



ИДЕНТИФИКАЦИЯ ИЗМЕНЕНИЯ СОСТОЯНИЯ ЛИНИИ ПО ВЕКТОРНЫМ ИЗМЕРЕНИЯМ НА ОСНОВЕ СЕТЕЙ ГЛУБОКОГО ОБУЧЕНИЯ

Н.Э. Готман, Г.П. Шумилова

Институт социально-экономических и энергетических проблем Севера
Коми научный центр Уральского отделения Российской академии наук,
г. Сыктывкар, Россия
iespn@ksc.komisc.ru

Резюме: ЦЕЛЬ. Рассмотреть проблему определения изменения в топологии электрической сети, возникающей вследствие отключения/включения одной из линий электропередачи. Разработать алгоритм обнаружения изменения состояния линии в реальном времени, используя вектора напряжений в узлах электрической сети и вектора токов в линиях, полученные от устройств синхронизированных векторных измерений (УСВИ) во время переходного процесса. Провести экспериментальные исследования на 14-узловой тестовой схеме электрической сети. МЕТОДЫ. Поставленная задача решена методом из области искусственного интеллекта, таким как машинное обучение, в частности "глубокое обучение". РЕЗУЛЬТАТЫ. В статье описана актуальность темы, предложено применение метода определения состояния линий с помощью классификатора на основе сверточных нейронных сетей (СНС). Проведены расчеты для различных архитектур СНС с различным количеством временных срезов от момента изменения состояния линии. Доказана эффективность совместного использования УСВИ и СНС при решении данной задачи. ЗАКЛЮЧЕНИЕ. Предложено решение определения изменения состояния линии в переходном режиме с помощью классификатора сверточных нейронных сетей, используя векторные измерения напряжения и тока в реальном времени. Получена высокая точность, вплоть до 100 %, определения состояния линии, независимо от зашумления данных. Изменение топологии сети определяется в самом начале переходного процесса практически мгновенно, что позволит оператору несколько раз в течение первых секунд идентифицировать состояние линии, чтобы убедиться в правильности принимаемых решений.

Ключевые слова: электрическая сеть, топология, синхронизированные векторные измерения, глубокое обучение, сверточные нейронные сети.

Для цитирования: Готман Н.Э., Шумилова Г.П. Идентификация изменения состояния линии по векторным измерениям на основе сетей глубокого обучения // Известия высших учебных заведений. ПРОБЛЕМЫ ЭНЕРГЕТИКИ. 2020. Т. 22. № 6. С. 55-67. doi:10.30724/1998-9903-2020-22-6-55-67.

IDENTIFICATION OF LINE STATUS CHANGES USING PHASOR MEASUREMENTS THROUGH DEEP LEARNING NETWORKS

NE. Gotman, GP. Shumilova

Federal Research Center Komi Scientific Center of the Ural Branch Russian
Academy of Sciences, ISE and EPN, Syktyvkar, Russia
iespn@ksc.komisc.ru

Abstract: THE PURPOSE. To consider the problem of detecting changes in a power grid topology that occurs as a result of the power line outage / turning on. Develop the algorithm for detecting changes in the status of transmission lines in real time by using voltage and current phasors captured by phasor measurement units (PMUs) are placed on buses. Carry out experimental research on IEEE 14-bus test system. METHODS. This paper proposes a method from the field of artificial intelligence such as machine learning in particular "Deep Learning" to solve the problem. Deep Learning arises as a computational learning technique in which high level abstractions are hierarchically modelled from raw data. One of the means to effectively extract the

inherent hidden features in data are Convolutional Neural Networks (CNNs). RESULTS. The article describes the topic relevance, offers to apply the method for detecting status of lines using a CNN classifier. The combination of different CNN architectures and the number of time slices from the moment of line status change are used to detect the power grid topology. The effectiveness of the joint use of PMUs and CNN in solving this problem has been proven. CONCLUSION. A solution for the line status change detection in the transient states using a CNN classifier is proposed. A high accuracy of the line status detection was obtained despite the influence of noise on measurement data. A change in the network topology is detected at the very beginning of the transient state almost instantly. It will allow the operator several times during the first seconds to identify the line state in order to make sure that the decisions made are correct.

Keywords: power network, topology, phasor measurement unit, deep learning, convolutional neural networks.

For citation: Gotman NE, Shumilova GP. Identification of line status changes using phasor measurements through deep learning networks. *Power engineering: research, equipment, technology*. 2020;22(6):55-67. doi:10.30724/1998-9903-2020-22-6-55-67.

Введение

Создание топологической модели электроэнергетической системы (ЭЭС) является очень важным этапом моделирования ЭЭС в реальном времени. Ошибки в этой модели могут привести к неверным и потенциально опасным управляющим воздействиям. В этой ситуации проверка правильности модели топологии электрической сети имеет большое значение.

Для эффективного управления современной энергосистемой с наличием децентрализованных источников энергии требуются надежные методы определения топологии электрической сети, которые поддерживаются современными измерительными системами, обеспеченными устройствами синхронизированных векторных измерений (УСВИ) [1]. УСВИ имеют возможность записывать быстрые переходные процессы с высокой точностью. Действительно, эти события могут произойти в течение нескольких секунд, что затрудняет их обнаружение традиционными системами SCADA (*Supervisory Control And Data Acquisition*). Временная синхронизация географически распределенных измерений обеспечивает лучшую оперативную осведомленность о топологии сети в режиме реального времени.

Предложено множество подходов с использованием УСВИ для обнаружения топологических изменений сети, вызванных отключениями линии, например, [2–6]. Отправной точкой в этих подходах является то, что отключение линии вызывает изменение вектора напряжения (модуля и фазового угла) во всех узлах электрической сети, и эти изменения больше, чем во время нормальной работы, например, при качаниях.

Ключевая особенность, которая делает идентификацию (включена / не включена) линии возможной, это то, что измеренные УСВИ значения вектора напряжения в узле различны для разных сценариев отключения линии, т.е. это своего рода "подписи", которые и используют авторы рассматриваемых работ для определения изменения топологии электрической сети. Каждый метод имеет свою специфику, но во всех методах определение топологии проводится в квазиустановившемся режиме, т.е. после окончания переходного процесса, вызванного каким-то непредвиденным обстоятельством, что увеличивает время определения отключения линии.

В работах [7–9] определение топологии сети было выполнено с использованием искусственных нейронных сетей (ИНС), где в качестве входных переменных использовались модуль и фаза вектора напряжения в узлах размещения УСВИ и перетоки активной и реактивной мощностей на конце линий около узла размещения УСВИ в установившемся режиме. В этих работах задача определения топологии сети также решалась в установившемся режиме.

С появлением систем мониторинга переходных режимов WAMS (*Wide Area Measurement Systems*) и последующего развертывания таких устройств мониторинга, центры управления заполняются все большим количеством данных. УСВИ способны сделать от 10 до нескольких сотен замеров за секунду, что намного выше, чем в традиционных системах SCADA, которые обычно выполняют один замер за 2–4 секунды. Эта новая парадигма представляет собой огромное количество необработанных данных, собранных каждый день. Например, в [10] говорится, что одна выборка УСВИ на частоте

60 Гц может создавать примерно 721 МБ данных в день, а набор данных, используемых от 44 УСВИ, составляет приблизительно 1 ТБ в месяц. Поэтому, как здесь сказано, широкомасштабные системы УСВИ представляют проблемы для обработки такого объема данных. Согласно [11], эта проблема может быть решена методами из области искусственного интеллекта, такими как машинное обучение, в частности «глубокое обучение» (*Deep Learning*). Эти методы могут быть полезны для извлечения характеристик из необработанных данных, причем новейшие алгоритмы машинного обучения способны сами находить признаки, по которым можно классифицировать входные данные.

Много исследовательских работ выполнено по применению глубокого обучения в энергосистемах: для прогнозирования нагрузки [12], кибербезопасности [13], для определения места короткого замыкания в линии [14], восстановления энергосистемы после аварии, выявления дефектов поврежденного оборудования в результате короткого замыкания [15]. Эти исследования охватывают такие области энергетики, как энергопотребление, умные сети (*smart grid*), рынок электроэнергии, надежность и др. [16]. Большинство статей по этим работам опубликовано, начиная с 2016 года. Известна одна работа по применению нейронных сетей глубокого обучения непосредственно для определения топологии электрической сети [17]. Это исследование сосредоточено на проблеме определения топологии в распределенной энергосистеме в реальном времени. Разработан новый метод определения топологии на основе сети глубокого обучения, используя концепцию ядро-узел-карта (*kernel-node-map*). Эта нейронная сеть адаптируется к физической топологии распределенной энергосистемы. В работе подтверждены преимущества по сравнению с современными методами.

В данной статье предлагается метод определения топологии традиционной электрической сети на основе сетей глубокого обучения, в котором используются данные переходного режима, измеренные устройствами синхронизированных векторных измерений.

Краткое введение в глубокие нейронные сети, и, в частности, в сверточные нейронные сети (СНС), как метод решения поставленной задачи, представлен в разделе 1. Раздел 2 посвящен исследованию применения СНС для определения изменения состояния линии в переходном режиме с представлением результатов исследования. В разделе "Результаты и дискуссия" проведено сравнение методов на основе СНС и ИНС по точности определения топологии электрической сети. В заключении сделаны выводы по результатам исследований и намечены дальнейшие направления работы по этой теме.

Материалы и методы

Глубокие нейронные сети как метод решения задачи

Глубокие нейронные сети (*Deep Learning Neural Networks (DLNN)*) становятся одним из самых популярных методов машинного обучения при создании систем искусственного интеллекта в разных областях, таких как распознавание речи, обработка естественного языка, компьютерное зрение, медицинская информатика и др. [18]. Их отличительными особенностями являются большее количество нейронов в слоях, более сложные способы соединения, автоматическое выделение признаков и увеличение вычислительных мощностей для обучения. Как указано выше, много исследовательских работ выполнено и по применению *DLNN* в энергосистемах.

Одна из причин успешного применения *DLNN* заключается в том, что сеть автоматически выделяет из данных важные признаки, необходимые для решения задачи. При обработке больших объемов данных нейронная сеть справляется с выделением признаков гораздо лучше, чем сам человек.

Многослойный перцептрон [19] является примером архитектуры глубокой нейронной сети. Такая сеть называется полносвязной. Существуют другие архитектуры *DLNN*, в частности неоконитрон, автокодировщики, сверточные нейронные сети, ограниченная машина Больцмана, глубокие сети доверия, сети долго-краткосрочной памяти, управляемые рекуррентные нейронные и сети остаточного обучения [20].

Для решения задачи определения изменения состояния линии наиболее из всех перечисленных подходят сверточные нейронные сети (СНС). Учитывая их свойство редкой связности и совместного использования параметров, они подходят для работы с данными пространственного распределения. Поэтому остановимся на более подробном представлении этих сетей.

СНС являются особым типом архитектуры искусственных нейронных сетей для обработки данных, нацеленной на эффективное распознавание входной информации. СНС получает входные данные, преобразует их с помощью ряда взаимосвязанных слоев и на

выходе выдает набор вероятностей (оценок). Существует много вариантов архитектуры СНС, но все они основаны на чередовании слоев, показанных на рис. 1.




Рис. 1. Архитектура сверточной нейронной сети

Здесь имеются три основные группы слоев: 1) входной слой; 2) слои выделения признаков; 3) слои классификации.

СНС представляют собой метод, который чаще всего используется для классификации изображений. Входной слой принимает трехмерные сигналы, при этом учитывается двухмерность изображения и разделение его на три канала: красный, синий, зеленый.

Перед началом расчетов на модели с СНС входные данные нормализуются. Нормализация входных данных необходима для адекватного применения математических моделей и компьютерных расчетов при вычислениях, связанных с большими и малыми величинами, для равномерного их распределения, представления значений в области $[0,1]$. В конечном счете, нормализация увеличивает информативность данных. Обычно используется формула, которая позволяет растянуть данные, подаваемые на вход СНС, от 0 до 1:

$$f(x_i, \min, \max) = \frac{x_i - \min}{\max - \min}, \quad (1)$$

где f – функция нормализации, x_i – элемент входных данных, \min , \max – соответственно, минимальное и максимальное значения среди элементов входного образца.

Слои выделения признаков имеют повторяющуюся структуру (свертка \rightarrow ReLU \rightarrow пулинг).

Сверточный слой, представляет из себя набор карт признаков, у которых есть сканирующее ядро (или, по-другому, фильтр). Мы получаем вход, применяем к нему ядро свертки и получаем на выходе карту признаков (рис. 2).




Рис. 2. Операция свертки

Входом свертки могут быть исходные данные или карта признаков, вычисленная другой сверткой. Размер всех карт сверточного слоя одинаков и вычисляется по формулам [21]:

$$\left. \begin{aligned} w &= mW - kW + 1, \\ h &= mH - kH + 1, \end{aligned} \right\} \quad (2)$$

где w, h – вычисляемые, соответственно, ширина и высота сверточной карты; mW – ширина предыдущей карты; mH – высота предыдущей карты; kW – ширина ядра; kH – высота ядра.

В ходе применения свертки ядро передвигается по ширине и высоте входной карты (рис. 2). Результатом является сумма произведений элементов ядра на соответствующие элементы части входной карты под ним. Математически операция свертки описывается формулой:

$$(F \times K)[a, b] = \sum_{x=1}^{kH} \sum_{y=1}^{kW} F[a+x-1, b+y-1] \times K[x, y] \quad (3)$$

где F – входная карта признаков, K – ядро свертки, $F \times K$ – результат свертки.

Блок линейной ректификации (*ReLU*), который на самом деле является функцией активации (здесь показан в виде слоя, поскольку так принято в литературе). Функция линейной ректификации активирует блок, если входной сигнал больше заданной величины. Функция описывается формулой $f(x) = \max(0, x)$, ее график показан на рис. 3.




Рис. 3. Функция линейной ректификации

Блоки *ReLU* находят широкое применение в современных глубоких сетях, поскольку хорошо работают во многих ситуациях.

Пулинговый слой уменьшает размерность карт предыдущего слоя, что приводит к ускорению вычислений. При этом происходит извлечение доминирующих признаков. Применяют один из двух видов пулинга: максимальный и средний. Максимальный пулинг выбирает максимальное значение из блока карты, размеры которого соответствуют ядру пулингового слоя. Средний пулинг возвращает среднее значение.

Слои классификации – это слои обычного многослойного персептрона, моделируют сложную нелинейную функцию, оптимизируя которую улучшается качество распознавания. Полносвязные слои являются важной составляющей СНС, в которую передается результат свертки и объединения, и определяется окончательное решение по классификации.

Обучение СНС проводится по методу обратного распространения ошибки. Оно подобно обучению многослойного персептрона.

Объект исследования и численные эксперименты

Для определения изменения в топологии электрической сети использована СНС, ориентированная на 14-узловую тестовую схему *IEEE* (рис. 4). На схеме показано размещение УСВИ в узлах 2, 4, 5, 6, 9, 11 и 13, полученное как результат оптимальной расстановки по критерию минимума количества устройств [22], обеспечивающих топологическую наблюдаемость ЭЭС. Наблюдаемость узла 8 обеспечивается за счет нулевой инъекции транзитного узла 7.

При показанной на схеме рис. 4 расстановке устройств УСВИ получаем семь векторных измерений напряжений и 27 векторных измерений токов, но используем из них только семь измерений фаз напряжения и только 20 измерений модулей токов, поскольку для семи линий имеем измерения на обоих концах, и одно из которых нет необходимости рассматривать. Отключения трансформаторов не рассматривались.

База данных для определения изменения состояния линий получена с

использованием программно-вычислительного комплекса (ПВК) «RastrWin 3» (v1.80.0.1485), в состав которого входит программный модуль «RUSTab», предназначенный для расчета электрохимических переходных процессов. В ПВК «RastrWin 3» воспроизведена 14-узловая схема электрической сети «IEEE 14 Bus Test Case» на основе данных о параметрах сети и генераторов из ПВК «DigSILENT PowerFactory».

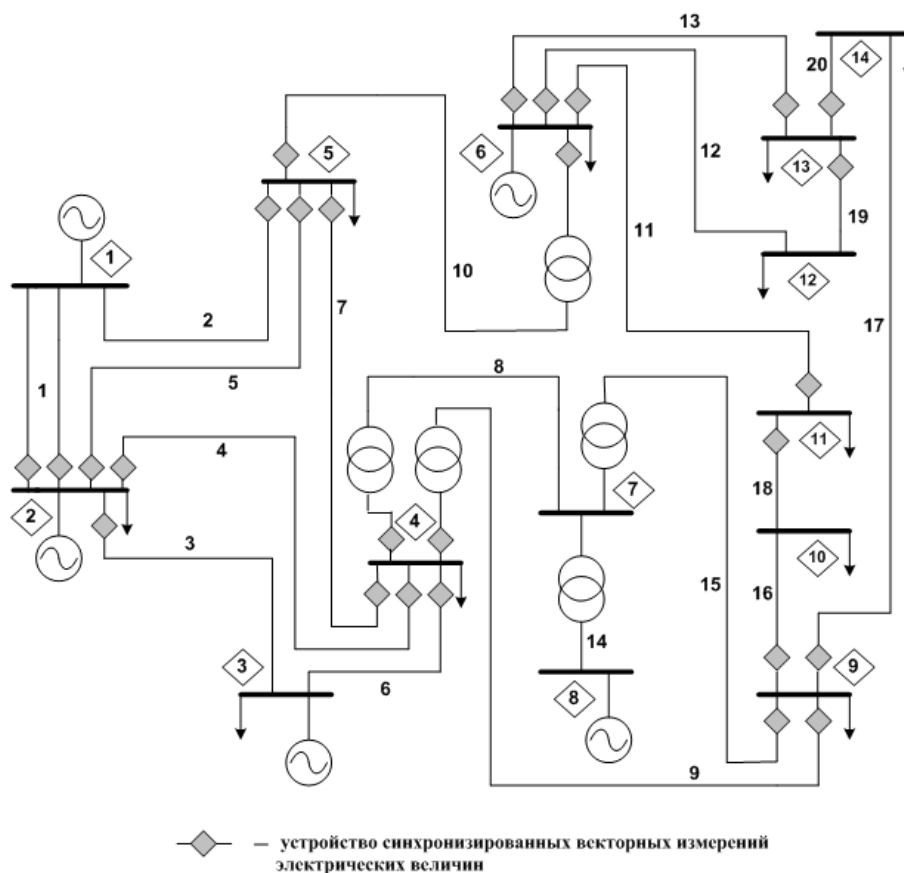


Рис. 4. 14-узловая тестовая схема IEEE

Для моделирования отключения/включения линии рассчитаны 500 режимов путем изменения нагрузки во всех нагрузочных узлах в диапазоне от 70 до 150 процентов от базового уровня и добавления к полученным значениям случайной величины, составляющей от 0 до 20 процентов величины базовой нагрузки в узле.




Рис. 5. Графики фаз напряжения в узлах 2, 4, 5 при аварийной ситуации на линии 2

Для каждого режима проведены расчеты переходных режимов, связанных с отключением одной из линий и включением ее через три секунды устройством автоматического повторного включения (АПВ). Результаты расчетов 200 режимов из 500 использованы для обучения сверточной нейронной сети, а 300 – для тестирования. На рис. 5 представлены графики фаз напряжения в узлах 2, 4 и 5 при отключении линии 2 и

включении ее устройством АПВ. Это ближайшие к месту аварийной ситуации узлы с установленными в них УСВИ. Время 0 с – это время отключения линии, 3 с – время срабатывания устройства АПВ.

Значения измерений, полученные расчетами на ПВК «*RastrWin 3*», использовались с добавлением случайным образом шума: изменение фазы напряжения на $\pm 0,5^\circ$ и модуля тока на $\pm 0,5\%$. Шум добавлялся из того расчета, что УСВИ имеют относительную погрешность измерения напряжений и токов не более $\pm 0,2\%$, и поскольку векторные измерения содержат в себе не только погрешность УСВИ, но и погрешность измерительных трансформаторов, то относительная погрешность зашумления несколько увеличена.

Рассматривалась задача определения состояния линий в 14-узловой тестовой схеме в любой момент переходного процесса. Для этого проведены расчеты с тремя вариантами входных данных, в качестве которых использовались изменения фаз напряжения в узлах и модулей токов в линиях через 0,1 с. Во всех трех вариантах в выходном слое СНС для каждой рассматриваемой линии значение 0 соответствовало тому, что линия находится в работе, а значение 1 – линия отключена.

Первый вариант. Количество входных параметров СНС равно 27, из них 7 значений напряжения, измеренных устройствами УСВИ в узлах, где они установлены, и 20 значений токов, измеренных УСВИ в линиях, инцидентных узлам расстановки УСВИ.

Использовались изменения значений измерений для одного временного интервала (один временной интервал – разница между измерениями в текущий и предыдущий моменты времени). Входом СНС является трехмерная матрица $1 \times 27 \times 1$.

Второй вариант. Использовались изменения значений измерений для двух последовательных временных интервалов. Количество входных параметров СНС равно 54. Входом СНС является трехмерная матрица $2 \times 27 \times 1$.

Третий вариант. Использовались изменения значений измерений от 1 до 20 временных интервалов. Количество входных параметров СНС варьировалось от 27 до 540 (27×20). Входами СНС являются трехмерные матрицы $n \times 27 \times 1$, где $n = 1, \dots, 20$.

Количество образцов для обучения и тестирования СНС варьировалось в зависимости от варианта расчетов и от количества временных срезов. Расчеты проводились по программе, разработанной на языке *Julia* (версия 1.4) с применением пакета *Flux* (библиотеки машинного обучения, включающей и функции для создания моделей СНС).

Таблица 1

Результаты определения топологии для двух вариантов входных данных СНС

Вариант	Данные (количество временных срезов при отключении и включении линии)	Количество образцов		Количество неверно классифицированных образцов при тестировании	Точность расчета, %
		для обучения	для тестирования		
1	1	6000	9000	0	100
	2	12000	18000	437	97,57
	3	18000	27000	1169	95,67
	4	24000	36000	4043	88,77
	5	30000	45000	5571	87,62
	6	36000	54000	7587	85,95
	7	42000	63000	9866	84,34
	8	48000	72000	10858	84,92
	9	54000	81000	11729	85,52
	10	60000	90000	13428	85,08
2	по 2 из 2	6000	9000	7	99,92
	по 2 из 3	12000	18000	347	98,07
	по 2 из 4	18000	27000	1209	95,52
	по 2 из 5	24000	36000	2110	94,14
	по 2 из 6	30000	45000	3150	93,00
	по 2 из 7	36000	54000	4463	91,55
	по 2 из 8	42000	63000	6256	90,07
	по 2 из 9	48000	72000	7582	89,47
	по 2 из 10	54000	81000	8011	90,11
	по 2 из 11	60000	90000	9486	89,46

Во всех вариантах расчетов для сверточных слоев использовали функцию активации *ReLU*. Классификация выполнялась с использованием логистической регрессии *softmax*. Для обновления весов при обучении СНС для всех протестированных вариантов применялась функция потерь – перекрестная энтропия, а в качестве функции оптимизации – *Adam* (алгоритм градиентной оптимизации стохастических целевых функций первого порядка).

Результаты расчетов с первыми двумя вариантами входных данных приведены в табл. 1 и табл. 2.

Анализируя точность расчетов и локализацию ошибок, можно сделать следующие выводы. Если проводить расчеты с данными более поздних относительно момента аварии временных срезов, то уменьшается точность, причем погрешность определения состояния линий растет для линий 115 кВ (линии 11-20) и остается допустимой для линий 230 кВ (линии 1-7). Это можно объяснить минимальным изменением фазы напряжения в узлах расстановки УСВИ по концам линий 115 кВ и небольшими перетоками по этим линиям. Для линий 230 кВ погрешность составляет менее 1% в расчетах со вторым вариантом данных (табл. 2).

Таблица 2

Распределение количества неверно классифицированных образцов при отключении / включении разных линий для двух вариантов входных данных СНС

Линия	Первый вариант расчета			Второй вариант расчета		
	Количество ошибок/относительная погрешность (%) при использовании данных:					
	2-х временных срезов	5-и временных срезов	10-и временных срезов	3-х временных срезов по 2	6-и временных срезов по 2	11-и временных срезов по 2
1	31 / 2,58	8/ 0,27	161/ 2,68	0 / 0	0 / 0	35 / 0,58
2	4 / 0,33	27/ 0,9	62/1,03	0/ 0	0 / 0	6 / 0,1
3	1 / 0,08	71/ 0	298/ 4,97	0 / 0	0 / 0	4 / 0,07
4	29/ 2,42	37/ 2,37	78/ 1,3	0 / 0	1 / 0,03	2 / 0,03
5	39 / 3,25	72/ 2,4	230/ 3,83	0 / 0	0 / 0	6 / 0,1
6	38 / 3,17	52/1,73	385/ 6,42	0 / 0	1 / 0,03	25 / 0,42
7	40 / 3,33	11/ 0,37	35/ 0,58	0 / 0	0 / 0	0 / 0
11	15 / 1,25	351/ 11,7	796/ 13,27	44 / 3,67	236 / 7,87	869 / 14,48
12	59 / 4,92	1259/ 41,97	2928/ 48,8	61 / 5,08	783 / 26,1	2650 / 44,17
13	2 / 0,17	313/ 10,43	751/ 12,52	1 / 0,08	60 / 2,0	327 / 5,45
16	33 / 2,75	485/ 16,17	1412/ 23,53	12 / 1,0	119 / 3,97	936 / 15,6
17	7 / 0,58	191/ 6,37	401/ 6,68	1 / 0,08	30 / 1,0	165 / 2,75
18	35 / 2,92	966/ 32,2	2073/ 34,55	52 / 4,33	584 / 19,47	1020 / 17,0
19	84 / 7,0	1443/ 48,1	2955/ 49,25	174 / 14,5	1024 / 34,13	2860 / 47,67
20	20 / 1,67	285/ 9,5	863/ 14,38	2 / 0,17	76 / 2,53	581 / 9,68
Количество тестируемых образцов для одной линии						
	1200	3000	6000	1200	3000	6000

Таблица 3

Точность результата определения состояния линии (отключена/включена) для третьего варианта входных данных СНС

Количество временных срезов	Размерность входных параметров	Точность результата, (%)	Количество временных срезов	Размерность входных параметров	Точность результата, (%)
1	1x27x1	100	11	11x27x1	100
2	2x27x1	99,92	12	12x27x1	99,99
3	3x27x1	99,66	13	13x27x1	99,49
4	4x27x1	100	14	14x27x1	99,91
5	5x27x1	99,98	15	15x27x1	99,96
6	6x27x1	100	16	16x27x1	99,94
7	7x27x1	99,97	17	17x27x1	99,07
8	8x27x1	99,99	18	18x27x1	99,72
9	9x27x1	100	19	19x27x1	99,26
10	10x27x1	99,99	20	20x27x1	99,77

Результаты расчетов с двумя первыми вариантами данных подсказали третий, особенность которого состоит в том, что на каждом временном срезе количество входных

данных увеличивается на 27, и на вход СНС подается матрица с количеством строк, увеличенным на единицу. Отсюда следует, что для каждого временного среза требуется своя архитектура СНС. Количество образцов для обучения и тестирования при этом не меняется (6000 – для обучения и 9000 – для тестирования). Точность определения изменения топологии сети, вызванного изменением состояния линии, для третьего варианта составляет почти 100 % (табл. 3).

Далее, в табл. 4 и 5 приведены архитектуры СНС для расчетов с данными одного и одиннадцати временных срезов. Количество слоев выделения признаков одинаково для обеих архитектур, но увеличение количества строк матрицы входных данных во втором случае позволило увеличить размерность ядра и для свертки, и для пулинга. Оба случая дают 100 % точность.

Таблица 4

Структурные параметры СНС для матрицы входных данных $1 \times 27 \times 1$

Слои	Действие	Размерность входа	Ядро	Размерность выхода
Первый слой выделения признаков	Свертка	$1 \times 27 \times 1$	1×2	$1 \times 26 \times 6$
	Пулинг	$1 \times 26 \times 6$	1×2	$1 \times 13 \times 6$
Второй слой выделения признаков	Свертка	$1 \times 13 \times 6$	1×2	$1 \times 12 \times 8$
	Пулинг	$1 \times 12 \times 8$	1×2	$1 \times 6 \times 8$
Слой классификации	Полносвязный слой	48	-	16

Таблица 5

Структурные параметры СНС для матрицы входных параметров $11 \times 27 \times 1$

Слои	Действие	Размерность входа	Ядро	Размерность выхода
Первый слой выделения признаков	Свертка	$11 \times 27 \times 1$	2×2	$10 \times 26 \times 36$
	Пулинг	$10 \times 26 \times 36$	2×2	$5 \times 13 \times 36$
Второй слой выделения признаков	Свертка	$5 \times 13 \times 36$	2×2	$4 \times 12 \times 14$
	Пулинг	$4 \times 12 \times 14$	2×2	$2 \times 6 \times 14$
Слой классификации	Полносвязный слой	168	-	16

Результаты и обсуждение

В данной работе, для определения состояния линий в 14-узловой тестовой схеме во время переходного процесса, рассмотрены три варианта входных данных сверточной нейронной сети.




Рис. 6. Структура искусственной нейронной сети, используемой для определения изменения в топологии электрической сети

Сравним результаты, полученные с применением СНС, с результатами определения топологии с теми же вариантами входных данных на основе ИНС (рис. 6), полученными ранее (рассматриваются два варианта, поскольку третий относится только к схеме с СНС). Здесь $NI = 27$ (или 54, в зависимости от варианта расчетов); количество нейронов в

выходном слое $NK = 15$, что соответствует рассматриваемому количеству отключаемых линий в тестовой схеме.

В табл. 6 и 7 представлены результаты определения топологии электрической сети при изменении состояния одной из линий для схем с СНС и ИНС.

Таблица 6

Результаты определения топологии для двух вариантов входных данных СНС и ИНС

Вариант	Данные (количество временных срезов при отключении и включении линии)	Количество образцов		Количество неверно классифицированных образцов при тестировании	Точность расчета, %		
		для обучения	для тестиро вания				
СНС и ИНС				СНС	ИНС	СНС	ИНС
1	1	6000	9000	0	0	100	100
	2	12000	18000	437	432	97,57	97,60
	3	18000	27000	1169	1078	95,67	96,01
	4	24000	36000	4043	5616	88,77	84,40
2	по 2 из 2	6000	9000	7	0	99,92	100
	по 2 из 3	12000	18000	347	358	98,07	98,01
	по 2 из 4	18000	27000	1209	1185	95,52	95,61
	по 2 из 5	24000	36000	2110	5914	94,14	83,57

Таблица 7

Распределение количества неверно классифицированных образцов при отключениях / включениях разных линий для двух вариантов входных данных СНС и ИНС

Линия	Первый вариант		Второй вариант	
	Количество ошибок/относительная погрешность (%) при использовании данных:			
	2-х временных срезов		3-х временных срезов	
	СНС	ИНС	СНС	ИНС
1	31 / 2,58	0 / 0	0 / 0	0 / 0
2	4 / 0,33	1 / 0,08	0 / 0	1 / 0,08
3	1 / 0,08	0 / 0	0 / 0	0 / 0
4	29/ 2,42	3 / 0,25	0 / 0	0 / 0
5	39 / 3,25	3 / 0,25	0 / 0	0 / 0
6	38 / 3,17	2 / 0,17	0 / 0	0 / 0
7	40 / 3,33	3 / 0,25	0 / 0	0 / 0
11	15 / 1,25	52 / 4,33	44 / 3,67	32 / 2,67
12	59 / 4,92	87 / 7,25	61 / 5,08	69 / 5,75
13	2 / 0,17	4 / 0,33	1 / 0,08	10 / 0,83
16	33 / 2,75	24 / 2,00	12 / 1,0	5 / 0,42
17	7 / 0,58	16 / 1,33	1 / 0,08	11 / 0,92
18	35 / 2,92	49 / 4,08	52 / 4,33	93 / 8
19	84 / 7,0	182 / 15,17	174 / 14,5	130 / 10,83
20	20 / 1,67	6 / 0,50	2 / 0,17	4 / 0,33
Количество тестируемых образцов для одной линии				
	1200		1200	

Анализируя полученные результаты, можно сказать, что точность модели с СНС выше, чем с ИНС, особенно когда определение изменения состояния линии происходит не в начале переходного процесса, а позже на несколько временных срезов. Для третьего варианта входных данных, которые можно обработать только на модели с СНС вследствие их большого объема, точность определения топологии сети не зависит от удаленности от начала переходного процесса.

Заключение

В этой работе предлагается решение определения изменения состояния линии в переходном режиме с помощью классификатора сверточных нейронных сетей, используя векторные измерения напряжения и тока в реальном времени. Подчеркивается важная роль совместного использования УСВИ и СНС при решении данной задачи. Возможность УСВИ записывать быстрые переходные процессы с высокой точностью в то же время

предоставляет большой объем данных, которые можно обработать пока только с помощью новейших алгоритмов машинного обучения и, в частности, сверточных нейронных сетей.

Получена высокая точность (вплоть до 100 %) определения состояния линии, независимо от зашумления данных. Изменение топологии сети определяется в самом начале переходного процесса практически мгновенно, что позволит оператору несколько раз в течение первых секунд идентифицировать состояние линии, чтобы убедиться в правильности принимаемых решений.

Дальнейшие направления исследований включают определение топологии сети, когда одновременно происходят изменения состояний двух или более линий.

Литература

1. Мокеев А.В. Особенности разработки, испытаний и внедрения устройств синхронизированных векторных измерений // Современные подходы к обеспечению надежности электроэнергетических систем. Сыктывкар, 2014. С. 56–62.
2. Tate J.E., Overbye T.J. Line outage detection using phasor angle measurements // IEEE Transactions on Power Systems. 2008. V. 23, N4. pp. 1644–1652.
3. Kim T., Wright S.J. PMU placement for line outage identification via multinomial logistic regression // IEEE Transactions on Smart Grid. 2018. V. 9, N1. pp. 122–131.
4. Cavarro G., Arghandeh R. Power distribution network topology detection with time-series signature verification method // IEEE Transactions on Power Systems. 2018. Vol. 33, N4. pp. 3500–3509.
5. Ponce C., Bindel D.S. FLiER: Practical topology update detection using sparse PMUs // IEEE Transactions on Power Systems. 2017. V. 32, N6. pp. 4222–4232.
6. Srikumar M.S., Ananthapadmanbha Dr.T., Khan F.Z., et al. Line outage detection using phasor measurement units. In: Procedia Technology 21 (2015), SMART GRID Technologies; August 6–8; 2015. pp. 88–95.
7. Готман Н.Э., Шумилова Г.П., Старцева Т.Б. Идентификация топологии электрической сети на основе искусственных нейронных сетей с использованием векторных измерений // Методические вопросы исследования надежности больших систем энергетики. Вып. 66. Актуальные проблемы надежности систем энергетики / Отв. ред. Н.И. Воропай, М.А. Короткевич, А.А. Михалевич. Минск: БНТУ, 2015. С. 251–257.
8. Шумилова Г.П., Готман Н.Э., Старцева Т.Б. Определение топологии электрической сети при делении ее на участки с привязкой к устройствам PMU // Методические вопросы исследования надежности больших систем энергетики. Вып. 67. Проблемы надежности систем энергетики / Отв. ред. Н.И. Воропай, Ю.Я. Чукреев. Сыктывкар: Издательство ООО «Коми республиканская типография», 2016. С. 250–255.
9. Готман Н.Э., Шумилова Г.П., Старцева Т.Б. Определение топологии электрической сети с использованием синхронизированных векторных измерений // Материалы Пятого Всероссийского научного семинара "Актуальные проблемы, направления и механизмы развития производительных сил Севера"; 21–23 сентября 2016 г., Сыктывкар. ООО «Коми республиканская типография», 2016. Ч. II. С. 115–123.
10. Cardoso P.E.A. Deep learning applied to PMU data in power systems: Ph.D. thesis. Faculdade De Engenharia Da Universidade Do Porto. 2017. 105 p. Available at: <https://repositorio-aberto.up.pt/bitstream/10216/106289/2/204483.pdf>. Accessed to: 21 Nov 2020.
11. Schmidhuber J. Deep learning in neural networks: an overview // Neural Networks. 2015. V. 61. pp. 85–117. doi: 10.1016/j.neunet.2014.09.003.
12. Shi H., Xu M.H., Li R. Deep learning for household load forecasting-A novel pooling deep RNN // IEEE Transactions on Smart Grid. 2017. V. 9, N5. pp. 5271–5280.
13. Wang H.Z., Ruan J.Q., Wang G., et al. Deep learning-based interval state estimation of AC smart grids against sparse cyber attacks // IEEE Transactions on Industrial Informatics. 2018. V. 14, N11. pp. 4766–4778.
14. Li W.T., Deka D., Chertkov M., et al. Real-time faulted line localization and PMU placement in power systems through convolutional neural networks // IEEE Transactions on Power Systems. 2019. V. 34, N 6. pp. 4640–4651.
15. Muhammad A., Lee J.M., Hong S.W., et al. Deep learning application in power system with a case study on solar irradiation forecasting. In: Proceedings Int. Conf. Artif. Intell. Inf. Commun. (ICAIIIC). Feb. 2019. pp. 275–279.
16. Zhang D., Xiaoqing H., Chunyu D. Review on the research and practice of deep learning and reinforcement learning in smart grids // CSEE Journal of Power and Energy System. 2018. V. 4, N3. p.p. 362–370.

17. Xiao M., Wang S., Ullah Z., et al. Topology detection in power distribution system using kernel-node-map deep networks // IET Gener., Transm. Distrib. 2020. V. 14, N19. p. 4033–4041. doi: 10.1049/iet-gtd.2020.0048.
18. Schmidhuber J. Deep learning in neural networks: an overview // Neural Networks. 2015. V. 61. pp. 85–117. doi: 10.1016/j.neunet.2014.09.00319.
19. Haykin Simon. Neural networks: a comprehensive foundation. Second edition. Хайкин С. Нейронные сети: полный курс. 2-е изд., испр. / пер. с англ. М: ООО «И.Д.Вильямс». 2006. 1104 с.
20. Созыкин А.В. Обзор методов обучения глубоких нейронных сетей // Вестник Южно-уральского государственного университета. Серия: Вычислительная математика и информатика. 2017, Т.6, № 3. С. 28–59.
21. Patterson Josh, Gibson Adam. Deep Learning. A practitioner's approach. Паттерсон Дж., Гибсон А. Глубокое обучение с точки зрения практика / пер. с англ. М.: ДМК Пресс. 2018. 418 с.
22. Хохлов М.В., Голуб И.И. Унифицированный подход к оптимизации размещения РМУ в сети для обеспечения надежности наблюдаемости ЭЭС // Методические вопросы исследования надежности больших систем энергетики. Надежность либерализованных систем энергетики /Отв. ред. Н.И. Воропай, А.Н. Назарычев. Иркутск. 2015. № 65. С. 591–601.

Авторы публикации

Готман Наталья Эрвиновна — научный сотрудник отдела энергетики Института социально-экономических и энергетических проблем Севера Коми, «Коми научный центр Уральского отделения Российской академии наук», Сыктывкар, Россия. E-mail: gotman@energy.komisc.ru.

Шумилова Галина Петровна — канд.техн.наук., старший научный сотрудник отдела энергетики Института социально-экономических и энергетических проблем Севера Коми, «Коми научный центр Уральского отделения Российской академии наук», Сыктывкар, Россия. E-mail: shumilova@energy.komisc.ru.

References

1. Mokeyev AV. Development, testing and Introduction Features of Phasor Measurement Units. *Modern approaches to power system reliability support*. Syktyvkar, 2014. pp. 56-62.
2. Tate JE, Overbye TJ. *Line outage detection using phasor angle measurements*. IEEE Transactions on Power Systems. 2008;23(4):1644–1652.
3. Kim T, Wright SJ. *PMU placement for line outage identification via multinomial logistic regression*. IEEE Transactions on Smart Grid. 2018;9(1):122–131.
4. Cavarro G, Arghandeh R. *Power distribution network topology detection with time-series signature verification method*. IEEE Transactions on Power Systems. 2018;33(4):3500-3509.
5. Ponce C, Bindel DS. FLIER: *Practical topology update detection using sparse PMUs*. IEEE Transactions on Power Systems. 2017;32(6):4222–4232.
6. Srikumar MS, Ananthapadmanbha Dr.T, Khan F.Z, et al. Line outage detection using phasor measurement units. In: *Procedia Technology 21 (2015), SMART GRID Technologies*; August 6–8; 2015. pp. 88–95.
7. Gotman NE, Shumilova GP, Startseva TB. Identifikatsiya topologii elektricheskoy seti na osnove iskusstvennykh neyronnykh setey s ispol'zovaniyem vektornykh izmereniy In: *Rudenko International Conference Metodological problems in reliability study of large energy systems* Vyp. 66. Aktual'nyye problemy nadezhnosti sistem energetiki; 7-11 Sen 2015; Minsk, Byelorussia. Minsk: BNTU, 2015. pp. 251-257.
8. Shumilova GP, Gotman NE, Startseva TB. Opredeleniye topologii elektricheskoy seti pri delenii yeye na uchastki s privyazkoy k ustroystvam PMU. In: *Rudenko International Conference Metodological problems in reliability study of large energy systems* Vyp. 67. Problemy nadezhnosti sistem energetiki; 4-9 Jul 2016; Syktyvkar, Russia. Syktyvkar: ООО «Komi respublikanskaya tipografiya», 2016. pp. 250-255.
9. Gotman NE, Shumilova GP, Startseva TB. Opredeleniye topologii elektricheskoy seti s ispol'zovaniyem sinkhronizirovannykh vektornykh izmereniy. In: *Pyatoy Vserossiyskiy nauchnyy seminar «Aktual'nyye problemy, napravleniya i mekhanizmy razvitiya proizvoditel'nykh sil Severa»*. 21-23 Sen 2016; Syktyvkar, Russia. Syktyvkar: ООО «Komi respublikanskaya tipografiya», 2016;2:15-123.
10. Cardoso P.E. A deep learning applied to PMU data in power systems: Ph.D. thesis. Faculdade De Engenharia Da Universidade Do Porto. 2017. 105 p. Available at: <https://repositorio-aberto.up.pt/bitstream/10216/106289/2/204483.pdf>. Accessed to: 21 Nov 2020.

11. Schmidhuber J. Deep learning in neural networks: an overview. *Neural Networks*. 2015;61:85–117. doi: 10.1016/j.neunet.2014.09.003.
12. Shi H, Xu M.H, Li R. Deep learning for household load forecasting-A novel pooling deep RNN // *IEEE Transactions on Smart Grid*. 2017;9(5):5271–5280.
13. Wang H.Z, Ruan JQ, Wang G, et al. *Deep learning-based interval state estimation of AC smart grids against sparse cyber attacks*. *IEEE Transactions on Industrial Informatics*. 2018;14(11):4766–4778.
14. Li WT, Deka D, Chertkov M, et al. *Real-time faulted line localization and PMU placement in power systems through convolutional neural networks*. *IEEE Transactions on Power Systems*. 2019;34(6):4640–4651.
15. Muhammad A, Lee JM, Hong S.W, et al. *Deep learning application in power system with a case study on solar irradiation forecasting*. In: *Proceedings Int. Conf. Artif. Intell. Inf. Commun. (ICAIIC)*. Feb. 2019. pp. 275–279.
16. Zhang D, Xiaoqing H, Chunyu D. Review on the research and practice of deep learning and reinforcement learning in smart grids. *CSEE Journal of Power and Energy System*. 2018;4(3):362–370.
17. Xiao M, Wang S, Ullah Z, et al. *Topology detection in power distribution system using kernel-node-map deep networks*. *IET Gener., Transm. Distrib.* 2020;14(19):4033–4041. doi: 10.1049/iet-gtd.2020.0048.
18. Schmidhuber J. Deep learning in neural networks: an overview. *Neural Networks*. 2015;61:85–117. doi: 10.1016/j.neunet.2014.09.00319.
19. Haykin Simon. *Neural networks: a comprehensive foundation*. Second edition. Prentice Hall, Upper Saddle River, New Jersey 07458. 1998 (Russ. ed.: Khaykin S. Neyronnyye seti: polnyy kurs. 2-ye izd., ispr. / per. s angl. Moscow: OOO «I.D.Vil'yams». 2006; 1104 p.
20. Sozykin AV. Obzor metodov obucheniya glubokikh neyronnykh setey. *Bulletin of the South Ural State University Series «Computational Mathematics and Software Engineering»*. 2017;6(3):28–59. doi: 10.14529/cmse170303.
21. Patterson Josh, Gibson Adam. *Deep Learning. A practitioner's approach*. Patterson Dzh., Gibson A. *Glubokoye obucheniye s točki zreniya praktika* / per. s ang. Moscow: DMK Press., 2018; 418 p.
22. Khokhlov MV, Golub II. Unifitsirovanny podkhod k optimizatsii razmeshcheniya PMU v seti dlya obespecheniya nadezhnosti nablyudayemosti EES. In: *Rudenko International Conference «Methodological problems in reliability study of large energy systems»*. Nadezhnost' liberalizovannykh sistem energetiki; 30 Jun-04 Jul 2014; Saint-Petersburg, Russia: Irkutsk: ISEM SO RAN, 2015;65:251-257.

Authors of the publication

Natalia E. Gotman – Federal Research Center "Komi Scientific Center of the Ural Branch Russian Academy of Sciences", ISE and EPN, Syktyvkar, Russia. Email: iespn@ksc.komisc.ru.

Galina P. Shumilova – Federal Research Center "Komi Scientific Center of the Ural Branch Russian Academy of Sciences", ISE and EPN, Syktyvkar, Russia. Email: iespn@ksc.komisc.ru.

Получено

24 ноября 2020 г.

Отредактировано

15 декабря 2020 г.

Принято

15 декабря 2020 г.