в «изображения» активности параметров, в то время как для *RNN* или *LSTM* данные представляются в виде последовательностей.
- *Разделение данных.* Наконец, готовый датасет разделяется на обучающую, валидационную и тестовую выборки. Это позволяет не только обучить модель, но и оценить ее способность к обобщению на новых данных.

Предварительная обработка данных в контексте разработки нейросетевой модели

Предварительная обработка данных является неотъемлемой частью процесса подготовки к обучению нейросетевой модели. Этот этап направлен на улучшение качества данных путем их очистки, нормализации и преобразования, что в свою очередь способствует повышению точности и эффективности обучения. Рассмотрим подробнее каждый из аспектов предварительной обработки данных.

Очистка данных от шума и аномалий является первым шагом в процессе предварительной обработки. Шум может появляться в результате ошибок измерения, неисправностей датчиков или внешних помех. Для идентификации и удаления шума применяются различные методы, включая статистический анализ, фильтрацию и использование алгоритмов машинного обучения, способных распознавать и исключать аномальные значения из набора данных.

Пропущенные значения в данных могут возникать по различным причинам, включая сбои в работе датчиков и ошибки при сборе или передаче данных. Существует несколько подходов к заполнению пропусков, среди которых:

- Использование средних значений или медиан по соответствующим параметрам.
- Применение методов интерполяции для восстановления отсутствующих значений на основе соседних по времени записей.
- Использование алгоритмов машинного обучения для предсказания пропущенных значений, учитывая зависимости между различными параметрами.

Нормализация данных предполагает приведение всех измерений к единому масштабу, что необходимо для корректной работы большинства алгоритмов машинного обучения. Это достигается путем преобразования значений каждого признака таким образом, чтобы их распределение имело заданное среднее значение и стандартное отклонение, либо путем масштабирования в заданный диапазон. Нормализация улучшает сходимость алгоритмов обучения и повышает общую точность модели.

Завершающим этапом предварительной обработки является преобразование данных в формат, наиболее подходящий для выбранной архитектуры нейросети:

- Для *CNN* временные ряды могут быть преобразованы в «изображения» активности параметров оборудования, позволяя модели эффективно выявлять сложные шаблоны и зависимости.
- Для рекуррентных нейронных сетей (*RNN*) и сетей с долгой кратковременной памятью (*LSTM*) данные подготавливаются в виде последовательностей, что позволяет учитывать временные зависимости между различными наблюдениями.

Обучение нейросетевой модели для диагностики трансформаторного оборудования

В разработке нейросетевой модели для оценки состояния трансформаторного оборудования ключевым этапом является обучение, в ходе которого модель «изучает» закономерности в данных, позволяющие ей делать точные предсказания и выявлять потенциальные неисправности. В зависимости от специфики задачи и характера доступных данных, могут быть применены различные подходы к обучению: обучение с учителем, обучение без учителя и обучение с подкреплением. Каждый из этих методов имеет свои особенности и области применения.

Обучение с учителем предполагает наличие размеченного набора данных, где каждому входному образцу соответствует определенный «правильный» ответ (например, указание на нормальное состояние оборудования или на конкретный вид неисправности). В процессе обучения модель стремится минимизировать различие (ошибку) между своими предсказаниями и реальными данными, постепенно улучшая свою способность к распознаванию различных состояний оборудования. Этот подход особенно эффективен при наличии обширного и хорошо размеченного датасета, позволяя модели достигать высокой точности в задачах классификации и регрессии.

В отличие от обучения с учителем, обучение без учителя не требует наличия размеченных данных. Вместо этого модель анализирует входные данные, пытаясь самостоятельно выявить в них закономерности, группы похожих объектов или аномалии. Этот метод часто используется для задач кластеризации, снижения размерности данных и обнаружения аномалий. В контексте мониторинга трансформаторного оборудования обучение без учителя может помочь выявить нестандартные модели поведения оборудования, которые могут указывать на начинающиеся неисправности.

Обучение с подкреплением отличается от предыдущих подходов тем, что модель обучается на основе взаимодействия с окружающей средой, стремясь максимизировать некоторый кумулятивный выигрыш или «награду». В контексте диагностики оборудования этот метод может быть использован для оптимизации процессов принятия решений, например, для определения оптимального графика технического обслуживания на основе текущего состояния оборудования и его эксплуатационной истории. Обучение с подкреплением позволяет модели

адаптироваться к изменениям в работе оборудования, постепенно улучшая стратегию принятия решений.

Заключение

Разработка нейросетевой модели для оценки «индекса здоровья» трансформаторного оборудования демонстрирует значительный потенциал применения методов искусственного интеллекта и машинного обучения в энергетической отрасли. Применение такой модели позволяет не только повысить эффективность и надежность диагностики состояния оборудования, но и способствует оптимизации процессов технического обслуживания, снижению риска возникновения аварийных ситуаций и улучшению общей безопасности и устойчивости энергосистем. Результаты исследования показывают, что интеграция современных технологий в процессы мониторинга и управления состоянием трансформаторного оборудования открывает новые горизонты для повышения эффективности и надежности энергетической инфраструктуры.

Литература

1. Красноярская ГЭС // Википедия URL: ru.wikipedia.org/wiki/Красноярская_ГЭС (дата обращения: 15.01.2023).
2. История строительства Красноярской ГЭС // 6000megawatt.kkkm.ru URL: 6000megawatt.kkkm.ru/ (дата обращения: 15.01.2023).
3. Красноярская ГЭС // Ассоциация «Гидроэнергетика России» URL: www.hydropower.ru/stations/detail.php?ELEMENT_ID=1921 (дата обращения: 15.01.2023).
4. Бостром Ник. Искусственный интеллект. Этапы. Угрозы. Стратегии. – Москва: Мир, 2021. – 119 с.