



基于神经网络的配网电气拓扑识别算法

刘丽娜¹, 王 韬¹, 周一飞¹, 程志炯¹, 李方硕¹, 张昱航², 徐 杰^{2*}

(1. 国网四川省电力公司计量中心 成都 610045; 2. 电子科技大学信息与通信工程学院 成都 611731)

【摘要】提出了一种基于多通道自适应加权神经网络的配网电气拓扑识别算法, 构建了多通道一维卷积神经网络(1DCNN)模型, 以电压、电流、功率和功率因数 4 种采集数据作为各通道的输入数据, 通过两层叠加的卷积模块实现特征提取; 同时, 提出了一种自适应加权的特征融合方案, 通过神经网络自适应学习各通道重要性特征。实验采用真实用电数据制作数据集, 并针对通道数、数据种类、数据维度等参数进行了多组实验。实验结果表明, 该算法融合多种用电数据特征, 配网电气拓扑辨识准确率达到 99.772%。

关 键 词 自适应加权; 深度学习; 配网电气拓扑识别; 特征融合; 多通道模型
中图分类号 TP274 **文献标志码** A **doi**:10.12178/1001-0548.2022072

Distribution Network Electrical Topology Identification Algorithm Based on Neural Network

LIU Lina¹, WANG Tao¹, ZHOU Yifei¹, CHENG Zhijiong¹, LI Fangshuo¹, ZHANG Yuhang², and XU Jie^{2*}

(1. State Grid Sichuan Electric Power Corporation Metering Center Chengdu 610045;

2. School of Information and Communication Engineering, University of Electronic Science and Technology of China Chengdu 611731)

Abstract This paper proposes a distribution network electrical topology identification algorithm based on a multi-channel adaptive weighted neural network. The algorithm builds a multi-channel 1DCNN (one-dimensional convolutional neural network) model, and uses four types of data: voltage, current, power and power factor, to make the datasets. Feature extraction has been realized through two CNN layers stacked; Meanwhile, an adaptive weighted feature fusion is proposed, it can learn the importance of each channel's feature through neural network adaptively. Datasets collect real consumption data, and multiple sets of experiments are conducted with the number of channels, data types, data dimensions and other parameters. Results show that the proposed algorithm can integrate the advantages of multiple data features, the accuracy of electrical topology identification can reach 99.772%.

Key words adaptive weight; deep learning; distribution network electrical topology identification; feature fusion; multi-channel model

随着泛在电力物联网的迅速发展, 智能电表等采集设备实现了大范围普及, 带来了更为多样化的数据类型和可观的数据量。海量的电力数据为网络通信带来巨大压力, 也为中心主站带来了繁重的数据存储和处理工作。同时, 随着配电网“最后一公里”的智能化发展, 越来越多的高性能设备逐渐接入配电网低压侧, 为开展更为广泛的技术研究提供了硬件条件。

在配网电气拓扑识别方面, 依靠人工巡检的识别方式效率较低, 无法保证拓扑更新效率, 催生了

一系列配网拓扑辨识方法的研究^[1-2]。现有算法往往需要特殊设备或进行较为复杂的数据预处理, 拓扑识别效率有待提升。在此基础上, 面向配电物联网的边缘计算研究应运而生^[3-4], 边缘计算技术将中心主站的部分功能下放至边缘节点, 在边缘计算设备上实现海量数据的本地化处理, 提升了整个配电物联网系统的运行效率。基于边缘计算的配网电气拓扑辨识方法提升了台区拓扑识别效率, 但也需要关注跨台区用户归属等问题^[5]。近年来, 深度学习算法在实际应用场景中得到了广泛应用^[6-7]。文献 [8] 指

收稿日期: 2022-03-10; 修回日期: 2022-05-01

作者简介: 刘丽娜(1981-), 女, 高级工程师, 博士, 主要从事电能计量、智能计量设备检测及电磁兼容测试技术等方面的研究。

*通信作者: 徐杰, E-mail: xuj@uestc.edu.cn

出深度学习工具适用于处理智能电网中的大数据,并解释了深度学习在智能电网中的应用潜力。文献[9]为深度学习技术在配电网运行方式优化研究提供了有效参考。如何选择合适的网络模型,从海量多源异构的配电网数据中有效提取特征,是深度学习在配网电气拓扑识别问题中的关键^[10]。文献[11]将网络拓扑视为图,并构建了一个以负载为输入的深度神经网络,可以模拟不同负载下的交换机状态组合,满足优化目标的要求而无需迭代,提高了实际配电网中的重配置效率。文献[12]提出了一种基于深度学习的直流配电网故障定位方法,对径向分布网络的故障区域识别具有较高的识别率。文献[13]提出一种基于格拉姆角场和改进残差神经网络的户变关系识别方法,提高了户变关系的识别准确率和稳定性。上述研究均验证了深度学习在配电网大数据背景下的应用价值。

本文提出一种基于多通道自适应加权神经网络的配网电气拓扑识别算法,构建了多通道一维卷积神经网络(one-dimensional convolutional neural network, 1DCNN)模型,对低压侧用户的多种数据分别进行特征提取,并通过神经网络自适应分配各通道特征权重,利用卷积层进行特征的深度融合,从而实现配网电气拓扑的准确识别。

1 基于多通道自适应加权神经网络的配网电气拓扑识别算法

1.1 配网电气拓扑识别

配电网低压侧拓扑结构如图1所示。在配电网中,一个台区是指一个变压器供电的范围。在台区范围内,我国普遍采用三相交流电源,由3个频率相同、振幅相等、相位依次互差120°的交流电势组成,每个相位对应一个相区,3个相区尽量均等的接入用户,保证电力利用的最大化。拓扑识别的过程,就是根据用户用电数据,识别用户所在台区和具体相位的过程。

在传统配电网中,采集主站将区域内所有台区的用户数据收集起来,统一保存用户档案,需要大量的数据通信,也难以保证档案的实时更新。在具有边缘计算功能的低压台区^[4],每个或者多个台区接入一个边缘网关(E-IoT),用来收集并处理供电范围内所有智能电表的用电数据,进行配网电气拓扑识别,再将识别结果传输至主站更新存档,提高了配电网整体工作效率。




图1 基于边缘计算的低压台区拓扑结构

1.2 多通道自适应神经加权网络

针对配电网数据量大,数据易出现缺失、异常波动,影响低压侧拓扑的准确识别和其他上层应用开展的问题,本文提出了自适应加权多通道1DCNN的拓扑识别模型,结构如图2所示。该模型主要包括特征提取和特征融合两个模块。由于深度学习对数据缺失、异常波动等问题展现了极大地包容性,因此采集的低压侧用户数据可直接作为模型的输入数据。在特征提取模块,本文将电压、电流、功率和功率因数分别输入到4个通道中进行特征提取,再将提取到的特征输入特征融合模块,进行特征的自适应权重学习并进行加权融合,最终得到拓扑识别结果。

图3具体展示了特征提取模块的层级结构,在综合考虑配电网数据规模和算法执行效率的情况下,本文的特征网络采用了两层堆叠的1DCNN+BN+ReLU结构。其中1DCNN卷积过程如图4所示,假设输入的电力数据 X 的维度为 N_x ,卷积核 K 的维度为 N_k ,卷积过程为:

$$C(j) = \sum_{n=1}^{N_k} X(j+n)K(n) \quad (1)$$

式中, j 为特征位置,满足 $1 \leq j \leq N_x - N_k + 1$ 。

在每个卷积块的激活函数层之前,加入批量归一化(BN)层,可加快网络的训练和收敛速度,并防止训练过拟合,提高后续激活层的性能。激活函数层采用修正线性单元(rectified linear unit, ReLU)函数,可有效避免梯度消失问题,使模型具有稳定的收敛速度。

在特征融合模块中,考虑到不同种类的数据对拓扑识别有不同的影响,提出了一种自适应加权的特征融合方法。在模型训练过程中,通过神经网络

自适应学习各通道特征权重,对拓扑识别更为有利的数据获得更大的权重,从而提升拓扑识别的准确率。模块结构如图5所示,4种维度为 $H \times L$ 的特征首先经过卷积核大小为1的卷积层进行特征压缩,

得到维度为 $H \times L$ 的压缩特征,将4种压缩特征进行横向拼接后,再次通过卷积层压缩得到维度为 $H \times 4$ 的特征图,最后对每个特征纵向求均值,得到大小为 1×4 的矩阵。




图2 多通道自适应加权 1DCNN 拓扑识别模型




图3 特征提取网络




图4 1DCNN 卷积过程

图5中最后一层的 α 、 β 、 γ 、 δ 分别代表4个通道的自适应权重,为了保证权重之和为1,即图中的 $\alpha + \beta + \gamma + \delta = 1$,将得到的权重通过 Softmax 函数计算最终的权重值。Softmax 函数为:

$$P(i) = \frac{e^{\theta_i x}}{\sum_{k=1}^K e^{\theta_k x}} \quad (2)$$

式中, θ_i 和 x 是列向量。通过 Softmax 函数,可将 $P(i)$ 控制在 $[0,1]$ 之间,并保证 $\sum P(i) = 1$ 。

本文通过 Softmax 函数计算权重的具体公式为:

$$i = \frac{e^{\lambda_i}}{\sum_i e^{\lambda_i}} \quad (3)$$

式中, $i = \alpha, \beta, \gamma, \delta$ 。

自适应权重的分配方式由神经网络模型学习

得到,随着样本不同而变化,在实际低压台区拓扑识别中,可根据真实数据条件自适应调整,更加适应实际应用环境。由于不同通道的数据和特征之间并非完全独立,存在一定的隐含关系并影响着最终的拓扑识别,因此在为四通道特征自适应加权之后,本文将特征拼接并再次通过卷积层进行特征的深度融合,学习不同特征之间的隐含关系。最后采用 Softmax 函数作为分类函数。采用交叉熵损失函数作为本模型的损失函数,首先将台区和相位对应的类别转化为 one-hot 向量,再通过计算输出与样本真实标签之间的距离得到交叉熵,交叉熵值越小说明输出与真实值的概率分布越接近,计算公式为:

$$C = -\frac{1}{n} \sum_x y \ln a + (1-y) \ln(1-a) \quad (4)$$

式中, y 为样本的真实标签; a 为模型的实际输出。




图 5 自适应加权模块

2 实验数据与参数设置

2.1 数据集

本文采用某省电力公司低压侧真实用电数据制作配网拓扑识别数据集,选取 11 台变压器(即 11 个台区)下 2 205 名用户进行分析。每个用户通过台区档案记录确定归属台区与相位作为数据集标签,同时对用户的电压、电流、功率和功率因数进行采样,采样频率为 15 min,1 个用户 1 天的数据作为一个样本,采样时间共 9 天,筛选采样失败的样本,共计 18 096 个样本。

2.2 实验环境和参数对象

本文实验采用 Ubuntu16.04.6 系统,CPU 型号

为 Intel(R) Core(TM) i7-7700K CPU@4.20 GHz,显卡型号为 Nvidia Geforce 1080Ti,显存为 11 GB,基于深度学习的 Keras 开源框架完成所有实验。Keras 是一个高度模块化的神经网络库,采用 Python 开发,能够在 Tensorflow、Theano 等平台上完成深度学习的快速开发。

采用的单通道 1DCNN 模型如图 6 所示,其中每层卷积核个数分别为 32、32、64,前两层卷积核大小为 3,第三层为 1。



图 6 单通道 1DCNN 模型

本文提出的双通道 1DCNN 模型的各层参数如表 1 所示。对于参数优化器,采用 Adam 优化器来实现目标函数最小化,初始学习率设置为 0.001,一阶矩估计的指数衰减率为 0.9,二阶矩估计的指数衰减率为 0.999。实验所使用的训练批处理大小为 10,epoch 为 100。所用数据集是在真实数据基础上制作而成,所有模型均在此数据集上进行实验。

表 1 多通道 1DCNN 模型参数

模块	层	参数
特征提取模块	卷积层1	卷积核大小为3,卷积核个数为32, l2正则化0.02
	卷积层2	卷积核大小为3,卷积核个数为32
特征融合模块	卷积层	卷积核大小为1,卷积核个数为64, l2正则化0.02
	Dropout层	Dropout率为0.2

3 实验结果与分析

本节主要通过实验对比验证算法的有效性,具体分为以下 3 个方面:对比不同数据组合和不同通道数量下的拓扑识别结果;对比自适应加权模块对拓扑识别的影响,并分析权重的分配结果;对比多通道模型下不同数据维度的识别准确率。

3.1 多通道模型的有效性分析

为了验证多通道模型的有效性,本文首先对基于不同数据和不同通道个数进行了对比实验,结果如表 2 所示。

表 2 中,首先前 4 组实验分别使用电压、电

流、功率和功率因数中的单种数据作为输入，进行基于单通道 1DCNN 的拓扑辨识。实验结果显示，只有电压数据可单独实现较为准确的拓扑辨识，其他 3 种数据在单独使用时识别准确率都很低。基于这一结论，分别将电压数据与其他 3 种数据进行组合，通过双通道 1DCNN 模型开展拓扑辨识计算，实验结果显示，电压与任意其他数据组合的识别准确率都高于单通道模型，其中与功率因数的组合效果最好。在此基础上，将 4 种数据均作为输入，使用四通道 1DCNN 模型，最终的拓扑识别准确率达到 99.772%。因此，验证了多通道模型对台区拓扑识别准确度的提高。

表 2 多通道模型对比实验结果

通道数	电压	电流	功率	功率因数	准确率/%
1	√				99.548
		√			16.100
			√		18.042
				√	36.248
2	√	√			99.622
	√		√		99.638
	√			√	99.766
4	√	√	√	√	99.772

3.2 自适应加权模块实验分析

为了验证自适应权重对识别结果的影响，对是否添加自适应加权模块的四通道 1DCNN 模型进行了一组对比实验，实验结果如表 3 所示。结果显示，自适应加权模块使得识别的准确率、召回率和 F1 分数的 3 个指标均有所提高。可见，自适应加权模块实现了对各特征重要性的有效学习，提升了多通道模型的拓扑识别准确性。

表 3 自适应加权对比实验结果

实验编号	是否加权	准确率/%	召回率/%	F1 分数/%
1	否	99.530	99.512	99.514
2	是	99.772	99.686	99.686

在模型训练完成后，将样本带入模型中，输出特征融合模块的权重数值，表 4 给出了 10 个样本示例的自适应权重分配情况，可以看出电压在大部分样本的拓扑识别中都具有最大的权重，而其他 3 个指标在部分样本中也占了一定的比重。最终，全部 18 096 个样本的权重均值如下：电压权重为 0.678 67，电流权重为 0.122 85，功率权重为 0.095 91，功率因数权重为 0.102 55。可以看出电压对拓扑识别的影响最大，电流、功率因数和功率起到辅助作用，这与前面的多通道对比实验结论一致。

表 4 自适应权重示例

样本编号	权重			
	电压	电流	功率	功率因数
1	0.797 76	0.070 43	0.065 4	0.066 40
2	0.817 86	0.063 90	0.057 35	0.060 87
3	0.737 67	0.088 84	0.085 85	0.087 63
4	0.581 21	0.158 41	0.126 89	0.133 47
5	0.626 52	0.144 16	0.109 17	0.120 13
6	0.583 95	0.139 44	0.137 36	0.139 23
7	0.788 21	0.079 51	0.064 24	0.068 02
8	0.892 15	0.036 64	0.034 94	0.036 26
9	0.471 92	0.182 13	0.172 20	0.173 73
10	0.761 41	0.079 50	0.079 50	0.079 57

3.3 同维度样本数据实验分析

前述实验均使用了 1×96 维的输入数据，即采样时间为 1 天的样本。为了测试样本维度对模型识别效果的影响，本文基于 1×24、1×48、1×72 和

1×96 共 4 种输入数据维度进行了模型训练和测试。实验结果如表 5 所示，随着样本维度的增加，3 个测试指标均有所提升，最终维持趋于平稳。

由于输入大小为 72 和 96 的识别结果相差较

小, 本文对模型训练情况进行分析。图7给出了输入大小为72和96两个模型100轮训练的loss值变化曲线, 从图中看出, 输入大小为96的训练过程收敛更快, 在50轮次左右就已趋于平稳, 而输入大小为72的模型整体波动较大, 甚至在65轮训练时, 测试集loss值仍有较大起伏。因此, 综合考虑实际应用场景和两组实验结果, 选用96作为输入数据维度较为合适。

表5 不同样本维度对比实验结果

实验编号	样本维度	准确率/%	召回率/%	F1分数/%
1	24	94.610	92.726	93.086
2	48	98.974	98.936	98.940
3	72	99.646	99.634	99.634
4	96	99.772	99.686	99.686




图7 不同维度输入数据训练模型时的loss曲线

4 结束语

本文基于配电网的多源异构数据, 考虑电力数据的数据特征与采集条件, 提出了基于多通道自适应加权神经网络的配网电气拓扑识别算法, 采用了多通道1DCNN模型, 以电压、电流、功率和功率因数4种采集数据作为各通道的输入数据, 并提出了一种自适应加权的特征融合方案, 通过神经网络自适应学习各通道特征重要性, 实现各通道数据特征的合理融合。

随着配电网物联网的发展和边缘计算技术的落实, 将有越来越多的数据得以实现在线采集和存储, 深度学习等新兴算法也将有条件在边缘侧实现部署。在此基础上, 将有更为丰富的数据类型来支持本文算法, 实现更为准确高效的多通道拓扑识别; 针对不同台区的不同数据条件, 本算法可以动态地选择数据种类和通道数量, 满足各种应用需求。

参考文献

- [1] 李晓蕾, 刘昊, 牛斌斌, 等. 基于改进二叉树支持向量机的低压台区用户拓扑关系识别[J]. 电子器件, 2021, 44(4): 959-964.
- [2] LI X L, LIU H, NIU B B, et al. Low voltage topological connection relation identification based on the improved binary tree support vector machine[J]. Chinese Journal of Electron Devices, 2021, 44(4): 959-964.
- [3] 宋玮琼, 郭帅, 李冀, 等. 基于电压时序数据的配电台区户变关系智能识别[J]. 电力系统及其自动化学报, 2022, 34(1): 48-55.
- [4] SONG W Q, GUO S, LI J, et al. Intelligent recognition of user-transformer relationship in distribution station area based on time series voltage data[J]. Proceedings of the CSU-EPSCA, 2022, 34(1): 48-55.
- [5] CHEN J M, JIANG W, JIAO H, et al. Application prospect of edge computing in smart distribution[C]//2018 China International Conference on Electricity Distribution (CICED). [S.l.]: IEEE, 2018: 1370-1375.
- [6] LIU L N, LI R C, ZHOU Y F, et al. ETI-ECF: Edge computing framework for distribution network electrical topology identification[C]//The 4th International Conference on Computer Science and Application Engineering (CSAE). New York: ACM, 2020: 1-6.
- [7] ZHOU Y F, LIU L N, LI R C, et al. Distribution network electrical topology identification based on edge computing and improved KNN[C]//Proceedings of the 2020 4th International Conference on Electronic Information Technology and Computer Engineering. Association for Computing Machinery. New York: ACM, 2020: 806-813.
- [8] 杜娟, 刘志刚, 宋考平, 等. 基于卷积神经网络的抽油机故障诊断[J]. 电子科技大学学报, 2020, 49(5): 751-757.
- [9] DU J, LIU Z G, SONG K P, et al. Fault diagnosis of pumping unit based on convolutional neural network[J]. Journal of University of Electronic Science and Technology of China, 2020, 49(5): 751-757.
- [10] 吴润晖, 赵子天, 陈晓雷, 等. 大气低频声信号识别深度学习研究方法研究[J]. 电子科技大学学报, 2020, 49(5): 758-765.
- [11] WU Y H, ZHAO Z T, CHEN X L, et al. Research on deep learning method of atmospheric low frequency acoustic signal recognition[J]. Journal of University of Electronic Science and Technology of China, 2020, 49(5): 758-765.
- [12] BAGHERI A, BOLLEN M H J, GU I Y H. Big data from smart grids[C]//2017 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe). [S.l.]: IEEE, 2017: 1-5.

- [9] 闫冬, 彭国政, 高海龙, 等. 基于深度强化学习组合优化的配电网拓扑控制研究[J]. 电网技术, 2022(7): 2547-2554.
YAN D, PENG G Z, GAO H L, et al. Research on distribution network topology control based on deep reinforcement learning combinatorial optimization[J]. Power System Technology, 2022(7): 2547-2554.
- [10] 杨涛, 孙志达, 唐明, 等. 基于 TensorFlow 框架的改进 BP 户变关系识别方法[J]. 浙江电力, 2021, 40(8): 25-32.
YANG T, SUN Z D, TANG M, et al. An improved BP method for transformer-user relationship identification based on tensorflow framework[J]. Zhejiang Electric Power, 2021, 40(8): 25-32.
- [11] CHEN X G, TAN H, YU B, et al. Multi-Objective distribution network reconfiguration based on deep learning algorithm[C]//2018 IEEE International Conference on High Voltage Engineering and Application (ICHVE). [S.l.]: IEEE, 2018: 1-4.
- [12] LUO G M, TAN Y J, YAO C Y, et al. Deep learning-based fault location of DC distribution networks[J]. The Journal of Engineering, 2019(16): 3301-3305.
- [13] 白勇, 熊隽迪, 杨渝, 等. 基于格拉姆角场和改进残差网络的低压配电台区户变关系识别方法[J]. 重庆理工大学学报(自然科学), 2021, 35(12): 189-197.
BAI Y, XIONG J D, YANG Y, et al. Consumer-Transformer relationship identification based on gaf and improved residential network algorithm[J]. Journal of Chongqing University of Technology (Natural Science), 2021, 35(12): 189-197.

编辑 税红