

DOI: 10.19783/j.cnki.pspc.240088

基于随机森林和最大互信息系数关键特征选择的 配电网拓扑辨识研究

沈赋¹, 张微¹, 徐潇源², 王健¹, 付玉¹, 杨光兵¹, 翟苏巍³

(1. 昆明理工大学电力工程学院, 云南 昆明 650500; 2. 上海交通大学电子信息与电气工程系, 上海 200240;
3. 云南电网有限责任公司电力科学研究院, 云南 昆明 650217)

摘要: 随着高比例分布式能源(distributed generation, DG)的接入, 配电网的拓扑变化更加频繁。针对含 DG 的配电网拓扑辨识所需量测特征多、辨识准确率低的问题, 提出基于随机森林(random forest, RF)算法和最大互信息系数(maximal information coefficient, MIC)关键特征选择的配电网拓扑辨识方法。首先, 考虑风光出力的不确定性和相关性, 基于 Frank-Copula 函数得到典型风光出力场景, 与配电网不同拓扑相结合构建数据集。然后, 根据 RF 和 MIC 进行特征选择, 筛选出对拓扑辨识最重要且不含冗余信息的关键特征。最后, 利用蝙蝠算法(bat algorithm, BA)优化 BP(back propagation, BP)神经网络模型对配电网拓扑模型进行辨识。通过 IEEE 33 节点配电网和 PG&E 69 节点配电网进行仿真分析, 验证所提模型的可行性。

关键词: 配电网; 拓扑辨识; 不确定性; 相关性; 特征选择

Topological identification of distribution networks based on key feature selection using RF and MIC

SHEN Fu¹, ZHANG Wei¹, XU Xiaoyuan², WANG Jian¹, FU Yu¹, YANG Guangbing¹, ZHAI Suwei³

(1. Faculty of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650500, China;
2. Department of Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China;
3. Electric Power Research Institute, Yunnan Power Grid Co., Ltd., Kunming 650217, China)

Abstract: As the integration of a high proportion distributed generation (DG) into the power grid increases, topological changes in the distribution network become more frequent. A method for the topological identification in the distribution network based on the random forest (RF) and the maximal information coefficient (MIC) for key feature selection is proposed to address the issues of high measurement feature requirements and low identification accuracy in that identification for such networks containing DG. First, considering the uncertainty and correlation of wind and solar power output, typical scenarios of wind and solar power output are obtained based on the Frank-Copula function, and combined with different distribution network topologies to construct a dataset. Then, feature selection is performed using RF and MIC to identify the most important and key non-redundant features for topological identification. Finally, the bat algorithm (BA) is employed to optimize a back propagation (BP) neural network model for identification. Simulation analyses are conducted on the IEEE33 and the PG&E69-bus distribution networks to validate the feasibility of the proposed model.

This work is supported by the National Natural Science Foundation of China (No. 52107097).

Key words: distribution network; topology identification; uncertainty; correlation; feature selection

0 引言

由于风电、光伏大规模并网, 系统不确定性不

断增强, 配电网的安全稳定运行面临严峻挑战^[1-4]。为了应对各种新能源接入的不确定性, 需要对配电网进行实时的拓扑重构, 以保证配电网的安全稳定运行^[5-6]。配电网的拓扑辨识工作可以为后续潮流计算、状态估计、容量分配、故障定位等工作提供结构信息^[7-8]。因此, 设计具有高精度、高效率的含 DG 配电网的拓扑辨识方法可以更好地对配电网进行管理^[9-10]。

基金项目: 国家自然科学基金项目资助(52107097); 云南省应用基础研究计划项目资助(202101BE070001-061, 202201AU070111); 昆明理工大学高层次人才平台建设项目资助(KKZ7202004004)

在配电网拓扑辨识方面,文献[11]利用一种电网拓扑生成对抗网络模型,用于识别网络或径向结构的配电网拓扑;文献[12]提出一种基于自适应 k 近邻异常检验和自适应密度峰值聚类的低压台区拓扑识别方法;文献[13]提出了一种基于有功/无功功率注入和电压幅值数据来估计开环配电网导纳矩阵的方法;文献[14]提出了一种基于高级量测体系潮流匹配的辐射状中压配电网两阶段拓扑辨识方法;文献[15-16]利用混合整数线性优化模型对系统进行拓扑辨识。此外,部分学者利用量测装置对配电网的拓扑进行辨识。文献[17]提出了一种利用安装在配电网不同位置的智能电表和微相位测量单元获得的测量值来识别配电网拓扑;文献[18]提出一种可以利用同步相量量测装置(phasor measurement unit, PMU)提取出的信息实时估计系统动态矩阵,从而对网络拓扑变化进行辨识。但在实际运行中,由于运行成本的约束,难以在所有节点安装量测仪器,因此,文献[19]提出了一种在没有电压相角信息的情况下识别拓扑和估计线路参数的方法。上述方法在拓扑辨识过程中需要知道电网元件连接关系和开关状态信息,或者需要进行状态估计、复杂的潮流计算,在电网实际运行过程中,状态频繁变化的开关占少数,且开关存在拒动、误动的情况,状态估计与潮流计算将耗费大量的时间,影响电网拓扑识别效率。

基于上述问题,以机器学习为代表的人工智能算法被广泛运用到配电网拓扑辨识中,文献[20]将电网拓扑辨识归结为寻求盒子与小球全局最优组合问题,利用免疫智能算法对模型进行求解;文献[21]提出了一种基于深度神经网络的配电变压器联络关系辨识方案,通过特征提取、模型优化和集成学习等策略,提高了集成深度神经网络在配变联络关系辨识中的精确度;文献[22]提出一种基于初步拓扑辨识和潮流匹配的双层配电网拓扑辨识模型;文献[23]利用注意力机制和卷积神经网络进行拓扑辨识;文献[24]通过贝叶斯网络拟合配电网拓扑、光伏、负荷及测量电压的非线性关系,提高拓扑识别的泛化能力;文献[25]提出一种基于梯度惩罚优化条件生成对抗网络的配电网拓扑辨识方法;文献[26]提出了一种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。

上述使用人工智能算法进行配电网拓扑辨识的研究中,所需的量测数据量很大,大部分文献在采集 DG 节点的数据时假设 DG 出力服从概率分布^[27],只考虑了风光的不确定性,未考虑其相关性,可能造成计算误差,对配电网的管理将产生一定影响^[28];

另外,由于成本等因素的限制,现代量测设备虽然能够减小数据量测误差但并未在实际配电网中广泛应用,只在关键节点安装量测装置,然而上述研究为保证方法的有效性与适应性,一般需要所有节点的量测信息,不符合配电网量测装置有限的情况。

鉴于此,本文在构建配电网拓扑模型时考虑风光不确定性和相关性,基于随机森林(random forest, RF)算法和最大互信息系数(maximal information coefficient, MIC)进行特征选择。首先,根据华东地区某新能源场站的实际数据利用 Frank-Copula 函数生成风光出力场景,与配电网不同拓扑相结合构建量测数据集。其次,通过 RF 给量测特征进行重要度排序并根据 MIC 删除含冗余的特征,筛选出拓扑辨识的关键特征。再次,利用 BA 优化 BP 神经网络模型对配电网拓扑模型进行辨识。最后,通过 IEEE 33、PG&E 69 节点配电网对所提模型进行验证。

1 基于机器学习的配电网拓扑辨识

1.1 总体架构

目前,基于机器学习的配电网拓扑辨识可分为离线训练和在线应用两个阶段。离线训练阶段将采集到的数据作为训练集输入,拓扑标签作为输出,利用数据处理、特征选择等方法来降低数据集的维度,根据所用的机器学习算法进行模型训练;在线应用阶段将实时采集的断面量测数据输入到训练好的学习模型中,对当前时间断面下的运行拓扑进行辨识。其中,本文构建的配电网拓扑辨识总体框架如图 1 所示。

1.2 训练数据集构建

对于一个含 m 个节点的配电网,电力系统潮流方程如式(1)所示。

$$\begin{cases} P_i - U_i \sum_{j \in i} U_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) = 0 \\ Q_i - U_i \sum_{j \in i} U_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) = 0 \end{cases} \quad (1)$$

式中: P_i 、 Q_i 分别为节点 i 的有功注入功率和无功注入功率; U_i 、 U_j 分别为节点 i 、 j 的电压幅值; θ_{ij} 为节点 i 、 j 之间的电压相角差; G_{ij} 、 B_{ij} 分别为导纳矩阵的实部和虚部。

当拓扑情况已知时,只需确定其中任意两组变量,就可以求解出其他变量的值,从而对配电网的运行状态作出判断^[23]。

在传统配电网中,实时量测装置有限,量测类型相对单一,主要包括少量的节点电压幅值、支路功率和电流幅值实时量测,以及大量的节点注入功率伪量测等。此外,由潮流方程可知,节点电压幅值

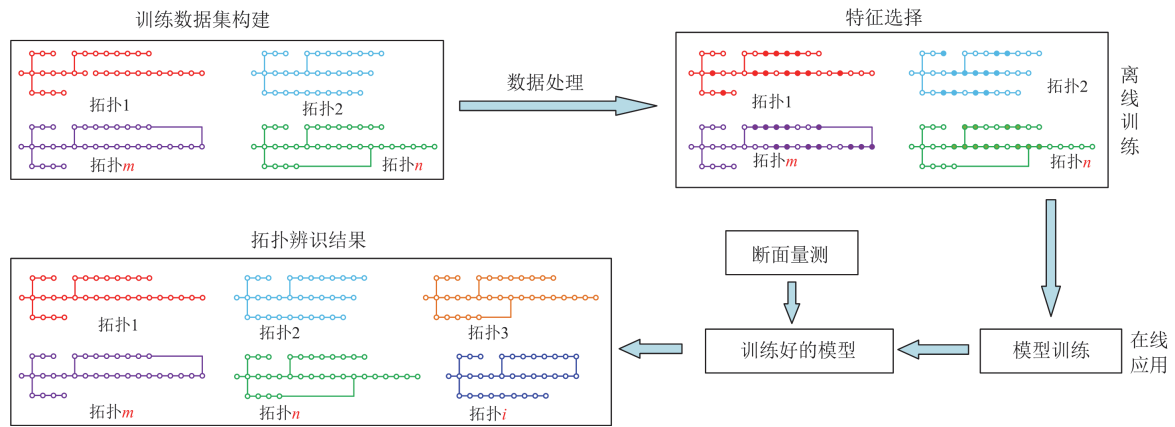


图 1 配电网拓扑辨识总体框架

Fig. 1 General framework for distribution network topology identification

是由节点功率和网络的接线方式共同决定的, 对于不同的网络拓扑, 节点间的电压会呈现不同的分布特性。综上, 考虑到节点电压幅值的分布蕴含着丰富的网络拓扑信息且较容易获取, 本文选择节点电压幅值作为输入数据来进行拓扑辨识, 输出数据为拓扑标签, 构建输入数据集 X 如式(2)所示。

$$X = \{V_1, V_2, \dots, V_m\} \quad (2)$$

式中, V_m 为节点 m 的电压幅值。

对得到的训练数据集进行数据预处理, 采用 min-max 标准化方法对节点电压幅值 V 进行归一化处理, 对于缺失数据, 采用文献[29]所提的基于最小方差的缺失值填补方法对数据进行预处理。

2 考虑不确定性和相关性的风光场景生成

当大量风光资源接入配电网时, 配电网的不确定性将增强。同时, 风光之间的相关性会造成相互依赖的 DG 节点的电压、频率等参数发生变化, 影响配电网的安全运行。

因此, 在辨识配电网拓扑结构的过程中, 不仅需要考虑风光的不确定性, 还须计及风光出力的相关性, 对风光出力的波动进行充分描述, 以获取更加准确、稳定的网络拓扑结构信息。

2.1 Copula 函数理论和选择

Copula 函数又称连接函数, 它通过连接变量的边缘分布和联合分布来考察变量之间的相关性。主要包括椭圆分布族 Copula 函数(Gaussian-Copula、t-Copula)和阿基米德分布族 Copula 函数(Frank-Copula、Clayton-Copula、Gumbel-Copula)。不同类型的 Copula 函数具有不同的性质及适用场景, 选择合适的模型更能准确地描述风光出力的相关性及其变化规律^[27]。

为了选择能更准确地描述风光相关性的 Copula

函数, 本文选择文献[27]所用的秩相关系数和欧式距离等指标来进行 Copula 函数的选择。

本文选取华东地区某新能源场站 2022 年 8 月份的实际风光出力作为仿真数据。首先根据历史数据计算风光出力的 Empirical-Copula 函数, 其次计算 5 种常用 Copula 函数 (Gaussian-Copula、t-Copula、Frank-Copula、Clayton-Copula、Gumbel-Copula) 的秩相关系数以及它们与 Empirical-Copula 函数之间的欧式距离, 具体如表 1 所示。

表 1 秩相关系数和欧氏距离

Table 1 Rank correlation coefficient and Euclidean distance

Copula 函数	秩相关系数		欧氏距离
	Kendall	Spearman	
Gaussian-Copula	-0.0209	-0.0313	0.7467
t-Copula	-0.1210	-0.1687	0.5630
Frank-Copula	-0.0976	-0.1460	0.5585
Clayton-Copula	7.2543×10^{-7}	1.0922×10^{-6}	0.8461
Gumbel-Copula	0.0500	0.0750	1.1237
Empirical-Copula	-0.0965	-0.1465	—

由表 1 可以看出, Empirical-Copula 函数和 Frank-Copula 函数的 Spearman 秩相关系数和 Kendall 秩相关系数最为接近, 其余 Copula 模型的秩相关系数与 Empirical-Copula 对比相差较远。并且 Frank-Copula 与 Empirical-Copula 的欧式距离最小。

当所选 Copula 函数与 Empirical-Copula 函数的秩相关系数越接近, 且两者欧氏距离越小时, 越能准确描述风光出力的相关性及其变化规律, 所以本文选择 Frank-Copula 函数刻画风光出力的相关性。

2.2 基于非参数核密度估计法和 Frank-Copula 函数的风光场景生成

本文考虑风光出力不确定性和相关性, 利用非

参数核密度估计法和 Frank-Copula 函数得到典型风光出力场景, 具体步骤如下所述^[30]。

步骤 1: 采集 n 天风光出力的实际数据, 基于非参数核密度估计法生成每个时段的风、光出力概率密度函数 $\hat{f}_h^t(x^t)$ 、 $\hat{f}_h^t(y^t)$ 如式(3)所示。

$$\begin{cases} \hat{f}_h^t(x^t) = \frac{1}{nh} \sum_{d=1}^n K\left(\frac{x^t - X_d^t}{h}\right) \\ \hat{f}_h^t(y^t) = \frac{1}{nh} \sum_{d=1}^n K\left(\frac{y^t - Y_d^t}{h}\right) \end{cases} \quad (3)$$

式中: x^t 、 y^t 分别为 t 时刻风机与光伏出力, $t = 1, 2, \dots, 24$; X_d^t 、 Y_d^t 分别为第 d 天 t 时刻风机与光伏出力; h 为带宽; $K(\cdot)$ 为高斯核函数, 即

$$K\left(\frac{x^t - X_d^t}{h}\right) = \left(\frac{1}{\sqrt{2\pi}}\right) \exp\left[-\frac{(x^t - X_d^t)^2}{2h^2}\right] \quad (4)$$

步骤 2: 根据概率密度函数求出其累积分布函数 $\hat{F}_{x^t}(x^t)$ 和 $\hat{F}_{y^t}(y^t)$, 基于 Frank-Copula 函数建立每个时段的风光出力联合分布函数 $\hat{F}(x^t, y^t)$ 为

$$\hat{F}(x^t, y^t) = C(\hat{F}_{x^t}(x^t), \hat{F}_{y^t}(y^t)) \quad (5)$$

式中, $C(\cdot)$ 为二维 Frank-Copula 函数, 即

$$C(u^t, v^t) = -\frac{1}{\lambda^t} \ln \left[1 + \frac{(e^{-\lambda^t u^t} - 1)(e^{-\lambda^t v^t} - 1)}{e^{-\lambda^t} - 1} \right] \quad (6)$$

式中: $u^t = \hat{F}_{x^t}(x^t)$; $v^t = \hat{F}_{y^t}(y^t)$; λ^t 为相关系数, $\lambda^t \in (-1, 1)$ 且 $\lambda^t \neq 0$ 。

步骤 3: 根据每个时段的联合概率分布函数, 进行采样得到 N 组随机采样结果, 利用采样结果和风光联合概率分布函数反变换, 得到每个时段的风机和光伏出力, 将得到的每个时段的风机和光伏出力组合起来, 生成一天的曲线, 即典型日曲线。

步骤 4: 由于采样数 N 较大, 为了简化分析和计算, 采用 K-means 聚类对 1000 个考虑到风光不确定性和相关性的风光场景采样结果进行筛减。

首先, 随机选择典型日曲线作为初始的聚类中心, 计算每个典型日曲线与每个聚类中心的距离, 并将其分配给距离最近的聚类中心所在的群组;

其次, 对于每个群组, 计算其与所有典型日曲线的平均值, 并将其平均值作为新的聚类中心, 重复上述步骤, 直到聚类中心不再发生变化;

最后, 当 K-means 算法收敛得到一组聚类中心, 表征数据集中的不同群组, 筛减得到 6 个典型风光出力场景。

3 基于 BA-BP 的配电网拓扑辨识

将典型风光场景出力数据注入配电网中, 与配电网的不同拓扑相结合构建量测数据集, 进一步选择特征, 筛选出拓扑辨识的关键特征, 然后利用 BA-BP 算法对配电网进行拓扑辨识。

3.1 特征选择

对于配电网量测数据的优化配置, 特征选择是一个重要的步骤, 其主要目的是从大量的数据中筛选出有意义的、不含冗余的特征信息, 优化配电网的量测配置方案^[26]。

本文首先基于所有节点的电压幅值构造初始特征变量, 但在实际应用中, 配电网量测装置有限, 为了应对实际情况下量测数据缺乏的问题, 根据 RF 和 MIC 进行关键节点特征选择。

考虑到 RF 在特征选择方面具有降低过拟合风险、可处理高维数据集、可应用于多类别分类问题、综合考虑多个因素(如特征在决策树中的分裂程度、特征的分裂位置和特征对预测结果的贡献等)等优势, 本文选择 RF 进行特征选择。在随机森林中, 每颗决策树都使用袋外数据(out of bag, OOB)来计算其袋外数据误差, 通过向 OOB 中全部样本的特征 X 中加入噪音, 使其在 X 处的数值发生变化, 从而计算出袋外数据误差。假设随机森林中有 K 棵决策树, 那么特征 X 的重要性, 可用式(7)表示^[31]。

$$X_{\text{importance}} = \frac{1}{K} \sum_{i=1}^K |e_{\text{trOOB}2} - e_{\text{trOOB}1}| \quad (7)$$

式中: $e_{\text{trOOB}1}$ 表示袋外数据误差; $e_{\text{trOOB}2}$ 表示加入噪声干扰后的袋外数据误差。

根据特征重要性筛选出的量测特征可能会包含部分冗余信息, 所以本文引入 MIC 对节点电压幅值量测特征进行相关性分析, 筛选出对拓扑辨识重要且不含冗余的关键特征。

MIC 用来衡量两个变量之间的关联程度(线性或非线性关系), 相较于互信息(mutual information, MI)有更高的准确度。MIC 计算如式(8)所示。

$$m_{\text{ic}}(x, y) = \max_{ab < B} \frac{I(x, y)}{\log_2 \min(a, b)} \quad (8)$$

式中: x 、 y 为两个随机变量; a 、 b 分别为 x 、 y 方向上划分的网格数, 且 $ab < B$, B 为网格数的上限; $I(x, y)$ 为互信息值, 即

$$I(x, y) = \int p(x, y) \log_2 \frac{p(x, y)}{p(x)p(y)} dx dy \quad (9)$$

式中: $p(x)$ 、 $p(y)$ 分别为 x 、 y 的边缘分布概率;

$p(x, y)$ 为 x 、 y 的联合分布概率。

通过 RF 和 MIC 进行特征选择后, 选取关键节点的节点电压幅值作为具体特征变量来辨识网络的拓扑结构。

3.2 BA-BP 的配电网拓扑辨识流程

BP 神经网络作为一种经典的前馈神经网络, 以其出色的非线性映射能力和强大的泛化性能著称, 但是仍存在学习速度慢、容易陷入局部极小值等缺陷, 为克服此问题, 本文引入 BA 对 BP 神经网络模型进行优化。

BA 具有全局搜索和局部搜索两个阶段, 其中全局搜索能够使 BP 从较差的初始状态快速收敛到局部最优解附近, 加速优化过程。另外, BA 的搜索机制能够克服 BP 对于初始权值和阈值敏感、易受噪声干扰等问题, 提高 BP 的鲁棒性和泛化能力。

BA 的主要参数如下^[32]所述。

1) 蝙蝠的脉冲频率更新公式

$$f_i = f_{\max} + (f_{\max} - f_{\min})\beta \quad (10)$$

式中: f_i 为第 i 只蝙蝠探寻目标时的脉冲频率; f_{\max} 、 f_{\min} 分别为蝙蝠发出的脉冲频率的最大、最小值; β 为 $[0,1]$ 内均匀分布的随机数。

2) 蝙蝠的飞行速度更新公式

$$v_i^t = v_i^{t-1} + (x_i^{t-1} - x^*)f_i \quad (11)$$

式中: v_i^t 、 v_i^{t-1} 分别为第 i 只蝙蝠在 t 时刻和 $t-1$ 时刻的飞行速度; x_i^{t-1} 为蝙蝠 i 在 $t-1$ 时刻的位置; x^* 为全局最优值下蝙蝠所处的位置。

3) 蝙蝠的位置更新公式

$$x_i^t = x_i^{t-1} + v_i^t \quad (12)$$

4) 蝙蝠局部搜索过程中对当前最优解施加随机扰动后的局部解, 如式(13)所示。

$$x_{\text{new}} = x_{\text{old}} + \eta A_i \quad (13)$$

式中: x_{new} 为对选取的最优解施加一个随机扰动之后得到的局部解; x_{old} 为当前最优解; η 为 $[-1,1]$ 内的随机数; A_i 为所有蝙蝠在 t 时刻的平均脉冲音量。

5) 蝙蝠搜寻猎物时的脉冲音量 A_i 和脉冲频率 r_i 的更新如式(14)和式(15)所示。

$$A_i^{t+1} = \alpha A_i^t \quad (14)$$

$$r_i^{t+1} = r_i^0 (1 - e^{-\lambda t}) \quad (15)$$

式中: A_i^t 为 t 时刻蝙蝠 i 的脉冲音量; α 为响度衰减系数, $\alpha \in [0,1]$; r_i^0 为初始脉冲频率; λ 为频率增加系数, 取值大于 0。

使用 BA 优化 BP 神经网络的权值和阈值参数,

BA 优化的适应度值函数 $F(i)$ 为

$$F(i) = \frac{1}{M} \sum_{i=1}^M \sum_{j=1}^M (y_{i,j}^p - y_{i,j})^2 \quad (16)$$

式中: M 表示样本个数; $y_{i,j}^p$ 、 $y_{i,j}$ 分别表示第 i 个样本对应输出点的预测值和实际值。

基于 BA-BP 的配电网拓扑辨识模型的步骤如下。

步骤 1: 将样本分为训练集和测试集, 并进行数据处理以及特征选择;

步骤 2: 对 BA 进行初始化设置, 包括种群数量、最大迭代次数等参数;

步骤 3: 采用 BA 进行寻优, 输出全局的最优解, 作为 BP 的权值和阈值;

步骤 4: 使用优化得到的权值和阈值对所建立的 BP 进行训练, 得到训练好的学习模型;

步骤 5: 将采集到的实时断面量测数据输入到训练好的模型中, 对断面拓扑进行辨识。

基于 BA-BP 的配电网拓扑辨识流程如图 2 所示。

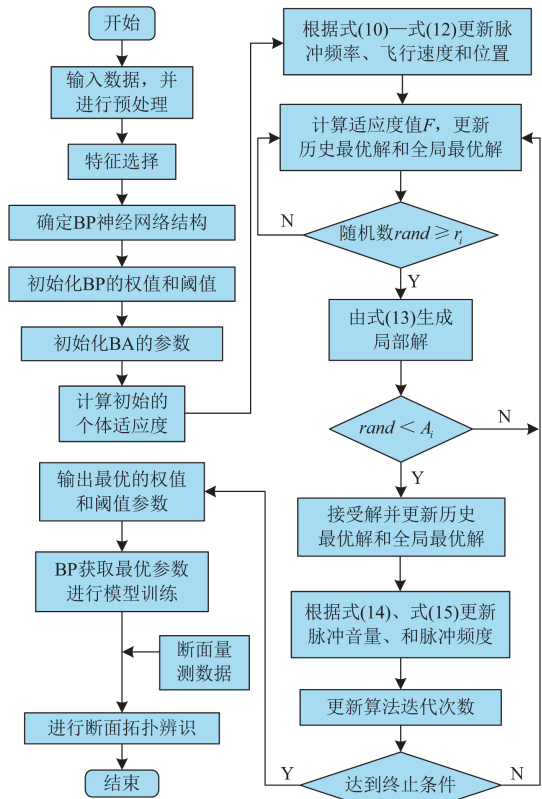


图 2 基于 BA-BP 的配电网拓扑辨识流程图

Fig. 2 Flowchart of BA-BP based distribution network topology identification

3.3 模型评价指标

为评估本文所用算法的准确性和有效性, 采用分类问题中常用的准确率 A_{cc} 、查准率 P_{re} 和召回率

R_{cc} 来进行模型评估, 具体如式(17)~式(19)所示。

$$A_{cc} = \frac{T}{n} \quad (17)$$

$$P_{re} = \frac{T_p}{T_p + F_p} \quad (18)$$

$$R_{cc} = \frac{T_p}{T_p + F_N} \quad (19)$$

式中: T 为全部正确分类的样本量; T_p 表示分类为正的样本; F_p 表示分类为正的负样本; F_N 表示分类为负的正样本。

准确率是正确分类的样本数与总样本数的比例, 为了防止样本不均衡的问题, 同时引入查准率和召回率对模型进行评价。查准率是分类正确的正样本个数占分类器判定为正样本的个数的比例, 衡量了学习模型的精度。召回率是分类正确的正样本个数占真正的正样本个数的比例, 衡量了学习模型的灵敏度。同时使用 3 个指标对模型进行评价更能反映模型性能。

4 算例分析

为验证所提模型的有效性和准确性, 分别在改造的 IEEE 33 节点和 PG&E 69 节点配电网系统上进行仿真测试, 两系统的初始拓扑如附录 A 图 A1、图 A2 所示。IEEE 33 节点配电网主要包括 32 条支路和 5 条联络线, 选择 4 个节点接入光伏发电站和风力发电站, 具体容量和位置参考文献[33], 系统额定电压为 12.66 kV; PG&E 69 节点配电网主要包括 68 条支路和 5 条联络线, 系统额定电压为 12.66 kV, 选择 5 个节点接入风、光电站, 具体容量和位置参考文献[34]。

4.1 风光出力场景生成

根据 2.1 节所用华东地区某新能源场站地区的真实数据, 考虑风光不确定性和相关性, 聚类筛减出风电和光伏的 6 种典型日场景如图 3 所示。

图 3 生成的典型风光出力场景, 考虑到了风光的不确定性和相关性, 将典型风光场景出力数据以及负荷数据按照接入位置注入到配电网中。改变联络线的开关状态生成 28 种典型拓扑, 设置拓扑标签为 1—28, 其中 1—21 为辐射状配电网, 22—28 为环状配电网, 见附录 A 表 A1 和表 A2。进一步由 Matpower 软件进行潮流计算获得每种拓扑下的节点电压幅值数据, 共 28×24 组量测数据, 作为拓扑辨识模型的输入数据。每组样本的初始特征共 33 维, 即节点电压幅值 $V_1 - V_{33}$ (PG&E 69 节点系统为 69 维, 即节点电压幅值 $V'_1 - V'_{69}$), 模型输出为拓扑标签, 随机选取 80% 的样本作为训练集, 20% 的样

本作为测试集。




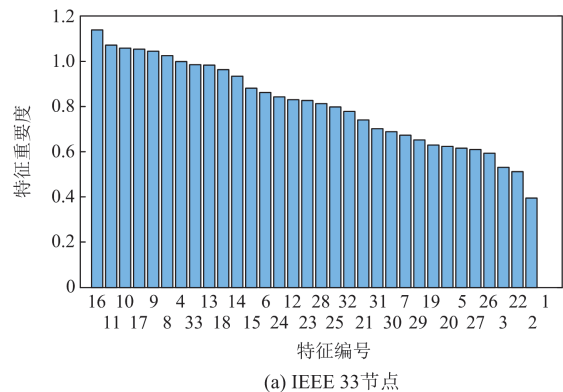
图 3 场景聚类筛减后风光出力

Fig. 3 Photovoltaic and wind output after scene clustering and screening

4.2 特征选择

利用 RF 对两种配电网中的原始特征进行重要度排序, 排序结果如图 4 所示。

由于图 4 排序结果中存在一定的冗余特征, 所以利用 MIC 对所有电压量测特征进行相关性分析, 相关性热力图如附录 A 图 A3、图 A4 所示。在所有电压量测特征中, 很多节点之间都存在强相关性: IEEE 33 节点配电网中 V_{14} 和 V_{15} (0.923)、 V_{15} 和 V_{16} (0.9407)、 V_{32} 和 V_{33} (0.93) 等; PG&E 69 节点配



(a) IEEE 33 节点

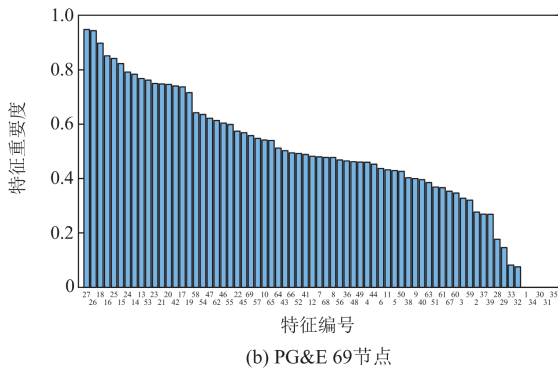


图 4 特征重要度排序

Fig. 4 Importance ranking of features

电网中 V'_2 和 V'_3 (0.999 173)、 V'_8 和 V'_{40} (0.993 389)、 V'_{57} 和 V'_{12} (1)、 V'_{40} 和 V'_{41} (1)、 V'_{55} 和 V'_{56} (1)、 V'_{57} 和 V'_{58} (1) 等。

依次减少特征数量并测试其准确率来检验特征数量与准确率的关系, 在 IEEE 33 节点和 PG&E 69 节点配电网中, 当量测特征数量分别达到 13 和 24 时拓扑辨识的准确率已经趋于稳定并且保持在 0.98 以上, 因此选用 13 和 24 作为两种规模配电网中的量测特征数量来进行拓扑辨识。

根据 RF 重要度排序结果筛选出 IEEE 33 节点配电网中重要度前 13 的特征为 $\{V_{16}, V_{11}, V_{10}, V_{17}, V_9, V_8, V_4, V_{33}, V_{13}, V_{18}, V_{14}, V_{15}, V_6\}$, 而根据 RF 和 MIC 筛选出的不含冗余特征的量测组合为 $\{V_{16}, V_{11}, V_9, V_8, V_4, V_{33}, V_{13}, V_6, V_{24}, V_{12}, V_{23}, V_{28}, V_{25}\}$ 。PG&E 69 节点配电网中重要度前 24 的特征为 $\{V'_{27}, V'_{26}, V'_{18}, V'_{16}, V'_{25}, V'_{15}, V'_{24}, V'_{14}, V'_{13}, V'_{53}, V'_{23}, V'_{21}, V'_{20}, V'_{42}, V'_{17}, V'_{19}, V'_{58}, V'_{54}, V'_{47}, V'_{62}, V'_{46}, V'_{55}, V'_{22}, V'_{45}\}$, 根据 RF 和 MIC 筛选出的不含冗余特征的量测组合为 $\{V'_{27}, V'_{26}, V'_{18}, V'_{16}, V'_{25}, V'_{15}, V'_{24}, V'_{14}, V'_{13}, V'_{53}, V'_{23}, V'_{21}, V'_{20}, V'_{42}, V'_{19}, V'_{58}, V'_{54}, V'_{47}, V'_{62}, V'_{46}, V'_{55}, V'_{45}, V'_{69}, V'_{10}\}$, 输入特征对准确率的影响如表 2 所示。

表 2 输入特征对准确率的影响

Table 2 Impact of input features on accuracy

配电网	输入特征	准确率	查准率	召回率
IEEE 33 节点	全部特征(33)	1.000 00	1.000 00	1.000 00
	重要度前 13 的特征	0.988 37	0.989 57	0.989 57
	删除冗余后的特征	0.994 19	0.992 86	0.996 04
PG&E 69 节点	全部特征(69)	1.000 00	1.000 00	1.000 00
	重要度前 24 的特征	0.985 19	0.964 29	0.952 39
	删除冗余后的特征	0.992 59	0.992 85	0.994 03

由表 2 可以看出, 无论在 IEEE 33 节点配电网还是 PG&E 69 节点配电网, 选用关键特征进行拓扑辨识的评估指标均高于选用重要度特征进行拓扑辨识的评估指标, 并且采用关键节点进行拓扑辨识的指

标值仅比采用全部特征进行拓扑辨识的指标值下降了 0.004~0.007, 但所用特征仅是原始特征的 40%, 降低了数据维度, 且符合配电网中量测装置有限的情况。

4.3 学习算法性能比较

为了验证本文所用方法的优越性, 分别用 BA-BP、GA-BP、PSO-BP 3 种算法进行拓扑辨识, 3 种算法的测试集准确率、查准率和召回率如表 3 所示。

表 3 学习算法性能比较

Table 3 Comparison of learning algorithm performance

配电网	智能算法	准确率	查准率	召回率
IEEE 33 节点	BA-BP	0.994 19	0.992 86	0.996 04
	GA-BP	0.977 79	0.971 93	0.978 57
	PSO-BP	0.970 37	0.980 21	0.980 21
PG&E 69 节点	BA-BP	0.992 59	0.992 85	0.994 03
	GA-BP	0.962 96	0.982 14	0.982 14
	PSO-BP	0.955 57	0.964 29	0.946 43

由表 3 可知, 3 种智能算法在两个系统中的测试集准确率都达到了 0.9 以上, 有着较好的分类效果。BA-BP 算法的准确率在两种配电网中都是最高的, 查准率和召回率也比 GA-BP 算法和 PSO-BP 算法高, 证明 BA-BP 能够准确地辨识当前拓扑, 具有较高的精度和灵敏度, 与 GA-BP、PSO-BP 相比具有一定的优越性。与 IEEE 33 节点配电网相比, 在 PG&E 69 节点配电网中 GA-BP 和 PSO-BP 的测试集准确率、查准率和召回率都有明显的下降, 而 BA-BP 的测试集准确率仅下降了 0.0016, 查准率下降 0.000 01, 召回率下降 0.002 01, 说明本文所用模型在 PG&E 69 节点配电网中仍然具有较好的拓扑辨识效果, 并未因节点数量的增多而导致拓扑识别效果明显下降, 具有良好的适用性。

为进一步验证所提算法的性能, 计算该模型的归一化混淆矩阵, 其热力图结果如图 5 所示。其中第 i 行第 j 列表示: 真实拓扑类别是 i 、预测拓扑类别为 j 的概率。

由图 5 可以看出, 两个节点配电网中的对角线上的元素几乎全为 1, 非对角线上的元素基本均为 0, 验证了本文方法在不同规模配电网中仍然具有较好的分类性能。

4.4 抗噪能力分析

由于训练数据来源于仿真, 数据质量较好, 考虑到实际应用情况, 在原始量测数据中加入随机噪声模拟配电网真实量测数据, 噪声水平分别为 0.01%、0.05%和 0.1%, 在不同规模配电网中各算法的测试集准确率如表 4 所示。





图 5 混淆矩阵热力图

Fig. 5 Confusion matrix thermodynamic diagram

表 4 考虑量测噪声的测试集准确率

Table 4 Accuracy of test set considering measurement noise

配电网	智能算法	噪声水平/%		
		0.01	0.05	0.1
IEEE 33 节点	BA-BP	0.983 11	0.936 13	0.887 46
	GA-BP	0.948 15	0.903 70	0.837 04
	PSO-BP	0.933 33	0.844 44	0.814 82
PG&E 69 节点	BA-BP	0.987 09	0.900 43	0.859 26
	GA-BP	0.925 93	0.807 41	0.792 59
	PSO-BP	0.911 11	0.800 00	0.762 96

由表 4 可知，随着噪声水平的增大，在两种规模配电网中，所有算法的准确率均有所下降。但是 GA-BP 和 PSO-BP 在 IEEE 33 节点配电网中，在噪声水平为 0.01%、0.1% 下，准确率分别下降了 0.111 11 和 0.118 51，在 PG&E 69 节点配电网中分别下降了 0.133 34 和 0.148 15。相较于 GA-BP 和 PSO-BP 准

准确率迅速下降的情况，BA-BP 在 IEEE 33 节点配电网中仅下降了 0.095 65，在 PG&E 69 节点配电网中下降了 0.127 83，即使在噪声水平为 0.1% 的情况下仍能保持 0.859 26 的准确率，可见随着噪声水平的增大，BA-BP 算法在 IEEE 33 节点和 PG&E 69 节点配电网中都具有较好的适应性，证明本文所提方法具有较好的抗噪能力。

5 结论

本文考虑风光出力的不确定性和相关性，构建了计及风光不确定性和相关性的配电网拓扑模型，采用 RF 和 MIC 进行特征选择，并利用 BA-BP 对配电网拓扑模型进行辨识。通过 IEEE 33 节点配电网和 PG&E 69 节点配电网进行仿真分析，得出如下结论。

1) 根据输入特征与准确率之间的关系，利用关键性节点的量测数据即可实现拓扑辨识，降低了原始数据集的数据维度且符合实际配电网中量测装置有限的情况。

2) 基于 RF 计算量测数据的重要性，并通过 MIC 判定不同量测数据的相关性，可以筛选出对拓扑辨识重要且不含冗余的关键特征，能够给配电网配置量测装置提供参考。

3) 本文所构建的基于 BA-BP 的配电网拓扑辨识模型不仅适用于辐射状网络，同时也适用于环网。相较于 GA-BP 和 PSO-BP 算法，BA-BP 算法在不同规模的配电网中具有更高的准确率以及更好的抗噪能力。

附录 A




图 A1 IEEE 33 节点配电网初始拓扑

Fig. A1 Initial topology of IEEE 33-bus distribution network




图 A2 PG&E 69 节点配电网初始拓扑

Fig. A2 Initial topology of PG&E 69-bus distribution network




图 A3 IEEE 33 节点配电网量测特征相关性

Fig. A3 Measurement feature correlation of IEEE 33-bus distribution network

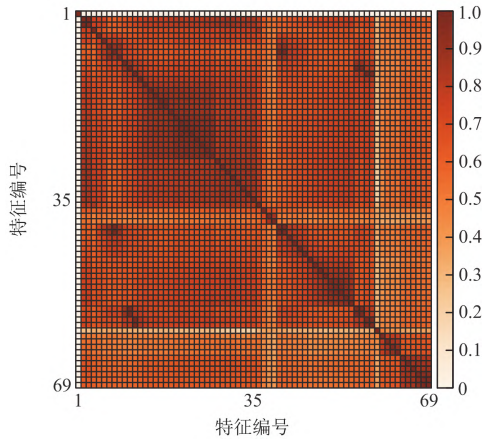


图 A4 PG&E 69 节点配电网量测特征相关性

Fig. A4 Measurement feature correlation of PG&E 69-bus distribution network

表 A1 IEEE 33 节点系统典型拓扑

Table A1 Typical topology of an IEEE 33-bus system

线路开断		拓扑 标签	线路开断		拓扑 标签
连接支路	断开支路		连接支路	断开支路	
—	—	1	12-22	8-9	15
18-33	32-33	2	8-21、12-22	7-8、11-12	16
12-22	11-12	3	12-22	3-4	17
14-15	9-15	4	25-29	3-4	18
8-21	7-8	5	25-29	5-6	19
25-29	28-29	6	12-22、18-33	5-6、29-30	20
18-33	17-18	7	25-29	—	21
25-29	24-25	8	12-22	—	22
12-22、18-33	10-11、12-13	9	8-21	—	23
12-22	2-19	10	18-33	—	24
8-21	4-5	11	9-15	—	25
9-15、12-22	9-10、14-15	12	8-21、12-22	20-21	26
18-33、25-29	3-23、31-32	13	9-15、18-33	13-14	27
25-29	6-26	14	12-22、18-33	11-12	28

表 A2 PG&E 69 节点系统典型拓扑

Table A2 Typical topology of a PG&E 69-bus system

线路开断		拓扑 标签	线路开断		拓扑 标签
连接支路	断开支路		连接支路	断开支路	
—	—	1	27-54	19-20	15
27-54	26-27	2	15-69、27-54	66-67、14-15	16
27-54	53-54	3	13-20	13-14	17
39-48	43-44	4	27-54	52-53	18
39-48	47-48	5	15-69	6-7	19
11-66	63-64	6	11-66、15-69	3-59、66-67	20
15-69	63-64	7	11-66	—	21
13-20	19-20	8	15-69	—	22
15-69	13-14	9	13-20	—	23
15-69、13-20	14-15、18-19	10	27-54	—	24
39-48	9-42	11	39-48	—	25
11-66、39-48	6-7、47-48	12	11-66、15-69	65-66	26
11-66、13-20	6-7、19-20	13	27-54、39-48	47-48	27
13-20、27-54	16-17、25-26	14	13-20、27-54	19-20	28

参考文献

[1] 郑国光. 支撑“双碳”目标实现的问题辨识与关键举措研究[J]. 中国电力, 2023, 56(11): 1-8.
ZHENG Guoguang. Problem identification and key measures to support the achievement of carbon peak and carbon neutrality[J]. Electric Power, 2023, 56(11): 1-8.

[2] 王一清, 沙倩, 刘秋林. 区域综合能源系统接入的配电网扩展规划研究[J]. 电力科学与技术学报, 2023, 38(6): 198-205.
WANG Yiqing, SHA Qian, LIU Qiulin. Research on distribution network expansion planning for regional integrated energy system access[J]. Journal of Electric Power Science and Technology, 2023, 38(6): 198-205.

[3] FANG X, YANG Q, YAN W. Power generation maximization of distributed photovoltaic systems using dynamic topology reconfiguration[J]. Protection and Control of Modern Power Systems, 2022, 7(3): 1-15.

[4] 韩平平, 陈思远, 张楠, 等. 考虑分布式光伏的低压台区线损异常辨识方法[J]. 电力系统保护与控制, 2023, 51(8): 140-148.
HAN Pingping, CHEN Siyuan, ZHANG Nan, et al. Line loss anomaly identification method for low-voltage station area considering distributed PV[J]. Power System Protection and Control, 2023, 51(8): 140-148.

[5] 戴雪婷, 李辉, 何柏娜, 等. 配电网拓扑分析与线路参数辨识研究[J]. 电力科学与技术学报, 2023, 38(4): 46-56.
DAI Xueting, LI Hui, HE Baina, et al. Research on topology analysis and line parameter identification of distribution network[J]. Journal of Electric Power Science and Technology, 2023, 38(4): 46-56.

[6] 吴龙腾, 徐春华, 邱泽坚, 等. 考虑双侧量测误差的配电网拓扑识别及参数联合估计方法[J]. 电力系统保护

- 与控制, 2023, 51(16): 149-157.
- WU Longteng, XU Chunhua, QIU Zejian, et al. Topology identification and joint parameter estimation of a distribution network considering bilateral measurement errors[J]. Power System Protection and Control, 2023, 51(16): 149-157.
- [7] 刘刚, 朱林, 祁升龙, 等. 基于拓扑结构变化的配电网自适应保护方法[J]. 电力科学与技术学报, 2022, 37(1): 106-112.
- LIU Gang, ZHU Lin, QI Shenglong, et al. Adaptive protection method for distribution networks based on the dynamic topology[J]. Journal of Electric Power Science and Technology, 2022, 37(1): 106-112.
- [8] 马光, 朱文, 顾慧杰, 等. 基于加权最小绝对值状态估计的有源配电网拓扑辨识方法[J]. 中国电力, 2024, 57(1): 167-174.
- MA Guang, ZHU Wen, GU Huijie, et al. Topology identification method for active distribution network based on weighted minimum absolute value state estimation[J]. Electric Power, 2024, 57(1): 167-174.
- [9] 刘晟源, 章天晗, 林振智, 等. 数据赋能低压配用电系统精益化运行的关键技术与算法[J]. 电力系统自动化, 2023, 47(3): 187-199.
- LIU Shengyuan, ZHANG Tianhan, LIN Zhenzhi, et al. Key technologies and algorithms of data empowerment for lean operation of low-voltage power distribution and consumption system[J]. Automation of Electric Power Systems, 2023, 47(3): 187-199.
- [10] 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.
- [11] WU H, XU Z, ZHAO J, et al. Gridtopo-GAN for distribution system topology identification[J]. IEEE Transactions on Industrial Informatics, 2023, 19(4): 5356-5366.
- [12] 史子轶, 夏向阳, 刘佳斌, 等. 基于AKNN异常检验与ADPC聚类的低压台区拓扑识别方法[J]. 中国电力, 2024, 57(5): 168-177.
- SHI Ziyi, XIA Xiangyang, LIU Jiabin, et al. Low-voltage substation area topology recognition method based on aknn anomaly detection and ADPC clustering[J]. Electric Power, 2024, 57(5): 168-177.
- [13] ZHANG J, WANG P, ZHANG N. Distribution network admittance matrix estimation with linear regression[J]. IEEE Transactions on Power Systems, 2021, 36(5): 4896-4899.
- [14] 刘超, 杨扬, 梁栋, 等. 基于AMI潮流匹配的中压配电网两阶段拓扑辨识[J]. 电力系统及其自动化学报, 2020, 32(3): 123-128.
- LIU Chao, YANG Yang, LIANG Dong, et al. Two-stage topology identification of medium-voltage distribution network based on power flow matching of AMI measurements[J]. Proceedings of the CSU-EPSA, 2020, 32(3): 123-128.
- [15] TIAN Z, WU W, ZHANG B. A mixed integer quadratic programming model for topology identification in distribution network[J]. IEEE Transactions on Power Systems, 2016, 31(1): 823-824.
- [16] 萧展辉, 邹文景, 唐良运. 基于多周期性MILP模型的新型配电系统拓扑辨识方法[J]. 电测与仪表, 2023, 60(2): 117-125.
- XIAO Zhanhui, ZOU Wenjing, TANG Liangyun. Topology identification method of novel distribution system based on multi-period MILP model[J]. Electric Measurement & Instrumentation, 2023, 60(2): 117-125.
- [17] SRINIVAS V L, WU J. Topology and parameter identification of distribution network using smart meter and μ PMU measurements[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-14.
- [18] WANG X, BIALEK J W, TURITSYN K. PMU-based estimation of dynamic state Jacobian matrix and dynamic system state matrix in ambient conditions[J]. IEEE Transactions on Power Systems, 2018, 33(1): 681-690.
- [19] 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.
- [20] 董宸, 吴强, 黄河, 等. 基于免疫算法的电网拓扑结构识别[J]. 发电技术, 2023, 44(1): 125-135.
- DONG Chen, WU Qiang, HUANG He, et al. Power grid topology identification based on immune algorithm[J]. Power Generation Technology, 2023, 44(1): 125-135.
- [21] 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.
- [22] 陈碧云, 吕怡博, 梁志坚, 等. 考虑数据失衡的新型配电网两阶段拓扑辨识[J]. 电力系统保护与控制, 2023, 51(21): 57-65.
- CHEN Biyun, LÜ Yibo, LIANG Zhijian, et al. Two-stage

- topology identification of a new-type distribution network considering data imbalance[J]. Power System Protection and Control, 2023, 51(21): 57-65.
- [23] 杨秀, 蒋家富, 刘方, 等. 基于注意力机制和卷积神经网络的配电网拓扑辨识[J]. 电网技术, 2022, 46(5): 1672-1682.
YANG Xiu, JIANG Jiafu, LIU Fang, et al. Distribution network topology identification based on attention mechanism and convolution neural network[J]. Power System Technology, 2022, 46(5): 1672-1682.
- [24] 任鹏哲, 刘友波, 刘挺坚, 等. 基于互信息贝叶斯网络的配电网拓扑鲁棒辨识算法[J]. 电力系统自动化, 2021, 45(9): 55-62.
REN Pengzhe, LIU Youbo, LIU Tingjian, et al. Robust identification algorithm for distribution network topology based on mutual-information Bayesian network[J]. Automation of Electric Power Systems, 2021, 45(9): 55-62.
- [25] 邵晨颖, 刘友波, 邵安海, 等. 基于生成对抗网络与局部电流相量的配电网拓扑鲁棒辨识[J]. 电力系统自动化, 2023, 47(1): 55-62.
SHAO Chenying, LIU Youbo, SHAO Anhai, et al. Robust identification for distribution network topology based on generative adversarial network and partial current phasor[J]. Automation of Electric Power Systems, 2023, 47(1): 55-62.
- [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] 林顺富, 刘持涛, 李东东, 等. 考虑电能交互的冷热电区域多微网系统双层多场景协同优化配置[J]. 中国电机工程学报, 2020, 40(5): 1409-1421.
LIN Shunfu, LIU Chitao, LI Dongdong, et al. Bi-level multiple scenarios collaborative optimization configuration of CCHP regional multi-microgrid system considering power interaction among microgrids[J]. Proceedings of the CSEE, 2020, 40(5): 1409-1421.
- [28] 王俊, 蔡兴国, 季峰. 基于 Copula 理论的相关随机变量模拟方法[J]. 中国电机工程学报, 2013, 33(22): 75-82, 13.
WANG Jun, CAI Xingguo, JI Feng. A simulation method of correlated random variables based on Copula[J]. Proceedings of the CSEE, 2013, 33(22): 75-82, 13.
- [29] 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.
- [30] 白凯峰, 顾洁, 彭虹桥, 等. 融合风光出力场景生成的多能互补微网系统优化配置[J]. 电力系统自动化, 2018, 42(15): 133-141.
BAI Kaifeng, GU Jie, PENG Hongqiao, et al. Optimal allocation for multi-energy complementary microgrid based on scenario generation of wind power and photovoltaic output[J]. Automation of Electric Power Systems, 2018, 42(15): 133-141.
- [31] 杨晓梅, 郭林明, 肖先勇, 等. 基于可调品质因子小波变换和随机森林特征选择算法的电能质量复合扰动分类[J]. 电网技术, 2020, 44(8): 3014-3020.
YANG Xiaomei, GUO Linming, XIAO Xianyong, et al. Classification of multiple power quality disturbances based on TQWT and random forest feature selection algorithm[J]. Power System Technology, 2020, 44(8): 3014-3020.
- [32] 陈欢, 彭辉, 舒乃秋, 等. 基于蝙蝠算法优化最小二乘双支持向量机的变压器故障诊断[J]. 高电压技术, 2018, 44(11): 3664-3671.
CHEN Huan, PENG Hui, SHU Naiqiu, et al. Fault diagnosis of transformer based on LS-TSVM optimized by bat algorithm[J]. High Voltage Engineering, 2018, 44(11): 3664-3671.
- [33] DOROSTKAR-GHAMSARI M R, FOTUHI-FIRUZABAD M, LEHTONEN M, et al. Value of distribution network reconfiguration in presence of renewable energy resources[J]. IEEE Transactions on Power Systems, 2016, 31(3): 1879-1888.
- [34] 徐俊俊, 吴在军, 周力, 等. 考虑分布式电源不确定性的配电网鲁棒动态重构[J]. 中国电机工程学报, 2018, 38(16): 4715-4725, 4976.
XU Junjun, WU Zaijun, ZHOU Li, et al. Robust dynamic reconfiguration for distribution networks considering uncertainty of distributed generations[J]. Proceedings of the CSEE, 2018, 38(16): 4715-4725, 4976.

收稿日期: 2024-01-19; 修回日期: 2024-05-21

作者简介:

沈 赋(1988—), 男, 博士, 副教授, 研究方向为新型电力系统建模; E-mail: shenfu@kust.edu.cn

张 微(1999—), 女, 硕士研究生, 研究方向为新型电力系统建模; E-mail: zhangwei990507@163.com

王 健(1994—), 男, 通信作者, 博士, 讲师, 研究方向为综合能源系统建模及可靠性评估。E-mail: jianwangzx@163.com

(编辑 张 颖)