

Авторы:

Федоров А.О.^{1,2},
к.т.н. Петров В.С.^{1,2},
к.т.н. Ильин А.А.¹,
¹ЧГУ им. И.Н. Ульянова,
²ООО «ЭКРА ИТ»,
г. Чебоксары, Россия.

Fedorov A.O.^{1,2},
Ph.D. Petrov V.S.^{1,2},
Ph.D. Ilyin A.A.¹,
¹Chuvash State University,
²«EKRA IT» LTD,
Cheboksary, Russia.

ОДНОСТОРОННЕЕ ВОЛНОВОЕ ОПРЕДЕЛЕНИЕ МЕСТА ПОВРЕЖДЕНИЯ НА ОСНОВЕ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ

SINGLE-END TRAVELING WAVE FAULT LOCATION BASED ON CONVOLUTIONAL NEURAL NETWORK

Аннотация: сложная конфигурация примыкающей электрической сети или наличие на контролируемой линии электропередачи (ЛЭП) кабельных вставок значительно усложняют распознавание волны, вернувшейся от места короткого замыкания (КЗ), при одностороннем волновом определении места повреждения (ОМП). Авторы предлагают не концентрировать усилия на распознавании волны от КЗ и оценке момента ее прихода, а делегировать поиск места повреждения сверточную нейронную сеть. В статье сформулированы правила подготовки исходных данных для обучения сверточной нейронной сети, приведены рекомендации по выбору ее архитектуры и правила ее обучения. Исследования показали, что разработанное решение на основе сверточной нейронной сети позволяет с высокой точностью определять место повреждения как на воздушной, так и на кабельно-воздушной ЛЭП.

Ключевые слова: определение места повреждения линии электропередачи, сверточная нейронная сеть

Abstract: the branched configuration of the adjoining electrical network or cable segments on the monitored power line greatly complicate the recognition of the wave, returned from the short circuit, for the single-end fault location. The authors propose not to concentrate efforts on recognizing the wave, returned from the short circuit. Instead of this, authors propose to delegate the fault location to a convolutional neural network. In the article, the rules of preprocessing data for training a convolutional neural

Введение

Одностороннее волновое ОМП основано, как известно, на оценке времени пробега волной расстояния от места измерений фазных величин до места КЗ и обратно. При этом часто сложно распознать волну, вернувшуюся от места повреждения, среди множества других волн, приходящих от неоднородностей на контролируемой ЛЭП и из примыкающей электрической сети [1, 2]. Поэтому для одностороннего волнового ОМП авторы предлагают использовать сверточную нейронную сеть (Convolutional neural network, *CNN*).

Осциллограммы аварийных процессов, полученные в условиях эксплуатации, несомненно, будут отличаться от осциллограмм, полученных на основе имитационного моделирования, из-за ВЧ-шумов и локальных искажений фронтов волн, вызванных трактом измерения [3, 4, 8]. Использование *CNN* нивелирует это отличие благодаря ее способности выявлять лишь значимые фрагменты сигнала [5] и позволяет не концен-

трировать усилия на фиксации моментов прихода волн, а также не требует распознавания среди них волны, отраженной от места повреждения.

В настоящей статье излагаются общие правила и принципы подготовки данных для обучения *CNN*, а также приводятся рекомендации по выбору ее архитектуры и обучению.

Подготовка данных

Исходными данными для обучения *CNN* являются сигналы волн, полученные путем моделирования повреждений в модели энергообъекта. Эти данные должны быть компактными и релевантными, а их набор – обладать полнотой [6].

Для обеспечения компактности данных в наборе не должно содержаться идентичных сигналов волн. Поэтому:

- моделируются КЗ только с одной особой фазой;
- угол возникновения КЗ принимается равным 90°, поскольку амплитуды волн,

возникающих в месте повреждения, и, следовательно, в измерениях, зависят от него линейно [9];

- моделируются КЗ с переходными сопротивлениями 0, 50, 100 и 300 Ом, поскольку сигналы волн при КЗ с близкими значениями переходного сопротивления практически не будут отличаться: коэффициенты отражения и преломления в месте повреждения не изменяются более чем на 5% при изменении переходного сопротивления на 10 Ом (рис. 1) [6, 16]. Поэтому можно ограничиться лишь граничными и некоторыми промежуточными значениями переходного сопротивления;

- двухфазное КЗ на землю не моделируется, поскольку коэффициенты отражения и преломления в используемом воздушном волновом канале для него совпадают с соответствующими коэффициентами при трехфазном КЗ (рис. 1) [16];

- длительность сигналов волн принимается равной времени пробега волной удвоенной длины ЛЭП, что достаточно для одностороннего волнового ОМП.

Для обеспечения релевантности набор данных очищается от неинформативных составляющих:

- в сигналах волн заграждаются волны, вернувшиеся к месту измерений из примыкающей сети, поскольку они располагаются на одном и том же отрезке времени для всех мест КЗ на ЛЭП [13];

- исключается из рассмотрения предаварийный режим как не связанный с режимом КЗ;




Рис. 1. Коэффициенты отражения и преломления волн воздушного волнового канала в месте повреждения при различных видах КЗ и переходных сопротивлениях R_f ; верхние индексы (1), (2), (1,1) и (3) – однофазное, двухфазное, двухфазное на землю и трехфазное КЗ соответственно

- заграждается составляющая промышленной частоты;

- используются сигналы волн воздушного волнового канала, поскольку затухание волн в нем заметно меньше, чем в земляном волновом канале [12].

Для обеспечения полноты набора данных он должен покрывать всю длину ЛЭП с постоянным шагом изменения положения места КЗ вдоль линии. Упомянутый шаг выбирается исходя из требований к точности ОМП [8, 10, 11]. Кроме того, полнота набора данных обеспечивается моделированием однофазных, двухфазных и трехфазных КЗ.

Подготовленные данные случайным образом разделяются на три выборки [14]:

- обучающая: используется для обучения *CNN* и обычно принимается равной 70% от общего набора подготовленных данных;

- валидационная: используется для контроля переобучения *CNN* и, как правило, принимается равной 15% от общего набора подготовленных данных;

- тестовая: используется для проверки результата обучения.


Для повышения скорости и стабильности обучения *CNN* из истинных расстояний до места КЗ для каждой выборки вычитается математическое ожидание [15].

Выбор архитектуры

Точность ОМП на основе *CNN* определяется не только качеством набора данных, но и ее архитектурой. Выбор архитектуры *CNN* осуществляется эмпирически и рассматривается как задача планирования эксперимента [17]. В первом приближении, руководствуясь правилом «от простой архитектуры к сложной» [18], сосредотачиваются на минимизации среднеквадратической погрешности ОМП и лишь затем добиваются снижения максимальной погрешности путем уточнения отдельных параметров сети и обучения. При этом, выбирая архитектуру, учитывают, что в сверточном слое *CNN* не следует использовать фильтры большой размерности. Их лучше заменить каскадом сверток с фильтрами более низкой размерности. При этом формируется сеть с меньшим числом параметров, но с тем же размером входа и выхода, что минимизирует вероятность переобучения *CNN* [7], [19].

network are formulated, recommendations for choosing its architecture and learning rules are presented. The developed solution based on a convolutional neural network makes it possible to locate the fault with high accuracy both on overhead and hybrid power lines.

Keywords: fault location on power line, convolutional neural network.



Федоров Алексей Олегович

В 2020 г. в ЧГУ им. И.Н. Ульянова получил степень магистра по направлению «Электроэнергетика и электротехника» по профилю «Электроэнергетические системы, сети, электропередачи, их режимы, устойчивость и надежность». Аспирант кафедры ТОЭ и РЗА ЧГУ им. И.Н. Ульянова. Инженер-исследователь 2 категории ООО «ЭКРА ИТ».



Петров Владимир Сергеевич

В 2010 г. в ЧГУ им. И.Н. Ульянова получил степень магистра по направлению «Электроэнергетика» по профилю «Электроэнергетические системы, сети, электропередачи, их режимы, устойчивость и надежность».

В 2015 г. в ЧГУ им. И.Н. Ульянова защитил кандидатскую диссертацию на тему «Цифровая система автоматического ограничения повышения напряжения сетей 110–750 кВ».

Доцент кафедры ТОЭ и РЗА ЧГУ им. И.Н. Ульянова. Руководитель группы ООО «ЭКРА ИТ».

Правила обучения

При выборе архитектуры *CNN* руководствуются следующими правилами обучения:

- использование слоя подвыборки позволяет *CNN* выявлять лишь значимые фрагменты сигнала и повышает скорость обучения [20];
- для симметричных функций активации с нулевым средним (например, \tanh) лучше использовать инициализацию весов Ксавье, а для ReLu и ему подобных – инициализацию Хе [21];
- для ускорения обучения разделяют обучающую выборку на мини-батчи [21];
- для достижения более точных результатов коэффициент скорости обучения уменьшается, когда ошибка обучения перестает снижаться [15];
- для проверки на тестовой выборке используют нейронную сеть, которая имела наименьшую ошибку валидации при обучении.

Реализация одностороннего волнового ОМП

Приведенные в настоящей статье правила и рекомендации по подготовке данных, выбору архитектуры и обучению *CNN* применяются при одностороннем волновом ОМП на воздушных и кабельно-воздушных ЛЭП.

• Воздушная ЛЭП

На рис. 2 приведена структурная схема одностороннего волнового ОМП воздушной ЛЭП на основе *CNN*. Подготовка данных выполняется на персональном компьютере с учетом правил, изложенных в настоящей статье.

Устройство ОМП сначала преобразует (блок TWS) аварийные фазные токи i_a, i_b, i_c в нормализованный сигнал волн I_{tw}^n (рис. 2, а). Блок TWS состоит из каскадного соединения блока модального преобразования (MT), формирующего сигнал воздушного волнового канала, фильтра верхних частот (HPF), заграждающего составляющую промышленной частоты, а также блока нормализации (NORM). Из сигнала I_{tw}^n удаляются волны, вернувшиеся из энергосистемы, примыкающей к месту измерений (шаблон I_{tr}). Сам шаблон I_{tr} формируется при помощи метода главных компонент (блок PCA) на основе результатов математического моделирования повреждений на

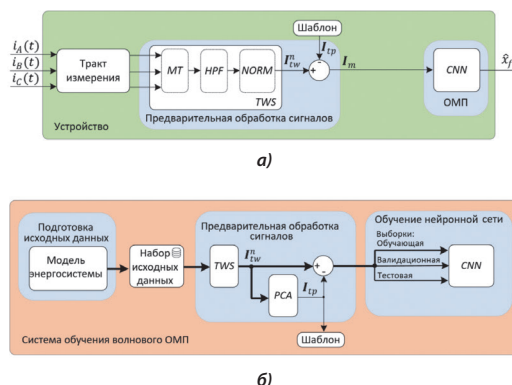


Рис. 2. Реализация одностороннего волнового ОМП ВЛ на основе CNN: а) функциональная схема устройства; б) система обучения волнового ОМП

контролируемой ЛЭП (рис. 2, б). Полученный таким образом сигнал I_m подается на вход обученной *CNN*, которая определяет расстояние до места повреждения \hat{x}_f .

• Кабельно-воздушная ЛЭП

В связи со значительной сложностью распознавания волны, отраженной от места повреждения, классический односторонний способ волнового ОМП вовсе не нашел применения на кабельно-воздушных ЛЭП [22]. Развитие предлагаемого решения позволяет выполнить поиск места КЗ на кабельно-воздушных линиях (КВЛ). При этом подготовка исходных данных и предварительная обработка сигналов для ОМП на ВЛ и КВЛ идентичны, а сама реализация ОМП несколько отличается.

Оценку расстояния до места КЗ на каждом сегменте линии предлагается делегировать своей нейронной сети (рис. 3). Это обусловлено принципиальным отличием процессов распространения волн при КЗ на различных сегментах. Для этого сначала при помощи *CNN*-классификатора идентифицируется поврежденный сегмент

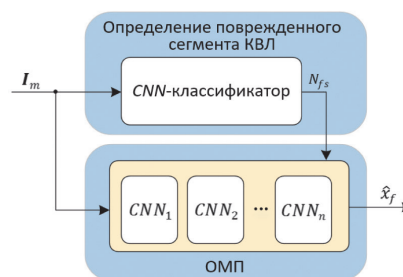


Рис. 3. Реализация одностороннего волнового ОМП КВЛ на основе CNN

КВЛ N_{js} , а затем место КЗ на нем определяется соответствующей нейронной сетью ($CNN_I - CNN_n$).

Пример

Сначала рассмотрим пример разработки CNN для одностороннего волнового ОМП на воздушной ЛЭП длиной 80 км (рис. 4).

Все ВЛ на рис. 4 выполнены на опорах ПБ 220-1 с проводом марки АС-300/39. Примыкающие эквиваленты энергосистем характеризуются волновым сопротивлением 190 Ом.

С учетом вышеупомянутой методики разработана архитектура CNN , представленная на рис. 5.

Параметры обучения CNN , при которых достигается необходимая точность волнового ОМП на ВЛ (300 м), приведены в табл. 1, а сам процесс обучения проиллюстрирован на рис. 6.

Таблица 1. Параметры обучения CNN

Параметр	Значение
Алгоритм оптимизации	adam
Уровень затухания скользящего среднего значения градиента	0,95
Уровень затухания скользящего среднего значения градиента в квадрате	0,99
Максимальное количество эпох	50
Размер мини-батча	8
Перемешивание данных	каждую эпоху
Начальная скорость обучения	0,001
Количество эпох, после которых снижается скорость обучения	5
Коэффициент снижения скорости обучения	0,1
Сеть, возвращающаяся по результатам обучения	с наименьшей ошибкой валидации




Рис. 4. Схема участка сети с ВЛ



Рис. 5. Архитектура и параметры CNN для ОМП на ВЛ



Ильин Алексей Анатольевич
 В 2014 г. в ЧГУ им. И.Н. Ульянова защитил кандидатскую диссертацию на тему «Совершенствование методов структурного анализа входных сигналов цифровых систем релейной защиты и автоматизации». Заместитель заведующего кафедрой ТОЭ и РЗА ЧГУ им. И.Н. Ульянова, доцент.




Рис. 6. Изменение среднеквадратической ошибки (RMSE, кВ) при обучении CNN

Испытания разработанной CNN показали, что среднеквадратическая ошибка ОМП на тестовом наборе данных составляет 27 м, а максимальная – не превышает 230 м (рис. 7). При этом шаг, с которым изменялось положение места КЗ вдоль ЛЭП при формировании набора данных, составлял 250 м.

Теперь рассмотрим реализацию односторонне-го волнового ОМП на КВЛ (рис. 8). Кабельная вставка выполнена из группы одножильных кабелей 2XS(FL)2Y 127/220 1X1500, проложенных горизонтально под землей на глубине 1,5 м. Все остальные параметры схемы идентичны параметрам схемы на рис. 4.

Архитектура CNN-классификатора, определяющего поврежденный сегмент линии, приведена на рис. 9. Ее основное отличие от архитектуры CNN, которая решает задачу определения расстояния до места КЗ, заключается в том, что количество нейронов в выходном слое равно количеству сегментов КВЛ, то есть трем, а функция их активации – логистическая функция *softmax*, значения на выходе которой характеризуют вероятность повреждения каждого сегмента КВЛ.

Параметры, при которых обучался CNN-классификатор, приведены в табл. 1. Точность работы классификатора после обучения составляет 99,86%. Ошибки наблюдаются при классификации сигналов волн, относящихся к КЗ на границах сегментов. Это объясняется схожестью упомянутых сигналов волн в их начале. Повышения точности классификатора можно достичь, например, путем более детального анализа конца упомянутых сигналов, поскольку там обнаруживаются их отличия друг от друга из-за приходящих волн от удаленных узлов сети.

На рис. 10 приведены результаты испытания нейронных сетей $CNN_1 - CNN_3$: среднеквадратическая ошибка CNN_1 составляет 26 м, $CNN_2 - 39$ м, $CNN_3 - 36$ м. Максимальная ошибка ОМП на КВЛ не превышает 200 м. Таким образом, предлагаемый способ одностороннего волнового ОМП КВЛ имеет высокую точность.




Рис. 8. Схема участка сети с КВЛ



Рис. 9. Архитектура и параметры CNN-классификатора




Рис. 7. Погрешность Δx_f ОМП на тестовой выборке: m_t – номер сигнала в тестовой выборке

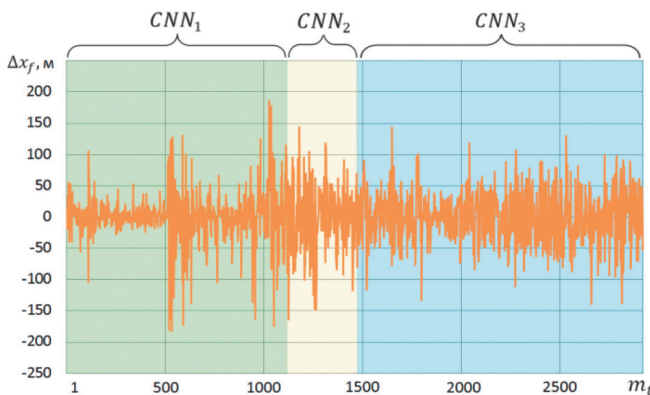


Рис. 10. Погрешность Δx_f определения места повреждения на сегментах КВЛ при помощи $CNN_1 - CNN_3$

Выводы

Одностороннее волновое ОМП осложнено необходимостью распознавания волны, вернувшейся от места повреждения, среди множества других волн, приходящих к месту измерений от неоднородностей на контролируемой ЛЭП и из примыкающей электрической сети. Для преодоления этой сложности в статье предлагается использовать сверточную нейронную сеть. Авторами сформулированы правила подготовки данных для обучения сверточной нейронной сети, приведены рекомендации по выбору ее архитектуры и правила обучения. Исследования показали, что разработанное решение на основе сверточной нейронной сети позволяет определить место повреждения как на воздушной, так и на кабельно-воздушной ЛЭП с погрешностью не более 300 м.

Литература:

1. A. Fedorov, V. Petrov, V. Naumov and V. Hristoforov, «Theory of Single-end Traveling Wave Fault Location,» 2021 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM), Sochi, Russia, 2021, pp. 68-74, doi: 10.1109/ICIEAM51226.2021.9446310.
2. Козлов, В.Н. Расширение возможностей пассивного волнового определения места повреждения за счет отраженных волн / В.Н. Козлов, К.И. Ермаков, Ю.В. Бычков // Релейная защита и автоматизация. – 2019. – № 4 (37). – С. 34-37.
3. W. Li, D. Deka, M. Chertkov and M. Wang, «Real-Time Faulted Line Localization and PMU Placement in Power Systems Through Convolutional Neural Networks,» in IEEE Transactions on Power Systems, vol. 34, no. 6, pp. 4640-4651, Nov. 2019, doi: 10.1109/TPWRS.2019.2917794.
4. Лачугин, В.Ф. Волновые методы определения места повреждения на воздушных линиях электропередачи // Релейная защита и автоматизация. – 2023. – № 1 (50). – С. 58-61.
5. Мясников, Е.Ю. Перспективы применения нейронных сетей в решении задач электроэнергетики [Текст] / Е. Ю. Мясников. // Проблемы и перспективы развития энергетики, электротехники и энергоэффективности: материалы IV Международной научно-технической конференции. – Чебоксары: Издательство Чувашского государственного университета. – 2020. – С. 54-60.
6. Brownlee J. Data Preparation for Machine Learning Data Cleaning, Feature Selection and Data Transforms in Python, Machine learning mastery, 2020, 398 p.
7. Мэрфи К.П. Вероятностное машинное обучение: введение / пер. с англ. А. А. Слинкина. – М.: ДМК Пресс, 2022. – 940 с.
8. S. Lan, M. -J. Chen and D. -Y. Chen, «A Novel HVDC Double-Terminal Non-Synchronous Fault Location Method Based on Convolutional Neural Network,» in IEEE Transactions on Power Delivery, vol. 34, no. 3, pp. 848-857, June 2019, doi: 10.1109/TPWRD.2019.2901594.
9. Козлов, В.Н. Возникновение пассивных волн при повреждениях на линиях электропередачи / В.Н. Козлов, К.И. Ермаков, М.И. Кирушин // Релейная защита и автоматизация. – 2023. – № 1 (50). – С. 46-49.
10. Wang, Lei, Yigang He, and Lie Li «A Single-Terminal Fault Location Method for HVDC Transmission Lines Based on a Hybrid Deep Network» Electronics 10, no. 3, 2021.
11. Almoataz Y., Shady Hossam E., Anamika Y. Artificial Intelligence Applications in Electrical Transmission and Distribution Systems Protection, published October 22, 2021 by CRC Press.
12. Федоров А.О., Алексеев В.С., Петров В.С. Модальные преобразования в устройстве волнового определения места повреждения // Современные тенденции развития цифровых систем релейной защиты и автоматики: Материалы научно-технической конференции молодых специалистов в рамках форума «РЕЛАВЭКСПО-2021», Чебоксары, 20–22 апреля 2021 года. – Чебоксары: Чувашский государственный университет имени И.Н. Ульянова, 2021. – С. 83-88.
13. Сергеев, А.В. Идентификация информационного образа сигнала электрической сети / А.В. Сергеев, А.О. Федоров, В.С. Петров // Информационные технологии в электротехнике и электроэнергетике: материалы XIII всероссийской научно-технической конференции, Чебоксары, 03 июня 2022 года.
14. L. Song Journey to Become a Google Cloud Machine Learning Engineer. Build the Mind and Hand of a Google Certified ML Professional. Packt Publishing, 2022, 330 p.
15. Brownlee J. Better Deep Learning. Train Faster, Reduce Overfitting and Make Better Predictions, Machine learning mastery, 2019, 575 p.
16. F.M. de Magalhães Júnior and F.V. Lopes, «Mathematical Study on Traveling Waves Phenomena on Three Phase Transmission Lines – Part II: Reflection and Refraction Matrices,» in IEEE Transactions on Power Delivery, vol. 37, no. 2, pp. 1161-1170, April 2022, doi: 10.1109/TPWRD.2021.3077730.
17. Славутский, Л.А. Выбор структуры нейронной сети для обработки сигналов как планирование эксперимента / Л.А. Славутский, Е.В. Славутская // Вестник Чувашского университета. – 2021. – № 3. – С. 123-132. – DOI 10.47026/1810-1909-2021-3-123-132.
18. Аггарвал, Чару Нейронные сети и глубокое обучение: учебный курс.: Пер. с англ. - СПб.: ООО «Диалектика», 2020. - 752 с.
19. CS231n: Convolutional Neural Networks for Visual Recognition. URL: <https://cs231n.github.io/convolutional-networks/#overview> (дата обращения: 10.03.2023).
20. Millstein F. Convolutional Neural Networks In Python. Beginner's Guide To Convolutional Neural Networks In Python. CreateSpace Independent Publishing Platform, 2018, 120 p.
21. Николенко С., Кадури А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. – СПб.: Питер, 2018. – 480 с: ил. – (Серия «Библиотека программиста»).
22. C.F. Jensen Online Location of Faults on AC Cables in Underground Transmission Systems. Springer Theses, 2014, 221 p., DOI: 10.1007/978-3-319-05398-1.