

基于分布-集中两阶段协同的有源配电网智能故障 区段定位方法

满超洪¹, 孙铁鹏², 李海锋¹, 梁华敏¹

(1. 华南理工大学电力学院, 广州 510640; 2. 广西电网有限责任公司贵港供电局, 广西 贵港 537100)

摘要: 针对有源配电网故障定位中传统集中式方法所需通信量大, 以及现有人工智能方法在分布式部署时面临模型复杂、资源受限等挑战, 提出了一种分布式部署-集中式诊断的两阶段协同智能故障区段定位方法。该方法首先利用变分模态分解对各分布测量单元采集的电流信号提取高维局部故障特征, 并通过轻量化多层感知机模型在终端完成初步诊断, 仅将低维度的故障区段概率向量上传。随后, 在集中式融合端以这些概率向量为元特征, 借助 K -Fold 交叉验证生成元学习数据, 构建基于 Stacking 的协同神经网络对多源信息进行端到端优化融合, 输出最终故障区段判别结果。仿真实验表明, 所提方法能够有效整合分布式观测信息, 在多种故障工况下均能实现高精度的故障区段定位, 其性能显著优于单个本地模型及简单融合策略, 为配电网故障的快速精准定位提供了新的有效途径。

关键词: 配电网; 故障区段定位; 分布式观测; 变模态分解; 特征融合; 堆叠泛化

Intelligent Fault Section Location Method of Active Distribution Network Based on Distribution-Centralized Two-Stage Cooperation

MAN Chaohong¹, SUN Tiepeng², LI Haifeng¹, LIANG Huamin¹

(1. School of Electric Power Engineering, South China University of Technology, Guangzhou 510640, China; 2. Guigang Power Supply Bureau of Guangxi Power Grid Co., Ltd., Guigang, Guangxi 537100, China)

Abstract: In view of the large communication volume required by traditional centralized methods in active distribution network fault section location, as well as the challenges faced by existing artificial intelligence methods such as complex models and resource constraints when deployed in a distributed manner, a two-stage collaborative intelligent fault section location method of distributed deployment and centralized diagnosis is proposed. This method first uses variational mode decomposition to extract high-dimensional local fault features from the current signals collected by each distributed measurement unit, and then completes the preliminary diagnosis at the terminal through a lightweight multi-layer perceptron model, only uploading the low-dimensional fault section probability vector. Subsequently, at the centralized fusion end, taking these probability vectors as meta-features, meta-learning data is generated with the aid of K -Fold cross-validation, and a collaborative neural network based on Stacking is constructed to optimize and fuse multi-source information end-to-end, in order to output the final fault section discrimination result. The simulation experiments show that the proposed method can effectively integrate distributed observation information and achieve high-precision fault section location under various fault conditions. Its performance is significantly better than that of a single local model and a simple fusion strategy, providing a new and effective way for the rapid and accurate location of distribution network faults.

Key words: distribution network; fault section location; distributed sensing; variational mode decomposition; feature fusion; stacking

基金项目: 智能电网国家科技重大专项资助项目(2024ZD0802200); 中国南方电网有限责任公司科技项目(GXKJXM20222230)。

Foundation item: Supported by the Smart Grid National Science and Technology Major Project under Grant (2024ZD0802200); the Science and Technology Project of China Southern Power Grid Co., Ltd. (GXKJXM20222230).

0 引言

准确、快速地定位配电网的故障区段, 对于提高配电网供电可靠性及自愈能力具有重要意义^[1]。随着分布式和可再生能源的大规模接入, 配电网的结构由单一电源辐射状网络转变为多端网络, 故障特征随之发生显著变化^[2-3], 给现有的故障定段方法带来挑战。

目前, 配电网故障区段定位方法主要包括基于阻抗的方法^[4-5]、行波法^[6-7]和基于矩阵算法的方法^[8-9]。其中, 基于阻抗的方法利用电压和电流相量计算等效阻抗进行定位, 但在分布式电源(distributed generation, DG)渗透率高时可能产生较大误差。行波法则利用故障产生的初始行波进行定位, 但在配电网拓扑复杂、线路分支多的情况下, 安装高频率采样设备成本高且容易受故障初相角的影响。基于矩阵算法的方法利用故障指示器进行, 分布式新能源介入后系统电流分布特征会发生变化, 传统矩阵算法难以自适应, 造成定位精度下降。

随着人工智能技术的发展, 基于数据驱动的故障诊断方法受到了广泛的关注。早期的研究侧重于利用单一模型提取全局数据的特征进行故障诊断, 如利用图注意力网络(graph attention network, GAT)^[10]、卷积神经网络(convolutional neural networks, CNN)^[11]、支持向量机(support vector machines, SVM)^[12]、利用长短期记忆神经网络(long short term memory, LSTM)^[13]等。尽管上述方法在特征提取和复杂模式识别方面展示了较强潜力, 但未能充分考虑分布式电源的接入后所引起的电压与电流幅值、相位等特性的变化^[14]。随着配电网中DG渗透率的不断提高, 其在故障期间造成的故障特征变异将越来越显著, 进而大大增加了故障定位的难度^[15]。

近年来学者开始将更丰富的时空信息与多源观测点数据结合, 以提升故障诊断的全面性与鲁棒性^[16]。文献[17]通过距离可分性判据提取故障特征, 利用SVM实现有源配电网故障类型判别及故障定位。文献[18]采用Alexnet模型通过标准遥信与广域测量系统数据进行故障诊断。文献[19]利用图神经网络(graph neural networks, GNN)将同步波形测量数据映射为时空图结构数据, 并结合电网物

理结构信息成功应用于高比例分布式电源接入的配电网中。然而, 目前的研究仍存在不少挑战。首先, 单个观测点获取的信息存在局限性, 难以全面反映整个网络的故障状态, 从而影响诊断准确性。其次, 尽管大型深度学习模型能够在全局信息充分时表现优异, 但在算力有限的边缘设备上部署这些模型仍面临技术和成本挑战。最后, 如何有效整合多个分布式观测点的局部信息, 尤其是如何处理信息的不确定性和冲突是提高系统整体性能的关键^[20-21]。

针对这些问题, 本文提出了一种基于分布式深度特征学习与协同神经网络融合的两阶段智能故障定位方法。第一阶段, 在各分布式观测点独立执行轻量级本地智能感知与初步诊断: 利用变分模态分解(variational mode decomposition, VMD)对各分布测量单元采集的电流信号提取高维局部故障特征, 并通过轻量化多层感知机(multilayer perceptron, MLP)模型在终端完成初步诊断, 仅将低维度的故障区段概率向量上传。第二阶段, 在集中式融合端以这些概率向量为元特征, 借助K-Fold交叉验证生成元学习数据, 构建基于Stacking的协同神经网络对多源信息进行端到端优化融合, 以输出最终故障区段判别结果。最后, 通过算例验证了本文所提分阶段方法在解决分布式电源接入背景下故障定位问题上具有良好的性能。

1 基于VMD算法的特征矩阵

VMD作为一种新的信号分解方法, 通过优化一个变分问题来分解信号, 将频率蕴含度高的信号分解成多个中心频率不同的单分量调幅调频信号, 从而避免了模态混叠问题, 并提供了更加清晰、稳定的模态成分^[22-23]。

VMD分解的性能高度依赖于预设参数 K 。不同的 K 值将导致分解出的模态分量及其波形产生差异。为了量化VMD分解的效果, 本文采用以下两个指标进行评估。

1) 重构误差 e , 用于衡量重构信号与原始信号的偏差程度, 定义为:

$$e = \frac{\|x(t) - \hat{x}(t)\|_2^2}{\|x(t)\|_2^2} \quad (1)$$

式中: $x(t)$ 为原始信号; $\hat{x}(t) = \sum_{i=1}^K u_i(t)$ 为 K 个模态分量重构信号。重构误差越小, 说明分解质量越高。

2) 能量集中度 E , 能够反映分解过程中的能量保持程度, E 接近 1 表示能量损失最小和分解完整性最佳, 定义为:

$$E = \frac{\|\hat{x}(t)\|_2^2}{\|x(t)\|_2^2} \quad (2)$$

在具体的 K 值选择上, 本文基于大量实际配电网故障数据比较了 K 取 2~9 时的分解效果, 图 1 展示了某次故障下故障相电流 VMD 分解 K 值优化分析结果, 在 K 取 2~4 时能量集中度高, 因此优先选择 2~4 中的 K 值, 且当 $K=4$ 时重构误差最小。因此, 本文选取 $K=4$ 为最优参数。




图 1 不同 K 值下 VMD 分解的效果评价图

Fig. 1 Evaluation graphs of the effect of VMD decomposition under different K values

在进行 VMD 分解得到 K 个模态分量后, 本文通过提取每个模态的特征构建故障特征矩阵, 具体步骤如下。

1) 利用 VMD 分解得到各观测点三相电流的 K 个固有模态分量。

2) 计算每个模态分量的时域和频域特征, 以从多维度反映故障所引起的信号变化, 包括:

(1) 均值 A_k 。该特征反映故障发生时某些频率成分的直流偏置或整体偏移水平。

$$A_k = \frac{1}{N} \sum_{t=1}^N u_k(t) \quad (3)$$

式中: N 为采样点数量; $u_k(t)$ 为经过 VMD 分解后得到的第 k 个模态分类。

(2) 标准差 σ_k 。故障会引起电流幅值变化, 而标准差可以衡量信号的波动幅度。

$$\sigma_k = \sqrt{\frac{1}{N-1} \sum_{t=1}^N (u_k(t) - A_k)^2} \quad (4)$$

(3) 峰度 K_k 。故障电流中通常包含冲击性的暂态分量, 峰度可以描述信号波形分布的尖锐程度。

$$K_k = \frac{1}{N} \sum_{t=1}^N \left(\frac{u_k(t) - A_k}{\sigma_k} \right)^4 \quad (5)$$

(4) 偏度 S_k 。故障的发生可能导致电流波形出现不对称畸变, 偏度能够反映波形的不对称程度。

$$S_k = \frac{1}{N} \sum_{t=1}^N \left(\frac{u_k(t) - A_k}{\sigma_k} \right)^3 \quad (6)$$

(5) 能量 E_k 。故障发生时不同频率的能量分布会发生显著变化, 能量反映模态分量的总功率。

$$E_k = \sum_{t=1}^N u_k(t)^2 \quad (7)$$

(6) 频谱熵 H_k 。故障发生时会引起新的频率分量, 使得频谱变得复杂, 而频谱熵用于衡量信号在频域内能量分布的复杂性。给定一个模态分量, 其频谱可通过傅里叶变换获得。

$$U_k(f) = \mathcal{F}(u_k(t)) \quad (8)$$

式中: $U_k(f)$ 为第 k 个模态分量的频域; $\mathcal{F}$ 为傅里叶变换; f 为频率。

计算归一化功率谱密度。

$$P_k(f) = \frac{|U_k(f)|^2}{\sum_f |U_k(f)|^2} \quad (9)$$

式中 $P_k(f)$ 为第 k 个模态分类的归一化功率谱密度。

最后得出频谱熵 H_k 。

$$H_k = -\sum_f P_k(f) \log P_k(f) \quad (10)$$

3) 基于 K 个模态分量的各特征计算结果可得到

总模态特征向量 $\mathbf{Z}$ 。

$$\mathbf{Z} = \begin{bmatrix} A_1 \sigma_1 K_1 S_1 E_1 H_1 \\ A_2 \sigma_2 K_2 S_2 E_2 H_2 \\ \vdots \\ A_k \sigma_k K_k S_k E_k H_k \end{bmatrix} \quad (11)$$

4) 将三相电流数据 I_A 、 I_B 、 I_C 分别进行上述处理, 即可得到三相的模态特征矩阵为:

$$\mathbf{Z}_i = \begin{bmatrix} \mathbf{Z}_{Ai} \\ \mathbf{Z}_{Bi} \\ \mathbf{Z}_{Ci} \end{bmatrix} \quad (12)$$

式中: $\mathbf{Z}_{Ai}$ 、 $\mathbf{Z}_{Bi}$ 、 $\mathbf{Z}_{Ci}$ 分别为观测点 i 的 A 相、B 相、C 相模态特征向量; $\mathbf{Z}_i$ 为观测点 i 的全模态特征矩阵。

利用 VMD 分解构建模态特征矩阵流程步骤如图 2 所示。




图 2 基于 VMD 分解的模态特征矩阵生成

Fig. 2 Model of feature matrix generation based on VMD decomposition

2 基于分布式特征学习的就地诊断模型

为了有效应对有源配电网中分布式能源接入带来的故障特征复杂化问题, 并充分利用部署在网络中多个观测点的实时量测数据, 本文提出的智能故障区段定位框架首先执行一个基于分布式特征学习的就地诊断流程。此阶段的核心目标是为每一个观测点构建一个独立的、轻量级的就地诊断模型, 使其能够基于该观测点采集到的局部故障特征, 对故障可能发生的区段进行快速且具有一定准确性的初步判断。这些初步诊断结果随后将作为下一阶段故障协同融合输入。

2.1 就地诊断模型

考虑到边缘计算资源限制以及对实时性的要

求, 本文选择 MLP 作为各观测点的诊断模型。MLP 作为一种前馈人工神经网络, 具有结构相对简单、易于实现、能够逼近任意连续函数以及对向量化特征数据处理能力强等优点^[24], 非常适合用于构建分布式节点的轻量级智能诊断模型。

为使每个本地 MLP 诊断模型能够充分学习其对应观测点的局部故障模式, 本文采用分布式独立训练的策略。针对每一个观测点都构建其专属的本地数据集, 汇集了该观测点在所有故障区段及工况下的特征向量与真实标签。通过将数据划分为训练所需的部分, 此划分与后续整个框架的测试集定义保持一致。同时, 每个观测点分别创建并初始化一个本地 MLP 模型及其对应的优化器, 使得每个模型拥有独立的参数和训练流程。

2.2 就地诊断流程

经过独立训练后每个观测点的本地 MLP 诊断模型即具备了基于其局部特征进行故障区段判断的能力。当新的故障发生时, 对于一个新的故障实例, 每个观测点会提取其相应的特征向量作为输入, 由此得到故障概率输出向量 $\mathbf{P}_m$ 。

$$\mathbf{P}_m = [\mathbf{P}_{m1}, \mathbf{P}_{m2}, \dots, \mathbf{P}_{mi}, \dots, \mathbf{P}_{mn}] \quad (13)$$

式中 $\mathbf{P}_m$ 为一个 n 维的概率向量, 其中每一个元素 $\mathbf{P}_{mi}$ 表示基于观测点 m 的局部信息及其学习到的故障模式, 用于判断当前故障发生在区段 i 的概率大小。这个概率向量 $\mathbf{P}_m$ 即是观测点 m 对当前故障区段所给出的初步诊断结果。它不仅揭示了该观测点部署的诊断模型认为最可能的故障区段, 更重要的是, 它为所有可能的故障区段都赋予了一个量化的置信度评估。基于分布式特征学习的就地诊断框架流程如图 3 所示。




图 3 基于分布式特征学习的就地诊断框架

Fig. 3 Local diagnosis framework based on distributed feature learning

3 基于 Stacking 的协同融合与诊断决策

单一观测点获取的特征可能因其位置、故障类型及具体工况而带有局限性难以全面覆盖故障的全貌, 特别是当观测点 i 距离故障位置较远时其输出

的预测概率可能不可靠。传统的简单融合方法，如对各分布式诊断模型输出的概率进行平均或固定加权求和，其融合能力有限，且固定的权重难以适应不同故障样本下各分布式诊断模型预测可靠性的动态变化。

为了克服这些局限性，本文借鉴了 Stacking 集成学习的思想，通过融合多观测点的预测结果来降低单点预测不确定性，构建了一个基于神经网络的协同融合模块。

3.1 元学习器与 K-Fold 交叉验证策略

Stacking 的核心在于引入一个元学习器，它不直接处理原始输入特征，而是将第一阶段多个本地诊断模型的输出作为新的输入特征，并学习如何基于这些特征来进行最终的预测^[25]。在本文中选择 MLP 作为元学习器，负责智能地整合来自所有分布式诊断模型的就地诊断信息。

元特征由所有就地诊断模型的初步诊断概率拼接而成，代表了各个局部模型对故障的判断^[26]。对于任一故障样本， m 个独立的本地诊断模型分别输出一个 n 维的概率向量，表示其在 n 个区段上的故障置信度分布，随后将这些概率向量顺序拼接，形成一个 $m \times n$ 维的元特征向量 X 。

$$X = [P_1, P_2, \dots, P_m]^T \quad (14)$$

式中 P_i 为观测点 i 的概率向量。向量 X 全面地概括了所有分布式观测点对当前故障的初步判断。

同时，为了防止元学习器在训练过程中对本身训练数据预测过于自信而导致的过拟合，Stacking 一般通过严格的 K -Fold 交叉验证进行训练^[27]。首先，将定义的训练数据池划分为 k 个互不相交的子折，然后，进行 k 轮迭代。在每一轮中将当前轮的 $k-1$ 个折作为临时训练集，用于重新训练所有的本地诊断模型。随后，使用这些在当前轮次临时训练好的本地诊断模型对剩余的第 k 个折进行预测，从而得到该验证集样本的概率输出，并将这些输出拼接为元特征。

经过 k 轮迭代后原始训练数据池中的每一个样本都有了一个对应的、由未在其上训练过的本地诊断模型生成的元特征。这些元特征及其真实标签共同构成了元学习器的训练数据集，在本文中 k 选择 5。

K -Fold 策略确保了元学习器是在本地诊断模型对其“未知”数据的预测基础上进行学习的，从而提高了其泛化能力。

3.2 元学习器的设计

元学习器的核心任务是学习一个从元特征空间到最终故障区段概率的映射函数。如图 4 所示，在本文用于融合的 MLP 模型是一个结构简洁而有效的前馈神经网络，其包括了输入层，采用 ReLU 激活函数的隐藏层，以及应用 Softmax 激活函数的输出层，确保输出为规范化的概率分布，表示系统对每个区段发生故障的最终置信度。




图 4 前馈神经网络结构示意图

Fig. 4 Schematic diagram of the feedforward neural network structure

3.3 最终故障区段决策

一旦元学习器训练完成，整个 Stacking 集成框架便具备了对新故障实例进行精确定位的能力。当一个新的故障发生时由所有的本地 MLP 本地诊断模型分别对各自观测到的局部特征进行处理，输出初步的诊断概率向量。这些概率向量被拼接形成该新故障实例的元特征向量，被输入到训练好的元学习器中。元学习器输出一个最终概率分布，系统选择该概率分布中具有最大概率值的区段作为最终的故障区段预测结果 P_{final} 。

$$P_{\text{final}} = \max [p_1, p_2, \dots, p_m] \quad (15)$$

式中 p_i 为元学习器输出的观测点 i 的故障概率。

通过上述基于 Stacking 的协同融合策略，本文提出的框架能够有效整合来自多个分布式数据源的信息，学习并自适应地调整各本地诊断模型预测的权重和组合方式，从而克服了传统简单融合方法的局限性。基于 Stacking 的协同融合学习框架如图 5 所示。

4 仿真与实验验证

在本文中，参考文献[28]模型中的线路参数，




图 5 基于stacking的协同融合学习框架

Fig. 5 Collaborative fusion learning framework based on stacking

基于PSCAD/EMTDC搭建了如图6所示的小电阻接地配电网仿真模型。其中,在各段线路首端都配置分布式量测装置,收集对应区段线路的三相电流,以及部署训练完成的模型。




图 6 10 kV 配网示意图

Fig. 6 Schematic diagram of 10 kV distribution network

以馈线L3上的故障为例,在考虑不同系统参数和故障条件下一共生成138 240个故障算例作为样本。其中,故障区段涵盖Section1至Section8这8个区段,每个故障区段都均匀地以10%的线路长度设置9个故障点;故障类型包含10种典型故障类型;故障初相角考虑了0°~150°共6种情况;故障过渡电阻考虑了从10 Ω~1 500 Ω共9种不同大小的情况。此外考虑了逆变型DG渗透率从0%变化到60%的情况,具体说明见表1。

图7为0%渗透率下区段1发生A相接地故障

表 1 不同 DG 渗透率情况说明

Tab. 1 Explanation of different DG permeabilities situations

DG 渗透率/%	情况说明
0	系统不接入DG;
20	单个DG容量为0.2 MVA,接入位置为C1、O4、O6、C2、C4末端;
40	单个DG容量为0.4 MVA,接入位置为C1、O4、O6、C2、C4末端;
60	单个DG容量为0.4 MVA,接入位置为C1、O4、O6、C2、C4末端;单个DG容量为0.2 MVA,接入位置为O7、O9、O12末端。

时,观测点1收集到的三相电流,包括了故障前后各一周。




图 7 故障前后三相电流图

Fig. 7 Three-phase current diagrams before and after the fault

4.1 基准测试

为了测试上面提到方法的有效性,本文将全部样本按80%、10%、10%划分为训练验证池和独立测试集。训练验证池内部采用5-Fold交叉验证生成元学习特征,本地诊断模型最终在90%的数据上训练完成。测试集中保持各类故障分布一致。

在不同DG渗透率情况下本文所提方法的准确性如表2所示,可见本文提出的基于分布式本地MLP和Stacking融合故障区段定位方法在所有考虑的DG渗透率条件下均表现出卓越的性能。

表 2 不同 DG 渗透率下 Stacking 方法正确率

Tab. 2 Accuracy rates of stacking methods under different DG permeabilities

DG 渗透率	Stacking MLP Fusion 方法准确率/%
0	98.12
20	97.72
40	98.41
60	97.92

在无 DG 接入(0 %渗透率)的理想情况下本文方法实现了高达 98.12 % 的整体测试集准确率,证明了方法框架的有效性。值得注意的是,随着 DG 渗透率从 0 % 增加到 60 %,本文方法的准确率仅从 98.12 % 微降至 97.92 %,整体降幅为 0.2 %。

这一结果充分表明,所提方法对于 DG 接入引发的电网故障特征变化具有出色的鲁棒性和适应能力。即使在 60 % 的高 DG 渗透率场景下本文方法依然能够维持在 97.9 % 以上的定位准确率。为进一步解释该模型在 DG 渗透率变化较大的情况下仍能保持较高的故障定位准确率,本文从机理上对所提方法进行了分析。

1)故障后最大的故障特征包括故障点电压跌落、系统等效阻抗、故障稳态电流的分布等。由于 DG 具有故障限流特性,即使在较大渗透率情况下其提供的故障电流仍远小于由电网所提的短路电流,因此不会改变故障的本质特征。

2)本文采用 VMD 分解提取了多个特征作为神经网络的输入,这些提取的故障特征不仅在一定程度上反映了更本质的故障特征,同时也能够在一定程度上削弱 DG 馈入电流大小变化带来的直接影响,使得不同渗透率下的数据分布更为一致。最后,是分布式观测下的优势:即便部分观测点受到 DG 扰动影响,其他节点依然能够捕捉到故障的典型特征。

3)本文所提模型采用覆盖各渗透率的全场景数据进行训练,使本地 MLP 聚焦于不随渗透率变化的核心故障特征,对 DG 变化不敏感,因而具备良好的跨场景泛化能力。

为了更细致地评估模型性能,表 3 展示了本文方法在不同 DG 渗透率下对各个故障区段的 F1 分数。从表 3 中可以看出,在所有 DG 渗透率条件下模型对大部分故障区段均能达到接近 1.0 的 F1 分数,表明其在精确率和召回率之间取得了良好的平

衡。由表 3 可知, DG 渗透率的增加对不同区段识别性能的影响存在差异。例如, Section6 在 DG 渗透率从 0% 增加到 60% 时 F1 分数略有波动,这与该区段在特定 DG 接入模式下故障特征的复杂化有关。然而,即使存在波动所有区段的 F1 分数仍保持在较高水平。总体而言, F1 分数的分析结果进一步证实了本文方法在不同 DG 场景下对各个故障区段均具有稳定且高效的识别能力。

图 8 呈现了本文方法在 0 % 和 60 % 的 DG 渗透率下的故障定段混淆矩阵。在这两种 DG 渗透率下混淆矩阵的对角线元素值远大于非对角线元素,表明绝大多数故障样本被正确定位。当 DG 未接入时主要的少量混淆集中在区段 1 以及相邻区段,例如区段 1 与区段 2 之间存在 9 例误判,这是由于电气距离相近而可能产生的判别模糊性。而当 DG 渗透率为 60 % 时在某些区段间的混淆略有增加,例如,区段 4 模型的误判结果明显增加,这是 DG 接入对特定区段间故障特征区分度的影响。然而,模型依然能够将绝大部分故障区段清晰区分开来。

4.2 对比实验结果与分析

为了全面验证本文提出方法的有效性和优越性,本文将其与现有方法进行了对比,所有对比均在 0 %、20 %、40 % 和 60 % 4 种 DG 渗透率下进行,结果如表 4 所示。

1)对比集中式 MLP

集中式模型能够将所有特征集中起来进行处理,在所有 DG 渗透率下也表现出非常高的准确率,均在 98 % 以上。本文提出的 Stacking 融合方法在各种 DG 渗透率情况下的准确率比集中式 MLP 更优。

尽管集中式 MLP 和本文所提方法相比准确率较为接近,但本文的分布式学习与 Stacking 融合框架在实际工程应用中能够降低对通信带宽的需求与减少数据传输,无需将所有数据上传到终端再进行诊断,仅需上传就地诊断模型的诊断结果向量,在

表 3 不同 DG 渗透率下 stacking 方法各区段 F1 分数表

Tab. 3 F1 score table of each section of the stacking method under different DG permeabilities

DG 渗透率/%	区段 1	区段 2	区段 3	区段 4	区段 5	区段 6	区段 7	区段 8
0	0.963 0	0.982 6	0.993 4	0.977 7	0.963 9	0.985 9	0.974 6	0.992 5
20	0.971 6	0.991 3	0.994 9	0.958 0	0.977 7	0.992 8	0.979 3	0.993 6
40	0.981 0	0.987 8	0.995 7	0.969 7	0.936 6	0.992 6	0.992 5	0.974 5
60	0.978 1	0.974 4	0.997 0	0.973 4	0.976 6	0.982 5	0.985 5	0.979 6




图8 Stacking融合方法的混淆矩阵

Fig. 8 Confusion matrix of the Stacking fusion method

表4 各方法在不同DG渗透率下的正确率

Tab. 4 Accuracy rates of various methods under different DG permeability rates %

DG 渗透率	集中式 MLP	文献[11]方法	文献[12]方法	本文方法
0	95.07	97.13	89.00	98.12
20	96.95	88.55	82.34	97.72
40	95.32	97.77	82.35	98.41
60	97.26	95.41	88.36	97.92

工程应用上更具优势。

2)对比其他集中式方法

本文方法还与文献[11-12]所提方法进行了比较,并且列出了它们在各种DG渗透率情况下的性能。由表4可知,在不同DG渗透率下本文所提方法的故障定段准确率更优。

4.3 消融实验

本文设计了对应的消融实验,通过与简单的融合策略和单一最佳观测点情况进行了比较,证明本文所提方法的有效性,结果如表5所示。与简单的平均概率融合和投票法融合相比,本文提出的Stacking融合方法同样展现出明显的性能优势。在各种DG渗透率下Stacking方法的准确率均高于这两种方法。这表明通过元学习器学习得到的自适应融合权重和非线性组合方式,能够比固定的、非学习的简单融合规则或者简单投票更有效地提取和利用来自各个本地模型的诊断信息,从而实现更精准的故障定位。同时,面对DG渗透率变化,简单的融合方法性能也存在一定的波动,而本文的Stack-

表5 消融实验结果

Tab. 5 Results of the ablation experiment %

DG 渗透率	单一最佳 MLP	平均法	投票法	本文方法
0	48.49	87.88	62.74	98.12
20	72.52	87.51	75.00	97.72
40	77.31	85.91	75.91	98.41
60	83.29	93.59	87.85	97.92

ing方法相对稳定。

本文提出的Stacking融合方法在所有DG渗透率下均显著优于单一最佳本地MLP模型。例如在60% DG渗透率下本文方法准确率高达97.92%,而单一最佳本地MLP在该渗透率情况下最佳观测点5的训练结果仅为84.49%。同时,从结果来看,不同DG渗透率情况下准确率最佳本地MLP不确定,比如在0%渗透率下准确率最高的观测点是观测点6,准确率只有51.05%,而在40%渗透率下最佳观测点又为观测点1。说明单一观测点的信息具有固有的局限性,难以全面捕捉复杂故障特征,而融合策略能够汇集多方优势,弥补个体不足。

4.4 噪声影响分析

在实际环境中,采集得到的数据往往含有噪声,会对信号处理带来一定的影响。为此,本文对原始信号加入了40 dB和30 dB的高斯白噪声来对模型效果进行评估。目前已有文献对噪声的处理大多是在训练模型过程中加入含噪声数据,以此达到模型对噪声的耐受目的。为此,本文对现有模型进行了微调处理,即在现有模型基础上用含噪声数据

再对模型进行调整。将模型与微调前结果进行了对比,为衡量模型效果,在这里提出性能保持率指标,其定义为:

$$\text{性能保持率} = \frac{\text{含噪声数据下准确率}}{\text{无噪声数据下准确率}} \times 100\% \quad (16)$$

在未对模型进行微调以前,直接使用含噪声数据进行测试,结果如表6所示。

表 6 未微调前含噪声的测试结果

Tab. 6 Test results with noises before fine-tuning

信噪比/dB	整体准确率/%	性能保持率/%
40	86.20	87.90
30	79.75	81.30

由表6结果可知,此时准确率略有下降,主要是由于模型未使用含噪声数据进行训练。对模型进行微调后,结果如表7所示。

表 7 微调后含噪声的测试结果

Tab. 7 Test results with noise after fine-tuning

信噪比/dB	整体准确率/%	性能保持率/%
40	96.97	98.9
30	92.12	94.0

微调后模型噪声鲁棒性显著提升,同时微调方法仅需在原模型基础上进行少量参数调整,通过让模型适应噪声特征分布有效提升了模型在噪声环境下的准确率。可见,本文所提模型对于噪声有一定的耐受能力,如果对模型进行微调处理则模型能够适应噪声能力且在常见噪声环境下依然具有很高的准确性。

4.5 模型迁移性分析

针对本文所训练模型迁移性问题补充了相应实验为了应对实际配电网中DG接入位置变化的问题,本文对基准模型进行了迁移训练。在20%的渗透率情况下调整了馈线3所接DG的容量和位置,单个DG容量为0.2 MVA,接入位置为的C1末端、O4末端、O7末端、C9末端、C4末端,生成了38 880个新的故障样本,具体接入位置补充在附录文件中。首先直接将原有模型用新故障样本作零迁移测试,得到的结果为78.11%,由此可知,在渗透率不变的情况下单单改变DG接入位置,原有模型具有一定直接泛化能力。

为了验证模型的迁移性,使用部分故障样本对

原有模型进行微调训练,使得其适应新工况下的故障特征,并重新进行测试,此时的准确率为98.01%,可见本文所训练模型具有可迁移性与一定的泛化能力。

5 结论

本文针对有源配电网故障故障区段定位,提出了一种基于分布式深度特征学习与Stacking集成神经网络智能故障区段定位新方法,通过算例验证与分析,可以得到以下结论。

1)在故障特征提取上,本文通过VMD分解提取构建故障特征矩阵,能够有效捕捉局部故障特征作为分布式模型输入;

2)在故障区域定段判别上,所提出的分布式部署-集中式诊断两阶段协同方法,能够较好地适应不同DG渗透率变化情况,实验结果表明该方法在各DG渗透率情况下均取得97.7%以上准确率;

3)与多种方法的对比结果表明,本文所提方法能够有效融合各观测点初步诊断结果进行诊断,在面对噪声干扰和模型迁移情况下均有良好表现,具有较好的泛化性。

参考文献

- [1] 王彩强,张青,李晨,等.含有限PMU的配电网故障区域在线辨识算法[J].南方电网技术,2024,18(12):42-50.
WANG Caiqiang, ZHANG Qing, LI Chen, et al. Fault section on-line identification algorithm with limited PMU for distribution network [J]. Southern Power System Technology, 2024, 18(12):42-50.
- [2] 詹惠瑜,刘科研,盛万兴,等.有源配电网故障诊断与定位方法综述及展望[J].高电压技术,2023,49(2):660-671.
ZHAN Huiyu, LIU Keyan, SHENG Wanxing, et al. Review and prospects of fault diagnosis and location method in active distribution network [J]. High Voltage Engineering, 2023, 49(2):660-671.
- [3] 吴璐子,缪希仁,庄胜斌,等.含分布式电源配电网故障检测与定位研究综述[J].福州大学学报(自然科学版),2022,50(6):751-759.
WU Luzi, MIAO Xiren, ZHUANG Shengbin, et al. Survey on fault detection and location of distribution network with distributed generation [J]. Journal of Fuzhou University (Natural Science Edition), 2022, 50(6):751-759.
- [4] MIRSHEKALI H, DASHTI R, KESHAVARZ A, et al. A novel fault location methodology for smart distribution networks [J]. IEEE Transactions on Smart Grid, 2021, 12(2):1277-1288.
- [5] 齐郑,黄朝晖,陈艳波.基于零序分量的阻抗法配电网故障定位技术[J].电力系统保护与控制,2023,51(6):54-62.
QI Zheng, HUANG Zhaohui, CHEN Yanbo. Impedance fault

- location technology for a distribution network based on a zero-sequence component [J]. Power System Protection and Control, 2023, 51(6):54 – 62.
- [6] 黄博,李文亮,徐学帅,等. 35 kV 中压配电网单相接地故障行波定位方法研究[J]. 电网与清洁能源, 2023, 39(1):58 – 63.
HUANG Bo, LI Wenliang, XU Xueshuai, et al. A study on the traveling wave location method of single-phase grounding fault in 35 kV medium voltage distribution network [J]. Power System and Clean Energy, 2023, 39(1):58 – 63.
- [7] 陈中豪,徐良德,郭挺,等. 基于 IGG 抗差的配电网多端行波故障定位方法[J]. 广东电力, 2022, 35(11):34 – 41.
CHEN Zhonghao, XU Liangde, GUO Ting, et al. Multi-terminal traveling wave fault location method for distribution network based on IGG robust [J]. Guangdong Electric Power, 2022, 35(11):34 – 41.
- [8] 梅飞,陈子平,裴鑫,等. 基于矩阵算法的有源配电网故障定位容错方法[J]. 电力工程技术, 2022, 41(6):109 – 115.
MEI Fei, CHEN Ziping, PEI Xin, et al. Fault-tolerant method for fault location of active distribution network based on matrix algorithm [J]. Electric Power Engineering Technology, 2022, 41(6):109 – 115.
- [9] 梁英达,田书,刘明杭. 基于相量校正的多源配电网故障区段定位[J]. 电力系统保护与控制, 2023, 51(1):33 – 42.
LIANG Yingda, TIAN Shu, LIU Minghang. Fault section location of multi-source distribution network based on phasor correction [J]. Power System Protection and Control, 2023, 51(1):33 – 42.
- [10] 李佳玮,王小君,和敬涵,等. 基于图注意力网络的配电网故障定位方法[J]. 电网技术, 2021, 45(6):2113 – 2121.
LI Jiawei, WANG Xiaojun, HE Jinghan, et al. Distribution network fault location based on graph attention network [J]. Power System Technology, 2021, 45(6):2113 – 2121.
- [11] 孟子超,杜文娟,王海风. 基于迁移学习深度卷积神经网络的配电网故障区域定位[J]. 南方电网技术, 2019, 13(7):25 – 33.
MENG Zichao, DU Wenjuan, WANG Haifeng. Distribution network fault area location based on deep convolution neural network with transfer learning [J]. Southern Power System Technology, 2019, 13(7):25 – 33.
- [12] 严凤,李双双. 基于 C 型行波与 SVM 的配电线路故障定位[J]. 电力系统及其自动化学报, 2016, 28(1):86 – 90.
YAN Feng, LI Shuangshuang. Composite fault location method based on C-traveling wave and SVM for distribution lines [J]. Proceedings of the CSU-EPSA, 2016, 28(1):86 – 90.
- [13] 李舟平,姚伟,曾令康,等. 基于长短期记忆网络的电网故障区域定位与故障传播路径推理[J]. 电力自动化设备, 2021, 41(6):164 – 174, 178.
LI Zhouping, YAO Wei, ZENG Linggang, et al. Fault section location and fault propagation path reasoning of power grid based on LSTM [J]. Electric Power Automation Equipment, 2021, 41(6):164 – 174, 178.
- [14] 徐良德,黄馨仪,郭挺,等. 考虑分布式光伏不确定性的输电系统供电能力评估[J]. 广东电力, 2024, 37(6):11 – 20.
XU Deliang, HUANG Xinyi, GUO Ting, et al. Evaluation of power supply capacity of integrated transmission and distribution systems considering distributed photovoltaic uncertainty [J]. Guangdong Electric Power, 2024, 37(6):11 – 20.
- [15] 缪希仁,赵丹,刘晓明,等. 含分布式电源配电网短路保护研究综述[J]. 高电压技术, 2023, 49(7):3006 – 3019.
MIAO Xiren, ZHAO Dan, LIU Xiaoming, et al. A research review of short-circuit protection in distribution network with distributed generation [J]. High Voltage Engineering, 2023, 49(7):3006 – 3019.
- [16] 葛磊蛟,李元良,陈艳波,等. 智能配电网态势感知关键技术及实施效果评价[J]. 高电压技术, 2021, 47(7):2269 – 2280.
GE Leijiao, LI Yuanliang, CHEN Yanbo, et al. Key technologies of situation awareness and implementation effectiveness evaluation in smart distribution network [J]. High Voltage Engineering, 2021, 47(7):2269 – 2280.
- [17] 刘科研,董伟杰,肖仕武,等. 基于电压数据 SVM 分类的有源配电网故障判别及定位[J]. 电网技术, 2021, 45(6):2369 – 2379.
LIU Keyan, DONG Weijie, XIAO Shiwu, et al. Fault identification and location of active distribution network based on SVM classification of voltage data [J]. Power System Technology, 2021, 45(6):2369 – 2379.
- [18] 邓祥力,吴高珍,魏聪聪,等. 基于多源数据融合的 Alexnet 神经网络大电网故障诊断[J]. 现代电力, 2023, 40(2):161 – 169.
DENG Xiangli, WU Gaozhen, WEI Congcong, et al. Fault diagnosis of large grid with alexnet neural network based on multi-source data fusion [J]. Modern Electric Power, 2023, 40(2):161 – 169.
- [19] 黄南天,程铎,蔡国伟. 基于改进时空图神经网络的高渗透率有源配电网故障定位[J]. 电力系统自动化, 2025, 49(10):112 – 122.
HUANG Nantian, CHENG Duo, CAI Guowei. Fault location of high penetration active distribution network based on improved spatiotemporal graph neural network [J]. Automation of Electric Power Systems, 2025, 49(10):112 – 122.
- [20] 张勇军,羿应棋,李立涅,等. 双碳目标驱动的新型低压配电系统技术展望[J]. 电力系统自动化, 2022, 46(22):1 – 12.
ZHANG Yongjun, YI Yingqi, LI Licheng, et al. Prospect of new low-voltage distribution system technology driven by carbon emission peak and carbon neutrality targets [J]. Automation of Electric Power Systems, 2022, 46(22):1 – 12.
- [21] 李振钊,王增平,张玉玺. 基于多源信息融合的有源配电网故障测距新方法[J]. 电网技术, 2023, 47(8):3448 – 3459.
LI Zhenzhao, WANG Zengping, ZHANG Yuxi. New method of fault location for active distribution network based on multi-source information fusion [J]. Power System Technology, 2023, 47(8):3448 – 3459.
- [22] 王远川,李泽文,夏翊翔,等. 基于 VMD 和改进聚类算法的配电网故障选线方法[J]. 电力系统及其自动化学报, 2024, 36(4):9 – 18.
WANG Yuanchuan, LI Zewen, XIA Yixiang, et al. Fault line selection method for distribution network based on VMD and improved clustering algorithm [J]. Proceedings of the CSU-EPSA, 2024, 36(4):9 – 18.
- [23] 陈晓华,王志平,吴杰康,等. 基于 VMD 和 IAO-SVM 的电压暂降源识别方法[J]. 广东电力, 2023, 36(1):59 – 67.
CHEN Xiaohua, WANG Zhiping, WU Jiekang, et al. Voltage sag source identification method based on VMD and IAO-SVM [J]. Guangdong Electric Power, 2023, 36(1):59 – 67.
- [24] 何一纯,李超顺,杨云鹏. 基于 MLP 和注意力机制 BiLSTM 的水电机组劣化趋势预测[J]. 水电能源科学, 2025, 43(3):

- 177 – 181, 100.
- HE Yichun, LI Chaoshun, YANG Yunpeng. Prediction of deterioration trends in hydropower units based on MLP and attention mechanism BiLSTM[J]. Water Resources and Power, 2025, 43(3):177 – 181, 100.
- [25] 邢超, 马红升, 覃日升, 等. 基于堆叠降噪自编码网络和多源数据加权融合的发电机故障诊断方法[J]. 高压电器, 2025, 61(5):170 – 178.
- XING Chao, MA Hongsheng, QIN Risheng, et al. Fault diagnosis method of generator based on stacked denoising autoencoder network and multi-source data weighted fusion[J]. High Voltage Apparatus, 2025, 61(5):170 – 178.
- [26] 游文霞, 李清清, 杨楠, 等. 基于多异学习器融合 Stacking 集成学习的窃电检测[J]. 电力系统自动化, 2022, 46(24):178 – 186.
- YOU Wenxia, LI Qingqing, YANG Nan, et al. Electricity theft detection based on multiple different learner fusion by Stacking ensemble learning[J]. Automation of Electric Power Systems, 2022, 46(24):178 – 186.
- [27] 邱磊鑫, 余涛, 彭秉刚. 基于异构基 Stacking 机制的居民负荷特征图像识别方法[J]. 电力系统保护与控制, 2022, 50(20):97 – 105.
- QIU Leixin, YU Tao, PENG Binggang. Image recognition method of resident load characteristics based on heterogeneous basis Stacking mechanism[J]. Power System Protection and Control, 2022, 50(20):97 – 105.
- [28] GUO Moufa, ZENG Xiaodan, CHEN Duanyu, et al. Deep-learning based earth fault detection using continuous wavelet transform and convolutional neural network in resonant grounding distribution systems[J]. IEEE Sensors Journal, 2018, 18(3), 1291 – 1300.

收稿日期: 2025-07-17; 网络首发日期: 2025-10-30

作者简介:

满超洪(2000), 男, 硕士研究生, 研究方向为电力系统故障分析与继电保护, mch7771@163.com;

孙铁鹏(1983), 通信作者, 男, 高级工程师, 学士, 研究方向为电力系统继电保护, stp2025@163.com;

李海锋(1976), 男, 教授, 博士, 研究方向为电力系统故障分析与继电保护, lihf@scut.edu.cn。

(上接第 71 页 Continued from Page 71)

- XU Limei, ZHAO Jin, LI Yumin, et al. Medium-term load forecasting model considering multivariate modeling[J]. Southern Power System Technology, 2024, 18(11):79 – 87.
- [21] 马燕峰, 杨小款, 赵书强, 等. 基于潮流转移和追踪的含风电电力系统运行风险评估[J]. 电力自动化设备, 2021, 41(1):77 – 83.
- MA Yanfeng, YANG Xiaokuan, ZHAO Shuqiang, et al. Assessment of operation risk for power system containing wind power based on power flow transferring and tracing[J]. Electric Power Automation Equipment, 2021, 41(1):77 – 83.
- [22] 何晓峰, 林子钊, 徐希, 等. 基于模糊化事故等级指标的调度风险评价方法[J]. 电力系统保护与控制, 2021, 49(5):98 – 104.
- HE Xiaofeng, LIN Zizhao, XU Xi, et al. A dispatch risk assessment method based on fuzzification accident rating index[J]. Power System Protection and Control, 2021, 49(5):98 – 104.
- [23] 李若琼, 司宇杰, 杨承辰, 等. 考虑柔性负荷的新型电力系统源荷日前-日内低碳优化调度[J]. 南方电网技术, 2025, 19(3):116 – 129.
- LI Ruqiong, SI Yujie, YANG Chengchen, et al. Day-ahead and intra-day low-carbon optimal scheduling of new power system source-load considering flexible load[J]. Southern Power System Technology, 2025, 19(3):116 – 129.
- [24] 何伊慧, 管霖, 王彤, 等. 南方电网新型电力系统规划建设的量化评估与分析[J]. 南方电网技术, 2024, 18(10):40 – 53.
- HE Yihui, GUAN Lin, WANG Tong, et al. Quantitative evaluation and analysis of planning and construction of the new power system in China Southern Power Grid[J]. Southern Power System Technology, 2024, 18(10):40 – 53.
- [25] 董周杰, 郭迎清. 基于综合模糊聚类算法的液体火箭发动机故障诊断[J]. 航空动力学报, 2020, 35(6):1326 – 1334.
- DONG Zhoujie, GUO Yingqing. Fault diagnosis of liquid rocket engine based on comprehensive fuzzy clustering algorithm[J]. Journal of Aerospace Power, 2020, 35(6):1326 – 1334.

收稿日期: 2024-10-29; 网络首发日期: 2025-07-30

作者简介:

毛志宇(1998), 男, 助理工程师, 硕士, 研究方向为储能建模与控制及其在电力系统中的应用, 电力安全技术, maozy1@csg.cn;

刘通(1975), 男, 高级工程师(教授级), 博士, 研究方向为配电网安全技术, liutong@csg.cn;

李培强(1975), 男, 通信作者, 教授, 博士, 研究方向为负荷建模、电力系统运行风险分析与控制, lpqcs@hnu.edu.cn。