

DOI: 10.19783/j.cnki.pspc.240746

基于深度神经网络融合欧氏距离的多环配电网拓扑辨识方法

李博通¹, 孙铭阳², 张婧¹, 陈发辉¹, 陈晓龙¹, 王永祺³, 武娇雯³, 魏然³

(1. 天津大学智能电网教育部重点实验室, 天津 300072; 2. 国家电网有限公司华北分部, 北京 100053;
3. 国网天津市电力公司, 天津 300010)

摘要: 针对多环配电网的拓扑辨识问题, 考虑到量测信息可能部分缺失的情况, 提出了基于深度神经网络融合欧氏距离的多环配电网拓扑辨识方法。首先, 分析了传统拓扑辨识中相关性判断法应用于环状配电网的局限性, 在此基础上提出基于欧氏距离的拓扑辨识判据。然后, 针对量测信息缺失时的多环拓扑辨识问题, 研究了利用深度神经网络融合欧氏距离判据的拓扑辨识方法。最后, 在 Matlab 中利用 MatPower 搭建 32 节点“蜂巢”电网模型, 在缺失不同比例的量测数据情况下验证方法的准确性。结果表明, 当缺失大量量测数据时, 所提方法仍有较高的拓扑辨识准确率。

关键词: 欧氏距离; 多环配电网; 深度神经网络; 拓扑辨识; 量测信息缺失

Topology identification method for multi-ring distribution networks based on deep neural networks and Euclidean distance

LI Botong¹, SUN Mingyang², ZHANG Jing¹, CHEN Fahui¹, CHEN Xiaolong¹, WANG Yongqi³, WU Jiaowen³, WEI Ran³

(1. Key Laboratory of Smart Grid of Ministry of Education, Tianjin University, Tianjin 300072, China; 2. North China Branch of State Grid Corporation of China, Beijing 100053, China; 3. State Grid Tianjin Electric Power Company, Tianjin 300010, China)

Abstract: In response to the problem of topological identification for multi-ring power distribution networks and considering the possibility of partial loss of measurement information, a method for topological identification of multi-ring power distribution networks based on deep neural networks and Euclidean distance is proposed. First, the limitations of the traditional topological identification method using correlation judgment in ring-shaped power distribution networks are analyzed. Based on this, a topological identification criterion based on Euclidean distance is proposed. Then, to address the issue of topological identification of multi-ring networks with missing measurement information, a method combining deep neural networks with the Euclidean distance criteria is proposed. Finally, a 32-node “honeycomb” power grid model is built in Matlab using MatPower, and the accuracy of the method is verified under different levels of missing measurement data. The results show that even with a large amount of missing measurement data, the proposed method still maintains a high accuracy for topological identification.

This work is supported by the Science and Technology Project of the Headquarters of State Grid Corporation of China (No. 5400-202412189A-1-1-ZN).

Key words: Euclidean distance; multi-ring power distribution network; deep neural network; topology identification; measurement information loss

0 引言

随着社会对可持续发展需求的不断提升, 我国电力系统正逐步实现“碳达峰”、“碳中和”的目标^[1-3]。在这一背景下, 分布式电源和储能系统大规模接入

中压配电网, 为实现新能源的高比例消纳提供了可行性。然而, 新能源的随机性和波动性给传统中压配电网的运行和管理提出了新的挑战^[4-6]。为确保电力系统能够稳定、高效地运行, 目前迫切需要更加精细和智能的监测、调控和保护手段。在提升调控精准度和保护性能的过程中, 准确的中压配电网拓扑结构是至关重要的基本条件^[7-8]。

与输电网相比, 中压配电网的结构特征和功能特性使得拓扑辨识面临巨大挑战。首先, 中压配电

基金项目: 国家电网有限公司总部科技项目资助(5400-202412189A-1-1-ZN)“低压配电网环网供电模式与运行策略研究”

网中含有大量的馈线和节点,设备繁多,结构复杂。中压配电网中监测设备和通信链路有限,系统可观性差,运行人员难以获得线路和开关状态信息,难以确定实时拓扑结构。其次,分布式发电和储能系统接入中压配电网,其随机性和波动性使得中压配电网的运行和控制方式更为复杂,拓扑变化更为频繁^[9]。一般而言,一个典型的配电变电站每天可能发生 5~10 次开关切换事件,若考虑优化控制、分布式能源协调等功能的实现,开关切换事件的频次将显著增长^[10]。因此,研究中压配电网拓扑辨识方法具有重要意义和价值。

拓扑辨识与潮流计算、状态估计、容量分配和故障定位等工作之间的联系紧密,可以为新能源接入中压配电网提供结构层面的决策支持和技术指导。国内外学者针对中压配电网拓扑辨识问题开展了大量研究,目前主要的拓扑辨识方法有最优匹配法^[11-14]、相关性判断法^[15-19]以及机器学习法^[20-27]。文献[11]利用网络拓扑约束和基尔霍夫定律结合同步相量测量装置(phasor measurement unit, PMU)建立回路电流方程,综合考虑拓扑错误以及数据中坏数据并存的情况对拓扑信息进行辨识。文献[12]利用直流潮流模型将支路两端相角差表示为支路有功功率和支路电纳的函数,以支路有功功率为变量,推导极坐标形式下不同量测量的量测方程,采用加权最小二乘算法求解状态量以判断线路是否投运。文献[13]引入了结构方程模型(structural equation modeling, SEM)来捕捉拓扑结构与支路电流之间的关系,然后采用混合整数规划(mixed integer programming, MIP)技术,通过复数方程的实部和虚部解耦以及泰勒展开等手段对方程和约束条件进行线性化处理,以便利用现有的商业求解器进行有效求解。文献[14]提出了一种基于量测数据与预测数据融合的拓扑辨识方法。该方法通过将预测的辨识结果转化为不确定参数的联合概率密度函数,并基于最大似然估计原理,确定与量测数据匹配概率最大的拓扑结构。文献[15]提出了一种针对配电网全局拓扑辨识以及状态估计的方法,通过计算不同节点之间的皮尔逊相关系数完成拓扑辨识,随后再使用 Newton-Raphson 迭代算法和潮流方程对最初的拓扑辨识结果进行修正。文献[16]引入了马尔科夫随机场进行节点关联分析和拓扑建模,并引入了伪似然方法和 L2 正则化理论来提高计算效率且防止过拟合问题。文献[17]提出了一种基于知识图谱技术的拓扑辨识方法,对低压配电网中的冗杂信息进行处理,推导出变压器、台区、馈线、低压用户电表的关联性规则,构建配电网拓扑结构和知识图谱。

文献[18]利用主成分分析法对数据进行分析,基于测量值的时序数列实现拓扑辨识。文献[19]提出了一种基于欧氏形态距离的配电台区拓扑结构辨识方法。该方法利用改进的最长公共子序列(longest common subsequence, LCS)方法计算形态距离,再结合欧氏距离和形态距离形成欧氏形态距离,使用聚类评价指标完成拓扑辨识。但是文献[11-19]所提方法难以在量测信息缺失时实现拓扑辨识。

机器学习法一般可以实现信息缺失场景下的拓扑辨识。文献[20]考虑了不同节点的量测数据对拓扑辨识的影响权重,使用 LightGBM 方法对节点的量测信息进行筛选,选择以电压幅值作为深度神经网络的输入完成配电网拓扑辨识。文献[21]考虑多种参数特征,使用归一化方法对有功功率、无功功率、电压幅值和电压相位角进行处理,再利用深度神经网络完成拓扑辨识。文献[22]提出了一种基于图卷积网络(graph convolutional network, GCN)的方法,将配电网中线路和节点特征抽象为线图,利用抽象后线图的邻接矩阵和节点特征训练卷积网络,该方法使用的量测信息为电压数据。文献[23]在卷积神经网络的基础上,选用均值法收集节点信息,求取某个节点及其相邻节点状态平均值作为模型输入,该方法默认了不同节点信息在网络中所占权重相等,缺乏对节点真实物理信息的考虑。文献[24]构建了融合卷积神经网络(convolutional neural networks, CNN)、长短期记忆网络(long short-term memory, LSTM)和注意力机制(Attention)的拓扑结构辨识模型。文献[25]利用变分高斯贝叶斯混合模型和麻雀搜索算法(sparrow search algorithm, SSA)-支持向量机(support vector machine, SVM)算法对配电网拓扑进行实时辨别。文献[26]提出了一种基于两阶段特征选择和格拉姆角场(Gramian angular field, GAF)的配电网拓扑辨识方法,使用基于 XGBoost 和最大信息系数的两阶段特征选择方法筛选量测数据,使用 3 层卷积神经网络完成拓扑辨识。文献[27]提出了一套基于集成深度神经网络的配电网联络关系辨识方案,该方案首先通过二维小波阈值去噪方法降低噪声影响,然后采用搜索、生成与评价策略对数据进行特征提取与选择,最后采用交叉熵深度神经网络完成联络关系辨识。文献[20-27]均使用机器学习的方法实现拓扑辨识,但存在以下两个问题: 1) 针对中压配电网的算例均为 IEEE 33 节点和 IEEE 69 节点或是更为简单的辐射状拓扑,其均未考虑到在多环电网结构下联络开关两侧电压的强相关性给拓扑辨识带来的困难,文献[24]不适用于具有强相关性的多环电网结构,其余文献均未提及多环

拓扑结构的适用性; 2) 文献[26]考虑到量测信息缺失最大 25% 的情况, 但并未考虑到大面积信息缺失的情况, 其余文献均未考虑到量测信息的缺失问题。

相对于辐射状配电网, 环状配电网具有高可靠性、高稳定性、强灵活性以及节能环保等优势^[28-30]。目前, 多环状配电网已在中国北京、雄安、上海、山东、浙江、天津等地开展示范工程^[31-33]。然而, 与辐射状配电网相比, 环状配电网的拓扑结构中各节点之间的电气距离更为接近, 各节点电压之间具有强相关性, 导致相关系数法和最优匹配法难以实现拓扑辨识, 机器学习法的拓扑辨识准确率低。因此, 本文针对多环中压配电网拓扑辨识方法展开研究。

本文提出一种基于深度神经网络融合欧氏距离的多环中压配电网拓扑辨识方法。首先分析皮尔逊相关系数判据应用于环状电网的局限性, 在此基础上提出基于欧式距离的拓扑辨识判据, 验证了在多环配电网中欧氏距离具有更强的表征拓扑结构的能力; 随后, 针对量测信息缺失的环状拓扑辨识问题, 研究并提出基于深度神经网络融合欧氏距离判据的拓扑辨识方法; 最后, 给出在缺失不同比例量测数据时本算法拓扑辨识的准确率。

1 表征拓扑结构的特征值及其特性分析

常用的基于配电网实时量测信息的拓扑辨识方法是相关性判断法^[34]。相关性判断法针对不同节点采集到的数据进行相关性计算, 相关性越高表明两节点间电气距离越近, 由此确定节点间联络开关的开断状态。在配电网中, 数据采集装置主要为 SCADA 装置, 采集的数据为节点输出功率和节点电压幅值。其中, 节点的输出功率主要取决于负荷或接入的分布式电源, 由于各负荷或分布式电源之间相对独立, 各节点功率之间的相关性较小。而两节点间的电气距离越近, 两节点的电压幅值波动越接近, 两节点的电压幅值相关性越高^[20]。因此, 节点电压幅值比节点输出功率更能有效反映节点间的电气距离, 更加适用于拓扑辨识。

1.1 表征拓扑结构的特征值

皮尔逊相关系数反映两个变量之间的相关性, 范围为 $[-1, 1]$, 其结果越接近 1, 表明其相关性越高。假设 \mathbf{Y} 和 \mathbf{Y}' 分别为两不同节点连续时刻的电压幅值。

$$\begin{cases} \mathbf{Y} = \{y_o\} (o=1, 2, \dots, g) \\ \mathbf{Y}' = \{y'_o\} (o=1, 2, \dots, g) \end{cases} \quad (1)$$

式中: y_o 为 o 时刻 \mathbf{Y} 的电压幅值; y'_o 为 o 时刻 \mathbf{Y}' 的电压幅值; g 表示该连续时刻电压量测值数量。两节点电压的相关系数为

$$r(\mathbf{Y}, \mathbf{Y}') = \frac{\sum_{o=1}^g (y_o - \bar{y})(y'_o - \bar{y}')}{\sqrt{\sum_{o=1}^g (y_o - \bar{y})^2} \sqrt{\sum_{o=1}^g (y'_o - \bar{y}')^2}} \quad (2)$$

式中: r 为变量 \mathbf{Y} 与变量 \mathbf{Y}' 的相关系数, $r > 0$ 表示变量 \mathbf{Y} 与 \mathbf{Y}' 正相关, $r < 0$ 表示 \mathbf{Y} 与 \mathbf{Y}' 负相关, $r = 0$ 表示两者不相关; \bar{y} 、 \bar{y}' 分别为变量 \mathbf{Y} 、 \mathbf{Y}' 的均值。

当辐射状配电网某一联络开关断开后, 联络开关两侧节点之间的电气距离明显增大, 其相关性明显降低, 因此利用相关系数法可实现辐射状配电网拓扑结构的有效辨识。但是, 环状配电网各节点电压之间有强相关性, 当某一联络开关打开后, 联络开关两侧仍有多条线路构成回路, 节点电压之间仍具有强相关性, 此时皮尔逊相关系数难以反映开关的开断情况。针对该问题, 本文采用欧氏距离作为表征环状配电网中联络开关开断的特征值。

欧氏距离 (Euclidean distance) 指在几何空间中两点之间的直线距离。它是一种常用的距离度量方法, 经常被用来衡量样本或数据点之间差异性, 欧氏距离表示为^[19]

$$d = |\mathbf{Y} - \mathbf{Y}'|_2 = \sqrt{\sum_{o=1}^g (y_o - y'_o)^2} \quad (3)$$

式中, d 表示欧式距离。相比于相关系数, 欧氏距离能够更好地表征数据之间的微小差异。当环状配电网联络开关打开时, 两侧的欧式距离明显增大, 因此利用欧式距离可以实现环状电网的拓扑辨识。

1.2 信息完全时环状拓扑结构的特征值分析

在 MatPower 中, 搭建如图 1 所示的多环蜂巢配电网结构。各节点的对外输出功率参考 IEEE 33 节点系统^[35], 如表 1 所示。

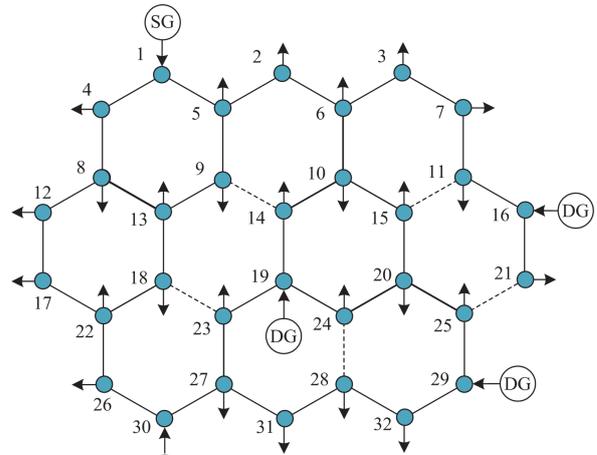


图 1 环状蜂巢配电网拓扑结构

Fig. 1 Topology of ring honeycomb distribution network

表 1 环状蜂巢配电网拓扑结构各节点对外输出的额定功率
Table 1 Rated power output of each node in the topology of the ring honeycomb distribution network

节点编号	额定有功/kW	额定无功/kvar	节点编号	额定有功/kW	额定无功/kvar
2	100	60	18	90	40
3	90	40	19	90	40
4	120	80	20	90	40
5	60	30	21	90	40
6	60	20	22	90	40
7	200	100	23	-300	-150
8	200	100	24	420	200
9	60	20	25	420	200
10	60	20	26	60	25
11	45	30	27	60	25
12	60	35	28	60	20
13	60	35	29	-300	-150
14	120	80	30	-300	-150
15	60	10	31	150	70
16	-350	-150	32	210	100
17	60	20			

图 1 中节点 1 为平衡节点, 节点 16、19、29、30 为分布式电源, 9-14、11-15、18-23、21-25、24-28 为联络开关。各节点的额定功率如表 1 所示。

在 MatPower 中, 将图 1 所示的蜂巢多环配电网中的 5 个联络开关随机开断 100 次, 随机生成了 100 种拓扑结构。在每一种拓扑结构下, 负荷和分布式电源的输出功率在额定功率的基准上随机波动, 均进行 30 次潮流计算。

以判断联络开关 9-14 开断为例, 利用每一种拓扑结构下 30 次潮流计算的数据, 计算节点 9 和节点 14 的电压相关系数, 如图 2 所示。

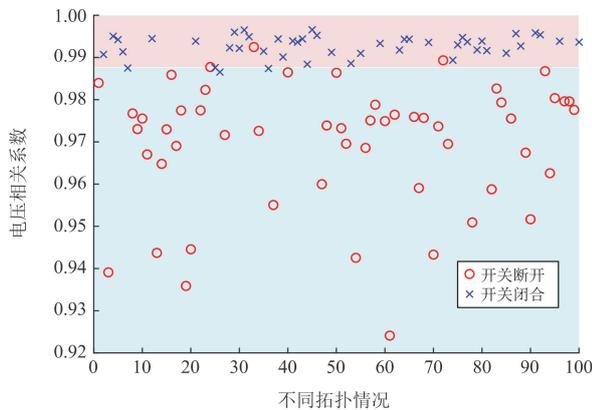


图 2 环状电网不同拓扑情况节点 9 和节点 14 的电压相关系数
Fig. 2 Voltage correlation coefficients of nodes 9 and 14 in different topologies of ring power network

图 2 表明, 环状电网联络开关断开或者闭合, 其联络开关两侧电压的相关系数都很高, 在(0.92,1)范围表现了强相关性, 而且有少量联络开关断开的相关系数要大于联络开关闭合时的相关系数。因此, 仅依靠联络开关两侧的电压相关系数的大小来判断联络开关状态可能会判断错误。

仍以联络开关 9-14 开断为例, 在每一种拓扑结构下利用 30 次潮流计算的数据, 计算节点 9 和节点 14 的电压欧氏距离, 如图 3 所示。

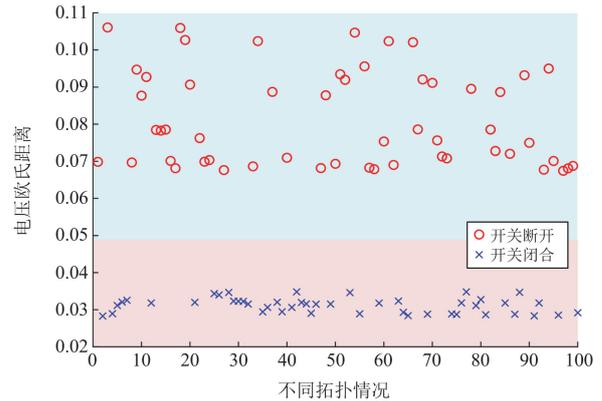


图 3 环状电网不同拓扑情况节点 9 和节点 14 的电压欧氏距离
Fig. 3 Voltage Euclidean distance of nodes 9 and 14 in different topology of ring network

根据图 3 可以看出, 联络开关闭合时的欧式距离比联络开关断开时更小, 而且有明显区别。图 2、图 3 表明, 对于环状配电网, 使用电压欧式距离作为判断联络开关开断的依据更为可靠。

1.3 信息缺失时环状拓扑结构的特征值分析

在实际电力系统中, 部分量测装置或通信通道可能会因故障、损坏或其他原因而失效。因此, 研究信息缺失时的拓扑辨识具有重要的现实意义。本节在部分量测信息未知的情况下进一步研究表征联络开关状态的特征值的表现情况。

考虑联络开关两侧均没有量测信息, 例如节点 9、节点 14、节点 18、节点 23 的量测信息缺失, 利用节点 13 和节点 19 的电压信息来判断联络开关 9-14 和联络开关 18-23 的开断情况, 如图 4 所示。

当联络开关 9-14 和联络开关 18-23 均闭合时, 节点 13 和节点 19 之间的电气距离最小, 即电压相关系数最高, 欧氏距离最小; 当联络开关 9-14 和 18-23 一个闭合一个断开时, 节点 13 和节点 19 之间的电气距离增大, 即电压相关系数减小, 欧氏距离增大; 当联络开关 9-14 和 18-23 均断开时, 节点 13 和节点 19 之间的电气距离最大, 即电压相关系数最小, 欧氏距离最大。

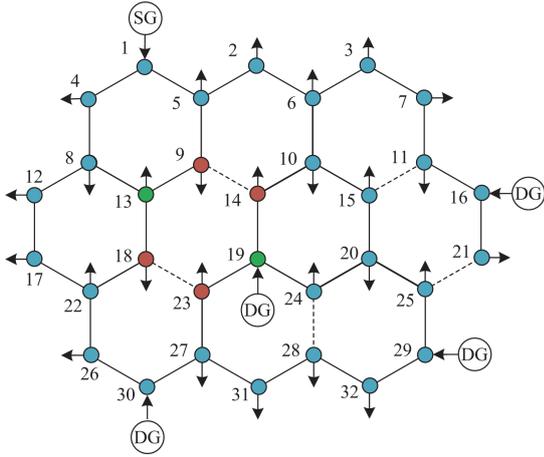


图4 缺失节点9、14、18、23量测信息的多环蜂巢电网拓扑
Fig. 4 Multi-ring cellular network topology of missing the measurement information of nodes 9, 14, 18 and 23

使用节点13和节点19的电压相关系数来判断联络开关9-14和联络开关18-23的开断情况,如图5所示。

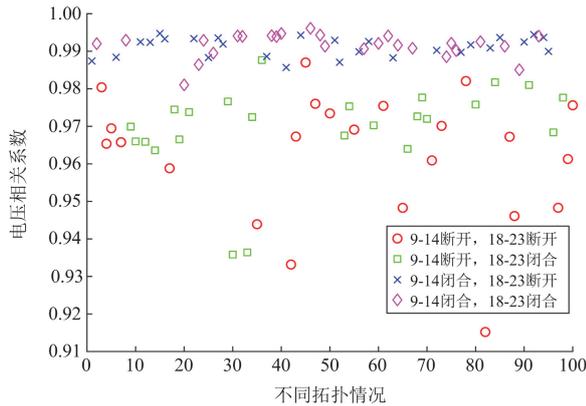


图5 环状电网不同拓扑情况节点13和节点19的电压相关系数
Fig. 5 Voltage correlation coefficients of nodes 13 and 19 in different topologies of ring power network

图5表明,仅依据节点13和节点19的电压相关系数大小,已经无法判断两个联络开关的开断情况。

使用节点13和节点19的电压欧氏距离来表征联络开关9-14和联络开关18-23的开断情况,如图6所示。

图6表明,当缺失了联络开关两侧的电压数据时,仅依靠节点13和节点19的电压欧氏距离可以对联络开关9-14和联络开关18-23的开断情况进行判断。当联络开关9-14闭合时,判断联络开关18-23的状态,节点电压的欧氏距离区别不明显,可能判断错误,此时可以引入其他节点之间的欧氏距离对

同一个联络开关进行综合判断,以提高其准确率。针对多维度欧氏距离信息融合的联络开关状态判别问题,可考虑采用深度学习算法构建多特征融合模型,通过自适应加权机制实现不同节点电压欧氏距离的有效整合,从而提升状态判别的准确性和可靠性。

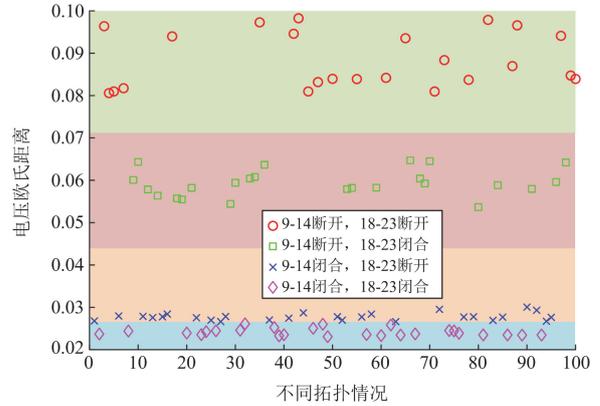


图6 环状电网不同拓扑情况节点13和节点19的电压欧氏距离
Fig. 6 Voltage Euclidean distance of nodes 13 and 19 in different topologies of ring power network

图6表明,当缺失了联络开关两侧的电压数据时,仅依靠节点13和节点19的电压欧氏距离可以对联络开关9-14和联络开关18-23的开断情况进行判断。

2 基于神经网络的多环拓扑辨识

根据第1节分析可知,在缺失联络开关两侧量测信息的情况下,相邻节点的电压欧氏距离仍能较好表征联络开关的状态。因此,可以利用不同节点电压之间的欧氏距离表征某一个联络开关状态的特征值。实际电网运行中,当出现量测装置故障等突发状况导致部分线路量测信息缺失时,电网可以利用未缺失节点电压信息获取大量表征联络开关开断的特征值,但各个特征值对于不同联络开关的表征权重尚不明确,本节采用神经网络的方式来解决上述问题。

2.1 深度神经网络的层次结构

深度神经网络(deep neural network, DNN)是深度学习的组成部分,它由多层神经网络组成,形成一种分层的结构。每一层包含多个神经元(或节点),而这些层次化的结构允许网络自动提取和学习数据的抽象特征。深度神经网络的深度来自于其多层次的结构,这种多层次的神经元堆叠结构使其能够更好地捕捉数据的复杂关系。图7为DNN的典型结构。

图7中, $x_i (i=1,2,\dots,m)$ 为输入层,将原始数据作为输入,每一个输入节点对应于一个特征量。本文中利用电压欧氏距离判断拓扑结构,各输入节点为不同节点电压之间的欧氏距离,输入层的个数取

决于可以得到的不同节点之间的电压欧氏距离总个数。 $a_j(j=1,2,\dots,n)$ 和 $b_k(k=1,2,\dots,s)$ 为两个隐藏层,根据具体问题对隐藏层的数量和每一层中神经元的数量进行选择,多个隐藏层使网络能够解决更复杂的问题,每一层都对输入进行一些抽象和转换,逐渐提取更高级的特征。但隐藏层过多将会导致计算时间过长、计算资源的浪费以及过拟合的问题。 $z_l(l=1,2,\dots,q)$ 和 $h(z_l)(l=1,2,\dots,q)$ 为输出层,输出层的个数取决于可能出现的拓扑结构数量,其中 $z_l(l=1,2,\dots,q)$ 为网络输出函数, $h(z_l)(l=1,2,\dots,q)$ 为激活函数,激活函数的输出结果为对应拓扑结构的概率。

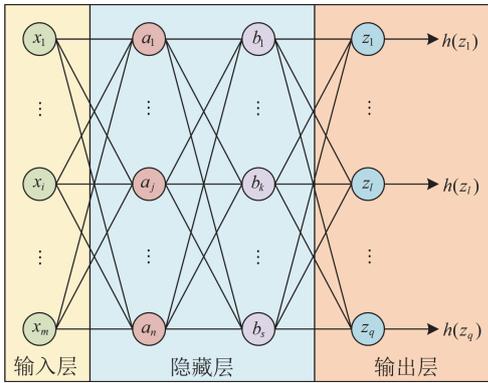


图7 DNN的典型结构

Fig. 7 Typical structure of DNN

2.2 深度神经网络的前向传播

前向传播是将电压欧氏距离从输入层传递到输出层并生成预测结果的过程。通过层与层之间的权重和激活函数,网络能够逐渐转换输入数据,提取输入数据特征,并最终生成输出数据。前向传播是推导阶段的关键,其效果取决于网络的权重和结构。

首先对电压欧氏距离进行数据处理,使用Min-Max归一化方法,将原始数据映射到指定的范围([0,1])。假设输入层原始数据 \mathbf{X} 为

$$\mathbf{X}=[x_1 \ x_2 \ \dots \ x_m]^T \quad (4)$$

式中: $x_i(i=1,2,\dots,m)$ 为在某一种拓扑结构下,计算得出的不同节点间电压欧氏距离; m 为不同节点间能构成的欧氏距离数量。对 \mathbf{X} 中的每一个元素通过式(5)进行归一化处理。

$$x'_i = \frac{x_i - \min(\mathbf{X})}{\max(\mathbf{X}) - \min(\mathbf{X})}, i=1,2,\dots,m \quad (5)$$

式中: $\min(\mathbf{X})$ 为 \mathbf{X} 中最小元素值; $\max(\mathbf{X})$ 为 \mathbf{X} 中最大元素值; x'_i 为 \mathbf{X} 中归一化后的元素,由此构成归一化后的输入数据为

$$\mathbf{X}'=[x'_1 \ x'_2 \ \dots \ x'_m]^T \quad (6)$$

式中, \mathbf{X}' 为归一化后的输入数据。

归一化数据处理将原始数据中的最小值映射到0,最大值映射到1,其他值则按照线性比例映射到[0,1]区间内。归一化是一种有效的预处理技术,有助于克服神经网络训练中数值稳定性和收敛性差的问题,从而提高模型的性能和泛化能力。

在前向传播过程中,每个神经元的输入是前一层神经元的输出,通过连接该神经元输入层和前一层神经元输出层的权重进行加权求和,如式(7)所示。

$$\begin{cases} a_j = f(\sum_{i=1}^m \omega_{i,j} x'_i + \theta_j), j=1,2,\dots,n \\ b_k = f(\sum_{j=1}^n \omega'_{j,k} a_j + \theta'_k), k=1,2,\dots,s \\ z_l = f(\sum_{k=1}^s \omega''_{k,l} b_k + \theta''_l), l=1,2,\dots,q \end{cases} \quad (7)$$

式中: $\omega_{i,j}$ 为连接输入层和第一个隐藏层的权重; θ_j 为其偏置; $\omega'_{j,k}$ 为连接第一个隐藏层和第二个隐藏层的权重; θ'_k 为其偏置; $\omega''_{k,l}$ 为连接第二个隐藏层和输出层的权重; θ''_l 为其偏置; $f(x)$ 表示隐藏层的激活函数,本文采用ReLU(Rectified Linear Unit),该函数为

$$f(x) = \max(0, x) \quad (8)$$

其中,对于输入 x ,如果 x 大于等于零,则输出 $f(x)=x$,否则输出 $f(x)=0$ 。引入ReLU激活函数有以下优势。

1) 引入非线性映射,使得神经网络能够学习和表示更加复杂的函数关系。线性变换的堆叠本质上仍是线性的,难以拟合非线性关系。网络通过ReLU进行非线性变换,则可以更好地拟合非线性关系。

2) 缓解梯度消失问题,ReLU激活函数在输入为正时具有恒为1的梯度特性,且不存在饱和现象。这一特性有效改善了神经网络在反向传播过程中的梯度衰减问题,有利于深层网络的训练优化。

3) 引入稀疏性,ReLU在负数部分输出为零,因此引入了一定程度的稀疏性。这种稀疏性有助于网络学习更具代表性的特征,减少不必要的冗余信息,从而提高其泛化性能。

输出层的激活函数使用SoftmaxLayer。该函数将网络的原始输出转化为一个概率分布的输出,使得所有类别的预测概率之和为1。对于输入向量 $[z_1 \ z_2 \ \dots \ z_q]^T$,其激活函数为

$$h(z_l) = \frac{e^{z_l}}{\sum_{p=1}^q e^{z_p}}, l=1,2,\dots,q \quad (9)$$

式中, e^{z_l} 表示 z_l 的指数,确保输出的每一个元素都是正的。

在多分类问题中, 可以使用交叉熵损失函数来衡量模型的输出与真实结果之间的差异。模型的输出 \mathbf{O} 为

$$\mathbf{O} = [h(z_1) \ h(z_2) \ \cdots \ h(z_q)] \quad (10)$$

实际类别表示为

$$\mathbf{T} = [t_1 \ t_2 \ \cdots \ t_q] \quad (11)$$

式中, $t_i (i=1, 2, \dots, q)$ 表示拓扑结构的所有类别, 真实类别对应为 1, 其余类别均为 0。

损失函数 c_{loss} 的表达式为

$$c_{\text{loss}} = -\sum_{i=1}^q t_i \ln(h(z_i)) \quad (12)$$

实际类别概率越低, 损失越大; 反之, 实际类别的概率越高, 损失越小, 当实际类别概率接近 1 时, 损失接近 0。

2.3 深度神经网络的反向传播及参数更新

式(6)中的权重和偏置可以写成 3 个权重矩阵 \mathbf{W}_1 、 \mathbf{W}_2 、 \mathbf{W}_3 和 3 个偏置矩阵 \mathbf{B}_1 、 \mathbf{B}_2 、 \mathbf{B}_3 , 即

$$\mathbf{W}_1 = \begin{bmatrix} \omega_{1,1} & \omega_{1,2} & \cdots & \omega_{1,m} \\ \omega_{2,1} & \omega_{2,2} & \cdots & \omega_{2,m} \\ \vdots & \vdots & & \vdots \\ \omega_{n,1} & \omega_{n,2} & \cdots & \omega_{n,m} \end{bmatrix} \quad (13)$$

$$\mathbf{W}_2 = \begin{bmatrix} \omega'_{1,1} & \omega'_{1,2} & \cdots & \omega'_{1,n} \\ \omega'_{2,1} & \omega'_{2,2} & \cdots & \omega'_{2,n} \\ \vdots & \vdots & & \vdots \\ \omega'_{s,1} & \omega'_{s,2} & \cdots & \omega'_{s,n} \end{bmatrix} \quad (14)$$

$$\mathbf{W}_3 = \begin{bmatrix} \omega''_{1,1} & \omega''_{1,2} & \cdots & \omega''_{1,s} \\ \omega''_{2,1} & \omega''_{2,2} & \cdots & \omega''_{2,s} \\ \vdots & \vdots & & \vdots \\ \omega''_{q,1} & \omega''_{q,2} & \cdots & \omega''_{q,s} \end{bmatrix} \quad (15)$$

$$\mathbf{B}_1 = [\theta_1 \ \theta_2 \ \cdots \ \theta_n]^T \quad (16)$$

$$\mathbf{B}_2 = [\theta'_1 \ \theta'_2 \ \cdots \ \theta'_s]^T \quad (17)$$

$$\mathbf{B}_3 = [\theta''_1 \ \theta''_2 \ \cdots \ \theta''_q]^T \quad (18)$$

使用 Xavier 初始化方法对权重矩阵进行初始化, 从均值为零的高斯分布中采样获得权重矩阵的元素。以权重矩阵 \mathbf{W}_1 为例, 其方差 $\text{Var}(\mathbf{W}_1)$ 为

$$\text{Var}(\mathbf{W}_1) = \frac{2}{m+n} \quad (19)$$

式中: m 为前一层的神经元数目; n 为当前层中的神经元数目。

使用 Xavier 初始化方法使得每一层的输出方差与输入方差相近, 从而避免梯度过大或梯度过小产生的梯度爆炸或梯度消失问题。每一层参数更新的幅度不会相差太大, 从而加速收敛。

使用 Adam 优化算法迭代求解权重和偏置。该

方法是一种基于梯度的优化算法, 结合了梯度的一阶矩估计和二阶矩估计, 以自适应的方式调整学习率。

具体计算步骤如下。

1) 初始化参数, 初始化一阶矩估计 u 为零; 初始化二阶矩估计 v 为零。

2) 计算梯度, 根据损失函数 c_{loss} 对每一个待求参数计算梯度。

3) 更新一阶矩估计 u 和二阶矩估计 v 。

$$u_t = \beta_1 u_{t-1} + (1 - \beta_1) \nabla c_{\text{loss}} \quad (20)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) (\nabla c_{\text{loss}})^2 \quad (21)$$

式中: u_t 为第 t 步的一阶矩估计; v_t 为第 t 步的二阶矩估计; β_1 和 β_2 为衰减系数; ∇c_{loss} 为 c_{loss} 的梯度。

4) 修正一阶矩估计和二阶矩估计。

$$\hat{u}_t = \frac{u_t}{1 - \beta_1^t} \quad (22)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (23)$$

式中: \hat{u}_t 为第 t 步的一阶矩估计; \hat{v}_t 为第 t 步的二阶矩估计。

5) 更新参数。

$$\theta_t = \theta_{t-1} - \alpha \frac{\hat{u}_t}{\sqrt{\hat{v}_t} + \varepsilon} \quad (24)$$

式中: θ_t 为第 t 步的待求参数; α 为学习率, 一般取值为 0.001; ε 为一个很小的常数, 用于防止除零错误, 一般取 1×10^{-8} , 其数值大小不影响准确率和计算时间。Adam 优化算法的流程图如图 8 所示。

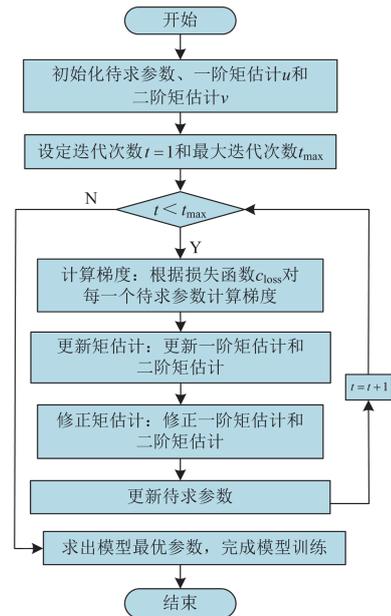


图 8 Adam 优化算法的流程图

Fig. 8 Flowchart of the Adam optimization algorithm

3 算例分析

针对图 1 的环状拓扑结构, 求解 32 个节点间的电压欧氏距离和相关系数, 将其分别作为深度神经网络的输入。图 1 中有 5 个联络开关, 5 个联络开关最多可以构成 32 种拓扑结构, 将不同拓扑进行排序编号 0—31, 并作为输出。5 个联络开关随机开断构造 100 种随机拓扑结构, 每一种拓扑结构下负荷和分布式电源的输出功率在额定功率的基础上随机波动, 均计算 30 次潮流, 模拟真实电力系统负荷波动情况, 利用电压数据求解欧氏距离和电压相关系数。取其中 75 组拓扑作为训练集, 25 组拓扑结构作为检验集。

深度神经网络相关参数设定如下: 两个隐藏层, 每个隐藏层含 300 个全连接神经元; 输出层有 32 个神经元; 迭代次数为 120 次; 使用 Adam 优化算法; 初始学习率为 0.005; 梯度最大阈值设定为 1。在 i7-7700 CPU, 12 GB RAM 的台式计算机中使用 Matlab 完成仿真。

3.1 信息完整时拓扑辨识算例

当特征值使用节点电压信息构成的电压相关系数时, 其拓扑辨识结果如表 2 所示。

表 2 信息完整时电压相关系数检验集准确率

Table 2 Accuracy of test set for voltage correlation coefficient with complete information

拓扑编号	准确率/%	拓扑编号	准确率/%	拓扑编号	准确率/%
1	99.997	10	79.177	18	47.446
2	89.096	11	92.961	19	84.463
3	47.077	12	98.372	20	64.093
4	99.296	13	99.959	21	91.141
5	96.666	14	99.673	22	86.648
6	98.920	15	100.000	23	59.635
7	54.694	16	99.997	24	78.459
8	99.836	17	64.756	25	72.764
9	97.507				

表 2 表明, 大部分拓扑结构辨识都有较高的准确率, 小部分拓扑辨识准确率不够高, 其平均准确率为 84.105%, 说明以电压相关系数为判据的深度神经网络模型进行拓扑辨识时的泛化性能不佳。

当特征值使用节点电压信息构成的电压欧氏距离时, 其拓扑辨识结果如表 3 所示。

由表 3 可以看出: 检验集中所有的拓扑均有较高的准确率, 其平均准确率为 99.968%。相比于表 2, 使用电压相关系数作为判据, 其准确率大幅提升。这说明在处理环状拓扑辨识问题时使用以电压欧氏

距离为判据的深度神经网络模型有更好的泛化性能。因此后续主要考虑使用电压欧氏距离作为判据构造深度神经网络模型。

表 3 信息完整时电压欧氏距离检验集准确率

Table 3 Accuracy of voltage Euclidean distance test set with complete information

拓扑编号	准确率/%	拓扑编号	准确率/%	拓扑编号	准确率/%
1	99.989	10	99.991	18	100.000
2	99.985	11	100.000	19	100.000
3	99.966	12	99.995	20	99.940
4	99.207	13	100.000	21	99.602
5	99.977	14	99.993	22	100.000
6	99.985	15	99.999	23	99.958
7	99.869	16	99.949	24	100.000
8	99.992	17	100.000	25	99.954
9	99.891				

3.2 信息缺失时拓扑辨识算例

1.3 节分析表明, 尽管关键信息的缺失会影响联络开关开断状态的判断准确性, 但通过引入其他节点的辅助信息仍可实现有效判别。特别是深度神经网络能够充分挖掘和融合多节点间的关联特征, 通过多层次信息整合显著提升判断准确性。因此, 理论上本方法适用于解决信息缺失情况下的拓扑辨识问题。

以图 9 为例, 随机丢失 25% 节点的电压数据。

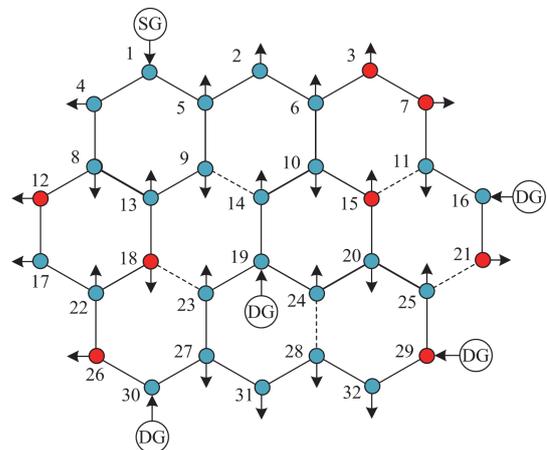


图 9 缺失 25% 量测信息的多环蜂巢电网拓扑

Fig. 9 Multi-ring cellular network topology missing 25% measurement information

图 9 中, 红色节点为缺失量测信息的节点。即缺失节点 3、7、12、15、18、21、26、29 的信息, 利用剩余节点之间的欧氏距离进行拓扑辨识。在不缺失数据时, 输入的数据有 $C_{32}^2 = 496$ 个 (32 个节点之间的欧氏距离), 缺失了 25% 的数据后, 输入数据

变为 $C_{24}^2 = 276$ 个(24 个节点之间的欧氏距离)。在构建好深度神经网络模型后,将检验集中的 25 组拓扑结构分别代入深度神经网络模型中计算其准确率,结果如表 4 所示。

表 4 缺失 25%量测数据时使用电压欧氏距离作为判据的准确率

拓扑编号	准确率/%	拓扑编号	准确率/%	拓扑编号	准确率/%
1	99.821	10	99.996	18	99.924
2	100.000	11	99.994	19	99.712
3	99.904	12	99.845	20	72.091
4	99.950	13	100.000	21	99.913
5	99.822	14	99.939	22	99.999
6	99.845	15	99.967	23	100.000
7	84.359	16	99.999	24	99.990
8	96.289	17	100.000	25	99.891
9	99.951				

表 4 中,各拓扑结构的准确率均较高,仅 7 号、8 号、20 号拓扑结构的准确率低于 99.7%,其平均准确率为 98.048%。

图 10 验证了随机丢失 50%的量测数据时,本文算法的效果。

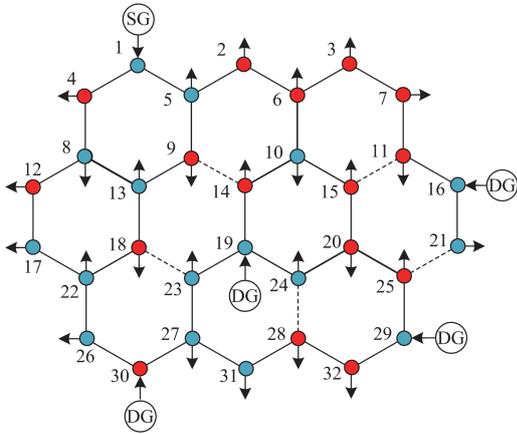


图 10 缺失 50%量测信息的多环蜂巢电网拓扑

Fig. 10 Multi-ring cellular network topology missing 50% measurement information

图 10 中,红色节点为丢失量测信息的节点。使用剩余节点的量测信息进行拓扑辨识。其输入参数为已知量测信息的两两组合,即 $C_{16}^2 = 120$ 个(16 个节点之间的欧氏距离)。在构建好深度神经网络模型后,将检验集中的 25 组拓扑结构分别代入深度神经网络模型中计算其准确率,结果如表 5 所示。

表 5 中,准确率低于 99%的拓扑结构有 8 个,

平均准确率为 96.035%。总体而言,在随机缺失 50%量测数据的情况下,拓扑辨识仍有较高的准确率。

表 5 缺失 50%量测数据时使用电压欧氏距离作为判据的准确率

拓扑编号	准确率/%	拓扑编号	准确率/%	拓扑编号	准确率/%
1	99.968	10	99.974	18	99.971
2	99.969	11	99.959	19	69.712
3	95.761	12	92.950	20	88.235
4	99.989	13	99.981	21	90.898
5	99.573	14	84.337	22	99.999
6	86.899	15	99.984	23	99.980
7	99.997	16	99.968	24	100.000
8	99.952	17	99.997	25	99.971
9	92.850				

图 11 验证了随机丢失 75%的量测数据时本文算法的效果。

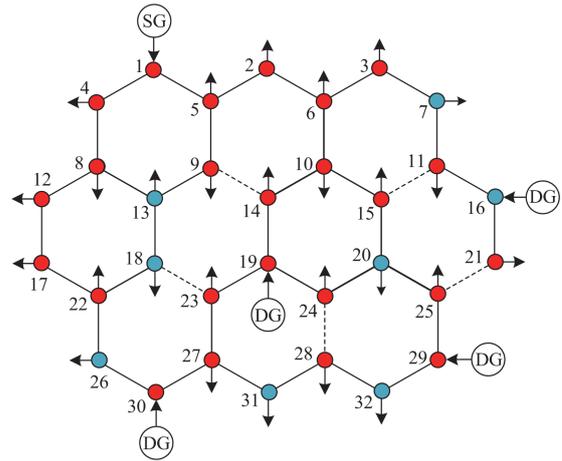


图 11 缺失 75%量测信息的多环蜂巢电网拓扑

Fig. 11 Multi-ring cellular network topology missing 75% measurement information

图 11 中,红色节点为丢失量测信息的节点。使用剩余节点的量测信息进行拓扑辨识。其输入参数为已知量测信息的两两组合,即 $C_8^2 = 28$ 个(8 个节点之间的欧氏距离),在构建好深度神经网络模型后,将检验集中的 25 组拓扑结构分别代入深度神经网络模型中计算其准确率,结果如表 6 所示。

表 6 中,在缺失 75%的量测数据时,算法准确率超过 99%的拓扑结构仍有 11 个,其平均准确率为 88.976%。因此,在缺失大量量测信息时,本文算法仍有较高的准确性。

为了验证本文方法的优越性,将本文方法(DNN 融合欧氏距离)与以下 4 种方法(DNN 融合相关系

数、DNN 直接处理量测数据、支持向量机(support vector machine, SVM)融合欧氏距离、卷积神经网络(convolutional neural network, CNN)融合欧氏距离)进行对比。在缺失不同比例数据情况下进行对比。图 12 为这 5 种方法在缺失不同比例数据时的拓扑辨识准确率。

表 6 缺失 75%量测数据时使用电压欧氏距离作为判据的准确率

Table 6 Accuracy of using voltage Euclidean distance as criterion when 75% of measurement data is missing

拓扑编号	准确率/%	拓扑编号	准确率/%	拓扑编号	准确率/%
1	72.701	10	99.777	18	99.832
2	90.259	11	65.532	19	99.942
3	99.186	12	63.214	20	94.995
4	99.830	13	99.624	21	98.882
5	100.000	14	100.000	22	99.993
6	89.463	15	99.964	23	68.514
7	53.604	16	100.000	24	72.178
8	67.991	17	91.089	25	99.303
9	98.518				

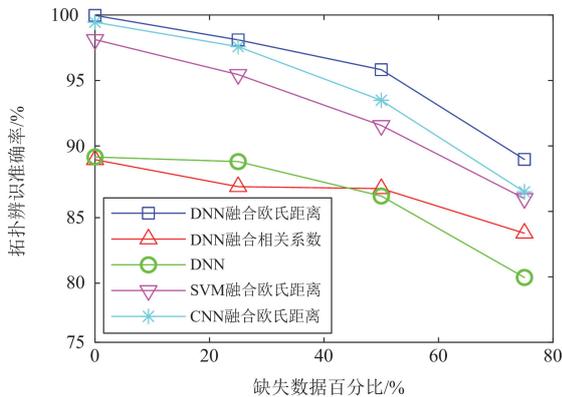


图 12 不同方法的拓扑辨识准确率

Fig. 12 Topology identification accuracy of different methods

图 12 表明,对比 DNN 融合相关系数判据以及 DNN 直接处理量测数据,本方法的欧氏距离判据应用于多环配电网拓扑辨识具有明显的优越性;对比 SVM 融合欧氏距离以及 CNN 融合欧氏距离,本方法中的 DNN 模型应用于多环配电网拓扑辨识具有更高的准确率。

为了验证本文方法中 Adam 优化算法的优越性,将其与随机梯度下降(stochastic gradient descent, SGD)算法和 RMSprop 算法进行对比。图 13 为使用这 3 种方法在缺失不同比例数据时的拓扑辨识准确率。

图 13 表明,本文的 Adam 优化算法拓扑辨识准

准确率远高于 SGD 优化算法,且略高于 RMSprop 优化算法。

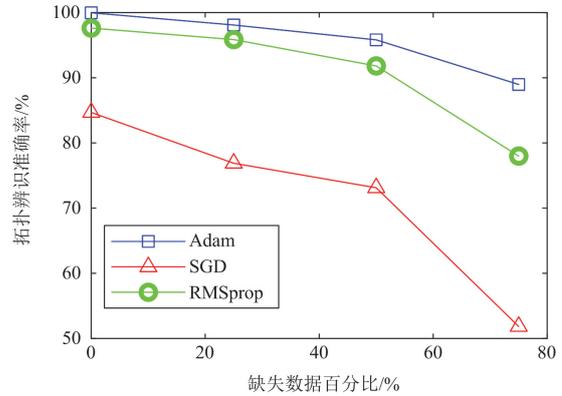


图 13 DNN 中不同优化算法的拓扑辨识准确率

Fig. 13 Topology identification accuracy of different optimization algorithms in DNN

4 结论

本文针对环状配电网在非完全信息下的拓扑辨识展开研究,主要贡献和结论如下。

1) 分析了相关系数判据应用于环状配电网拓扑辨识的局限性,并提出了基于欧式距离的环状配电网拓扑辨识判据。研究了在缺失部分量测信息时利用有限量测信息表征联络开关开断情况的方法。

2) 针对量测信息缺失的数量和位置不明确的问题,研究了利用神经网络融合欧式距离判据的拓扑辨识方法,使用了 ReLU 和 SoftmaxLayer 激活函数以及 Adam 优化算法构建了适用于拓扑辨识的神经网络模型。

3) 给出了在缺失不同比例量测数据时本文算法的准确性,在随机缺失 50%量测数据时,保证 96%的准确率;在随机缺失 75%的量测数据时,保证 88%的准确率。算例表明本文算法即使在缺失大量量测数据时,仍能保证有较高的拓扑辨识准确率。

参考文献

[1] 刘天蔚, 边晓燕, 吴珊, 等. 电力系统碳排放核算综述与展望[J]. 电力系统保护与控制, 2024, 52(4): 176-187. LIU Tianwei, BIAN Xiaoyan, WU Shan, et al. Overview and prospect of carbon emission accounting in electric power systems[J]. Power System Protection and Control, 2024, 52(4): 176-187.

[2] 程杉, 傅桐, 李洋洋, 等. 含高渗透可再生能源的配电网灵活性供需协同规划[J]. 电力系统保护与控制, 2023, 51(22): 1-12. CHENG Shan, FU Tong, LI Fengyang, et al. Flexible supply demand collaborative planning for distribution

- networks with high penetration of renewable energy[J]. *Power System Protection and Control*, 2023, 51(22): 1-12.
- [3] 陶思钰, 江福庆. 集群化发展模式下风电场预测、规划及控制关键技术综述[J]. *电力工程技术*, 2024, 43(1): 86-99.
- TAO Siyu, JIANG Fuqing. Review of the key technologies of wind farm cluster prediction, planning and control[J]. *Electric Power Engineering Technology*, 2024, 43(1): 86-99.
- [4] 刘洪, 李其哲, 徐晶, 等. 网孔型中压配电网组网形态、核心特征与研究展望[J]. *电力系统自动化*, 2023, 47(16): 181-191.
- LIU Hong, LI Qizhe, XU Jing, et al. Networking morphology, key feature and research prospect of mesh-type medium-voltage distribution network[J]. *Automation of Electric Power Systems*, 2023, 47(16): 181-191.
- [5] AHSAN F, DANA N H, SARKER S K, et al. Data-driven next-generation smart grid towards sustainable energy evolution: techniques and technology review[J]. *Protection and Control of Modern Power Systems*, 2023, 8(3): 1-42.
- [6] SHETA A N, ABDULSALAM G M, SEDHOM B E, et al. Comparative framework for AC-microgrid protection schemes: challenges, solutions, real applications, and future trends[J]. *Protection and Control of Modern Power Systems*, 2023, 8(2): 1-40.
- [7] 王成山, 王瑞, 于浩, 等. 配电网形态演变下的协调规划问题与挑战[J]. *中国电机工程学报*, 2020, 40(8): 2385-2396.
- WANG Chengshan, WANG Rui, YU Hao, et al. Challenges on coordinated planning of smart distribution networks driven by source-network-load evolution[J]. *Proceedings of the CSEE*, 2020, 40(8): 2385-2396.
- [8] 陈沛东, 曹华珍, 何璇, 等. 中压配电网近邻交互式分布式拓扑辨识算法[J]. *电力工程技术*, 2023, 42(2): 139-146.
- CHEN Peidong, CAO Huazhen, HE Xuan, et al. Distributed topology identification algorithm of medium-voltage distribution network based on neighboring interaction[J]. *Electric Power Engineering Technology*, 2023, 42(2): 139-146.
- [9] VITTAL V. The impact of renewable resources on the performance and reliability of the electricity grid[J]. *Bridge*, 2010, 40(1): 5-12.
- [10] CAVRARO G, ARGHANDEH R. Power distribution network topology detection with time-series signature verification method[J]. *IEEE Transactions on Power Systems*, 2018, 33(4): 3500-3509.
- [11] 马静, 张侯好, 马伟, 等. 一种新型电网拓扑错误辨识方法[J]. *电力自动化设备*, 2016, 36(1): 82-88, 96.
- MA Jing, ZHANG Yuyu, MA Wei, et al. Topology error identification of power grid[J]. *Electric Power Automation Equipment*, 2016, 36(1): 82-88, 96.
- [12] 何欣, 井天军, 田昀, 等. 基于支路有功功率的拓扑错误辨识方法[J]. *电子器件*, 2020, 43(3): 505-510.
- HE Xin, JING Tianjun, TIAN Yun, et al. Topology error identification method based on branches active power[J]. *Chinese Journal of Electron Devices*, 2020, 43(3): 505-510.
- [13] 刘博, 陈佳璇, 李江. 基于 SEM-MIP 状态估计的配电网拓扑辨识方法[J]. *电力系统保护与控制*, 2024, 52(13): 69-77.
- LIU Bo, CHEN Jiaxuan, LI Jiang. SEM-MIP based state estimation for topology identification in a distribution network[J]. *Power System Protection and Control*, 2024, 52(13): 69-77.
- [14] NOURI A, JAFARIAN M, KEANE A. Reconciliation of measured and forecast data for topology identification in distribution systems[J]. *IEEE Transactions on Power Delivery*, 2021, 37(1): 176-186.
- [15] ZHANG J, WANG Y, WENG Y, et al. Topology identification and line parameter estimation for non-PMU distribution network: a numerical method[J]. *IEEE Transactions on Smart Grid*, 2020, 11(5): 4440-4453.
- [16] ZHAO J, LI L, XU Z, et al. Full-scale distribution system topology identification using Markov random field[J]. *IEEE Transactions on Smart Grid*, 2020, 11(6): 4714-4726.
- [17] 高泽璞, 赵云, 余伊兰, 等. 基于知识图谱的低压配电网拓扑结构辨识方法[J]. *电力系统保护与控制*, 2020, 48(2): 34-43.
- GAO Zepu, ZHAO Yun, YU Yilan, et al. Low-voltage distribution network topology identification method based on knowledge graph[J]. *Power System Protection and Control*, 2020, 48(2): 34-43.
- [18] SATYA J P, NIRAV B, RAMKRISHNA P, et al. Identifying topology of low voltage distribution networks based on smart meter data[J]. *IEEE Transactions on Smart Grid*, 2018, 9(5): 5113-5122.
- [19] 尹鹏, 梁海深, 顾志成, 等. 基于欧氏形态距离与 AP 聚类分析的配电台区拓扑结构辨识方法[J]. *电力系统及其自动化学报*, 2023, 35(9): 95-102.
- YIN Peng, LIANG Haishen, GU Zhicheng, et al. Identification method for topology in distribution station area based on Euclidean morphological distance and AP clustering analysis[J]. *Proceedings of the CSU-EPSCA*, 2023, 35(9): 95-102.
- [20] 裴宇婷, 秦超, 余贻鑫. 基于 LightGBM 和 DNN 的智能配电网在线拓扑辨识[J]. *天津大学学报(自然科学与工程技术版)*, 2020, 53(9): 939-950.
- PEI Yuting, QIN Chao, YU Yixin. Online topology identification for smart distribution grids based on LightGBM and deep neural networks[J]. *Journal of Tianjin University (Science and Technology)*, 2020, 53(9): 939-950.
- [21] GOTTI D, AMARIS H, LARREA P L. A deep neural network approach for online topology identification in state estimation[J]. *IEEE Transactions on Power Systems*,

- 2021, 36(6): 5824-5833.
- [22] 孙伟, 朱世睿, 杨建平, 等. 基于图卷积网络的微电网拓扑辨识[J]. 电力系统自动化, 2022, 46(5): 71-81.
SUN Wei, ZHU Shirui, YANG Jianping, et al. Topology identification of microgrid based on graph convolutional network[J]. Automation of Electric Power Systems, 2022, 46(5): 71-81.
- [23] 杨华, 李喜旺, 司志坚, 等. 基于图神经网络的配电网故障预测[J]. 计算机系统应用, 2020, 29(9): 131-135.
YANG Hua, LI Xiwang, SI Zhijian, et al. Accident prediction of power distribution network based on graph neural network[J]. Computer Systems & Applications, 2020, 29(9): 131-135.
- [24] 凌佳凯, 章逸舟, 胡金峰, 等. 基于 CNN-LSTM-Attention 的配电网拓扑实时辨识方法[J]. 浙江电力, 2024, 43(3): 84-94.
LING Jiakai, ZHANG Yizhou, HU Jinfeng, et al. A real-time topology identification method of distribution networks based on CNN-LSTM-Attention[J]. Zhejiang Electric Power, 2024, 43(3): 84-94.
- [25] 王冠淇, 裴玮, 李洪涛, 等. 基于 FPGA 的两阶段配电网拓扑实时辨识算法[J]. 电力系统自动化, 2024, 48(12): 100-108.
WANG Guanqi, PEI Wei, LI Hongtao, et al. Real-time two-stage topology identification algorithm for distribution network based on field programmable gate array[J]. Automation of Electric Power Systems, 2024, 48(12): 100-108.
- [26] 潘毓笙, 秦超. 基于两阶段特征选择和格拉姆角场的配电网拓扑辨识方法[J]. 电力系统自动化, 2022, 46(16): 170-177.
PAN Yusheng, QIN Chao. Identification method for distribution network topology based on two-stage feature selection and Gramian angular field[J]. Automation of Electric Power Systems, 2022, 46(16): 170-177.
- [27] 蒋玮, 汤海波, 祁晖, 等. 基于集成深度神经网络的配电网联络关系辨识技术[J]. 电力系统自动化, 2020, 44(1): 101-108.
JIANG Wei, TANG Haibo, QI Hui, et al. Distribution network connectivity recognition based on ensemble deep neural network[J]. Automation of Electric Power Systems, 2020, 44(1): 101-108.
- [28] 祖国强, 宋晨辉, 张春晖, 等. 蜂巢状综合能源配电系统的组网结构与运行方式[J]. 电力系统自动化, 2023, 47(12): 47-55.
ZU Guoqiang, SONG Chenhui, ZHANG Chunhui, et al. Networking structures and operation modes of honeycomb integrated energy distribution system[J]. Automation of Electric Power Systems, 2023, 47(12): 47-55.
- [29] 王文超, 庞丹, 成龙, 等. 考虑电价型需求响应的交直流混合配电网优化调度[J]. 电网技术, 2019, 43(5): 1675-1682.
WANG Wenchao, PANG Dan, CHENG Long, et al. Optimal dispatch approach for hybrid AC/DC distribution networks considering price-based demand response[J]. Power System Technology, 2019, 43(5): 1675-1682.
- [30] 蒋玮, 余斌, 郁家麟, 等. 蜂巢状有源配电网中多端口能量枢纽控制策略[J]. 电力工程技术, 2023, 42(5): 70-79.
JIANG Wei, YU Bin, YU Jialin, et al. Control strategy of multi-port energy hub in honeycomb active distribution network[J]. Electric Power Engineering Technology, 2023, 42(5): 70-79.
- [31] 王云飞, 姜世公, 时光远, 等. 适应高可靠供电需求的城市中压配电网网架构建研究[J]. 供用电, 2020, 37(6): 33-39.
WANG Yunfei, JIANG Shigong, SHI Guangyuan, et al. Research on the construction of city area medium voltage distribution network adapted to the demand of high reliable power supply[J]. Distribution & Utilization, 2020, 37(6): 33-39.
- [32] 郭少飞, 李铁成, 段剑, 等. 适用于花瓣形配电网的联络线后备保护方案[J]. 电网与清洁能源, 2022, 38(4): 10-18.
GUO Shaofei, LI Tiecheng, DUAN Jian, et al. Backup protection for tie lines in a petal distribution network[J]. Power System and Clean Energy, 2022, 38(4): 10-18.
- [33] 钱建春, 蔡斌, 任明珠, 等. 上海 10 kV 配电网发展历程及现状分析[J]. 电力与能源, 2021, 42(2): 265-268.
QIAN Jianchun, CAI Bin, REN Mingzhu, et al. Development history and present situation of Shanghai 10 kV distribution network[J]. Power & Energy, 2021, 42(2): 265-268.
- [34] 王果, 郭文凯, 王长春. 配电网拓扑辨识研究综述及展望[J]. 吉林大学学报(工学版), 2023, 53(2): 312-327.
WANG Guo, GUO Wenkai, WANG Changchun. Overview and prospect of distribution network topology identification[J]. Journal of Jilin University (Engineering and Technology Edition), 2023, 53(2): 312-327.
- [35] BARAN M E, WU F F. Network reconfiguration in distribution systems for loss reduction and load balancing[J]. IEEE Transactions on Power Delivery, 1989, 4(2): 1401-1407.

收稿日期: 2024-06-16; 修回日期: 2024-08-11

作者简介:

李博通(1981—), 男, 博士, 副教授, 研究方向为电力系统保护与控制; E-mail: libotong@tju.edu.cn

孙铭阳(1997—), 男, 通信作者, 硕士, 研究方向为中压配电网拓扑辨识; E-mail: sunmingyang@tju.edu.cn

张靖(1999—), 女, 博士研究生, 研究方向为中压有源配电网保护. E-mail: zhangjing99@tju.edu.cn

(编辑 许威)