

ПРОГНОЗИРОВАНИЕ ПОТЕРЬ ЭЛЕКТРОЭНЕРГИИ В РАСПРЕДЕЛИТЕЛЬНЫХ СЕТЯХ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ

В.Д. Бибиков

*Томский политехнический университет,
ИШЭ, ОЭЭ, гр. 5А03*

Научный руководитель: В.Е. Рудник, ассистент ОЭЭ ИШЭ ТПУ;
А.Б. Аскарлов, старший преподаватель ОЭЭ ИШЭ ТПУ

Введение

Распределительные сети являются одной из важнейших частей энергосистемы, управление которыми осуществляется электrorаспределительными компаниями. Для эффективного управления ими необходимо использовать различные аналитические инструменты и алгоритмы, которые позволяют анализировать большие объемы данных и прогнозировать будущие потребности в электроэнергии, как и повышать энергоэффективность в целом. Для прогнозирования энергопотребления в настоящее время могут применяться средства на основе нейронных сетей, которые способны предсказывать потери электроэнергии в распределительных сетях с высокой точностью.

Расчет потерь электроэнергии в распределительных сетях

Потери электроэнергии в распределительных сетях можно поделить на два класса: условно-постоянные потери и условно-переменные (нагрузочные), которые суммарно можно определить с помощью формулы (1):

$$\Delta W_i = \Delta W_i' + \Delta W_i'' \quad (1)$$

Условно-переменные потери – это потери электроэнергии, которые изменяются в зависимости от различных факторов и условий работы энергосистемы. Они возникают при транспортировке, распределении и потреблении электрической энергии [4]. Их можно определить по формуле (2):

$$\Delta W_i' = \Delta P_{i \max}' \cdot \tau_{i \max} \quad (2)$$

Условно-постоянные потери – это потери электроэнергии, которые происходят непрерывно в системе или устройстве даже при отсутствии нагрузки или нагружения [4]. Эти потери обычно возникают из-за различных факторов, включая сопротивление проводников, диэлектрические потери в изоляции, тепловые расходы и другие неизбежные физические процессы.

Анализ работы нейронных сетей

Машинное обучение – это подобласть искусственного интеллекта. Машинное обучение использует статистические модели без явных инструкций. Нейронная сеть – это метод машинного обучения, который заключается в обучении посредством данных подобно человеческому мозгу. Прогнозирование потерь электроэнергии с помощью нейронных сетей может быть выполнено с использованием методов глубокого обучения. Глубокое обучение – это метод машинного обучения, который использует искусственные нейронные сети для моделирования и понимания сложных данных [1]. В отличие от традиционных методов машинного обучения, глубокое обучение позволяет автоматически извлекать признаки и структуры из данных, не требуя заранее их задания или предварительной обработки. Это позволяет моделям глубокого обучения достигать высокой точности в решении задач классификации, регрессии, генерации и других [1].

Искусственные нейронные сети состоят из нескольких слоев, как показано на рис. 1. Обычно они имеют один входной и один выходной слой. Между входом и выходом может быть любое количество слоев. Эти слои называются скрытыми слоями. Все слои состоят из клеток.

Собранные знания нейронной сети хранятся в весах взаимосвязей. Следовательно, обучение нейронной сети – это процесс изменения весов. Для обучения нейронной сети необходимо понимать насколько далеки выходные значения от истины. Это делается с помощью функции потерь. Функция потерь вычисляет оценку потерь, вычисляя расстояние между выходными данными сети и фактическим значением.

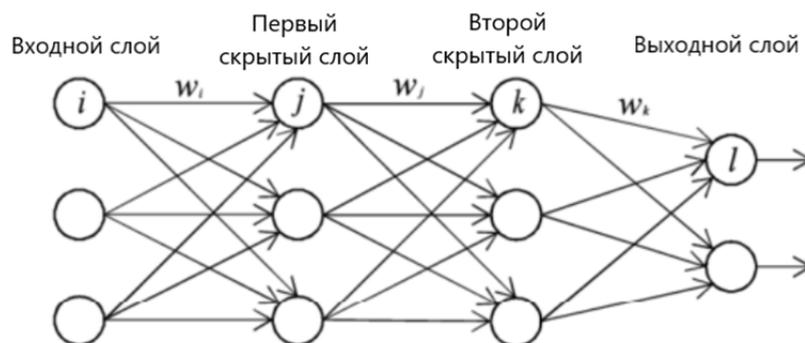


Рис. 1. Глубокая нейронная сеть

Для прогнозирования потерь в электрических сетях на основе нейронных сетей может использоваться следующая методика:

- **Сбор исходных данных:** для обучения нейронной сети необходимо собрать исходные данные о нагрузке электрической сети в прошлом периоде. Данные могут включать информацию о времени, дате, погодных условиях, днях недели и других факторах, влияющих на нагрузку.
- **Предобработка данных:** перед использованием данных для обучения нейронной сети необходимо их предварительно обработать. Это может включать удаление выбросов, заполнение пропущенных значений, нормализацию и т. д.
- **Разделение данных на обучающую и тестовую выборки:** исходные данные разделяются на две части – обучающую выборку, на которой будет происходить обучение нейронной сети, и тестовую выборку, на которой будет оцениваться точность прогнозирования.

Создание нейронной сети: на основе выбранной архитектуры (рис. 2) и параметров создается нейронная сеть. Это может быть многослойная нейронная сеть с различными функциями активации, количеством слоев и нейронов в каждом слое.

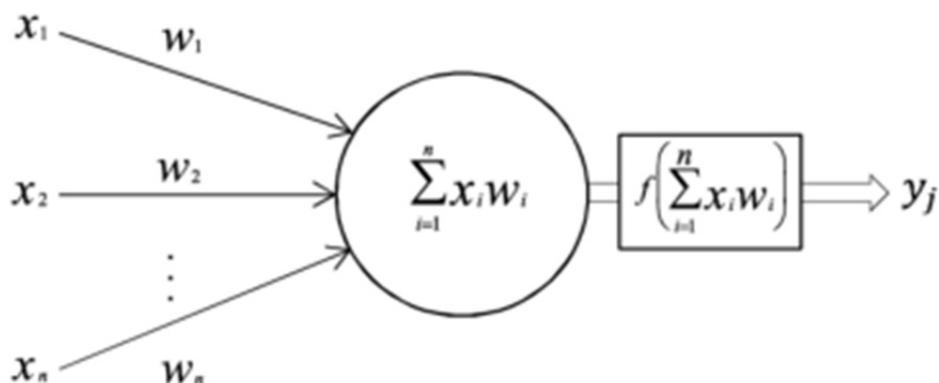


Рис. 2. Архитектура нейронной сети

Обучение нейронной сети: нейронная сеть обучается на обучающей выборке. Это происходит путем подачи исходных данных на вход нейронной сети и корректировки весов и параметров сети на основе ошибки прогнозирования.

Оценка точности нейронной сети: после завершения обучения нейронная сеть тестируется на тестовой выборке. Оценивается точность прогнозирования путем сравнения прогнозируемых значений с фактическими значениями.

Настройка параметров нейронной сети при недостаточной точности прогнозирования можно внести изменения в архитектуру и параметры нейронной сети, чтобы достичь более точных результатов.

Прогнозирование нагрузки: после успешного обучения и оценки точности нейронной сети она может быть использована для прогнозирования нагрузки в будущем. На вход нейронной сети подаются исходные значения переменной x , а на выходе получается прогнозируемое значение нагрузки.

Основываясь на минимуме ошибки обучения, времени обучения и минимальной ошибки прогнозирования была выбрана наилучшая нейронная сеть. Оказалось, что наиболее оптимальная функция распространения ошибки – функция обратного распространения ошибки, а наиболее подходящей функцией активации оказалась логистическая [3].

Для обучения нейронной сети необходим набор исходных данных. Набор данных *The Kieler Nachrichten Druckerzentrum* содержит данные о потреблении электроэнергии в реальной производственной среде. Он был собран Килером Нахрихтен Друкерцентрумом с 6 июля 2014 г. по 18 января 2019 г. Набор данных содержит измерения энергопотребления для 6 различных машин, записываемые каждые 15 минут. Эти машины представлены строками, как показано в табл. 1.

Таблица 1. Набор данных *Kieler Nachrichten Druckerzentrum*

machine id strings	machine	ID
e-aussenbeleuchtung-sud-nea	outside lights	m0
e-buro-aufenthalt	office lights	m1
e-druckluft-e2	air compressor	m2
e-kalte-1	air conditioner 1	m3
e-kalte-2	air conditioner 2	m4
e-rotation-e4	rotary printing press	m5

Часть набора *Kieler Nachrichten Druckerzentrum* представлена в табл. 2. Она представляет собой набор данных, содержащий имена машин, временные метки в миллисекундах с 1970 г. и текущую потребляемую мощность в ваттах. Полная таблица содержит 926830 строк.

Таблица 2. Первые пять строк набора данных *Kieler Nachrichten Druckerzentrum*

	0	1	2
0	e-kalte-1	1402504200000	94800.001413
1	e-kalte-1	1402505100000	93200.001389
2	e-kalte-1	1402506000000	93200.001389
3	e-kalte-1	1402506900000	92800.001383
...

На рис. 3 показано энергопотребление всех машин в январе 2015 г. По оси Y показано энергопотребление в ваттах, а по оси X – дата в днях. Первая закономерность – еженедельное потребление *e-druckluft-e2*, *e-kalte-1* и *e-buro-aufenthalt*. Машина *e-druckluft-e2* имеет самые высокие пики. Эти пики различаются по максимальной высоте от недели к неделе.

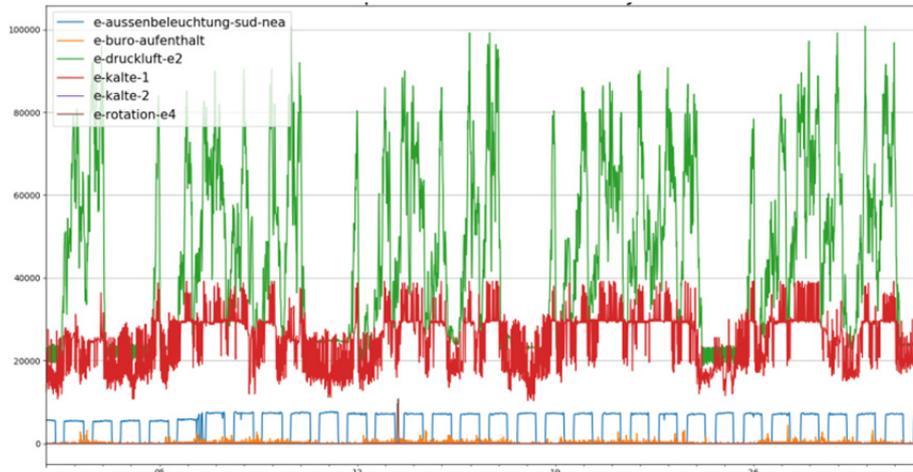


Рис. 3. Энергопотребление из набора Kieler Nachrichten Druckerzentrum

Следующий шаг – нормализация данных. Это не является необходимым функциональным требованием для модели, использующей нейронные сети, но поможет нейронной сети корректировать свои параметры в процессе обучения. Эта нормализация ускоряет процесс обучения и повышает точность результатов, которые выдает нейронная сеть. Для нормализации следующее используется формула (3):

$$X^* = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (3)$$

Выборка представляет собой (b, l, f, t) -тензор, где b – размер пакета; l – длина каждой выборки; f – количество признаков; t – тензор, содержащий метки [2]. Длина описывает, сколько значений признаков принимается. В этом контексте функции можно понимать, как столбцы данных, а цели – как соответствующие метки. Следовательно, данные должны быть построены таким образом, чтобы иметь эту форму. Это можно сделать путем создания необходимых наборов с помощью метода *TimeseriesGenerator* от *Keras*.

Для прогнозирования используется *Keras API*. Входной слой нейронной сети должен быть определен с использованием формы обучающих данных. Это важно, поскольку при слишком маленькой форме не все данные могут быть переданы в нейронную сеть. Это приведет к потере информации. Таким образом, форма определяется длиной образцов и количеством используемых функций. Выходной слой определяет форму вывода. Между входным и выходным слоем может быть несколько других слоев (скрытых), которые позволяют моделировать сложные зависимости и структуры в данных.

После определения структуры нейронной сети ее необходимо скомпилировать – преобразовать модели в оптимизированный исполняемый код, который может быть запущен на конкретной аппаратной платформе или устройстве.

Нейронная сеть может быть оценена с точки зрения точности с помощью функции *evaluate* из *Keras* и тестового набора или соответствующего генератора тестов. Эта функция оценки возвращает значение потерь для тестового набора. Если потери при обучении больше, чем потери при проверке, то модель предположительно перестраивается. В противном случае, если потери при проверке превышают потери при обучении, то модель предположительно недооснащена. Вариация модели близка к наилучшей если разница в обоих значениях потерь очень мала.

Вывод

В качестве вывода хотелось бы привести проблемы, над которыми необходимо работать для улучшения прогнозирования потерь электроэнергии в распределительных сетях.

Недостаток данных: для эффективного обучения нейронной сети требуется большой объем данных. Однако, в случае прогнозирования потерь электроэнергии может быть ограниченное количество доступных данных.

Несбалансированные данные: если данные о потерях электроэнергии несбалансированы, т. е. имеют сильное преобладание одного класса над другими, это может привести к проблемам в обучении нейронной сети и снижению ее точности.

Взаимосвязь с другими факторами: потери электроэнергии зависят от многих факторов: погода, нагрузка сети и другие переменные, все из них учесть крайне трудно.

Обобщение на новые данные: нейронная сеть может успешно прогнозировать потери электроэнергии на основе имеющихся данных, но ее способность обобщать и делать точные прогнозы на новых данных может быть ограничена. Это может быть вызвано недостатком разнообразия в обучающих данных или недостаточной репрезентативностью выборки.

Решение этих проблем требует тщательного подхода к сбору и обработке данных, выбору подходящей архитектуры нейронной сети, а также применения методов регуляризации и оптимизации для достижения наилучших результатов – именно над этим необходимо работать в будущем.

СПИСОК ЛИТЕРАТУРЫ

1. Jozefowicz R., Zaremba W., Sutskever I. An empirical exploration of recurrent network architectures // In: Proceedings of the 32nd International Conference on International Conference on Machine Learning. – 2015. – Vol. 37. – P. 2342–2350.
2. Henning S., Hasselbring W., Möbius A. A scalable architecture for power consumption monitoring in industrial production environments // In: 2019 IEEE International Conference on Fog Computing (ICFC). – June 2019. – P. 124–133.
3. Медведев В.С., Потемкин В.Г. Нейронные сети. MATLAB 6 / под общ. ред. к.т.н. В.Г. Потемкина. – М.: ДИАЛОГ МИФИ, 2002. – 496 с.
4. Фурсанов М. И. Определение и анализ потерь электроэнергии в электрических сетях энергосистем. – Минск: Белэнергосбережение, 2006. – 207 с.

ОПРЕДЕЛЕНИЕ И КЛАССИФИКАЦИЯ ВИДОВ УСТОЙЧИВОСТИ ДЛЯ СОВРЕМЕННЫХ ЭНЕРГОСИСТЕМ. ЗАРУБЕЖНЫЙ ОПЫТ

М.И. Старостин

*Томский политехнический университет,
ИШЭ, ОЭЭ, гр. 5А03*

Устойчивость энергосистемы отражает ее способность восстанавливаться после малых или значительных возмущений и возвращаться в исходное состояние, достигая равновесия. При изучении устойчивости энергосистемы мы рассматриваем ее как единое целое, включающее нагрузки, генераторы и электрическую сеть, соединяющую их.

Существуют два вида устойчивости энергосистемы: статическая и динамическая. Статическая устойчивость означает, что система способна справиться с малыми изменениями параметров режима. Динамическая устойчивость, в свою очередь, позволяет системе справиться с значительными изменениями параметров режима, такими как короткое замыкание.

Статическая устойчивость всегда присутствует в установившемся режиме, если таковой имеется. Статически неустойчивый режим не может продолжаться длительное время, поскольку даже небольшие возмущения (например, изменение нагрузки) немедленно приводят к его нарушению.