

DOI: 10.19783/j.cnki.pspc.240886

小样本条件下基于深度特征融合的配电网高阻 接地故障识别方法

尚博阳, 罗国敏, 刘畅宇, 王小君, 杨雪凤

(北京交通大学电气工程学院, 北京 100044)

摘要: 针对基于数据驱动的高阻接地故障检测可靠性低和样本需求度高的问题, 提出一种小样本条件下基于深度特征融合的配电网高阻接地故障识别方法。首先, 在配电网高阻故障特性分析的基础上, 利用离散小波变换对高阻故障信号的波形进行深度挖掘, 构造多尺度时频特征图和全局统计特征矩阵以增强高阻故障特征的表达。其次, 结合轻量级残差网络结构和自注意力机制设计深度特征提取网络, 实现局部和全局时频特征的融合提取。然后, 引入度量元学习计算各类样本在度量空间中的特征类原型以及类原型与样本之间的距离, 从而实现高阻故障分类器的构建。最后, 在不同复杂运行条件和现场数据集上进行算例测试, 验证了所提方法的有效性。

关键词: 配电网; 高阻接地故障; 时频特征融合; 小样本; 自注意力机

High-impedance fault identification method for distribution networks based on deep feature fusion in small sample conditions

SHANG Boyang, LUO Guomin, LIU Changyu, WANG Xiaojun, YANG Xuefeng
(School of Electrical Engineering, Beijing Jiaotong University, Beijing 100044, China)

Abstract: To address the issue of low reliability and high sample demand of data-driven high-impedance fault detection, a high-impedance fault identification method for distribution networks based on deep feature fusion in small sample conditions is proposed. First, based on the analysis of high-impedance fault characteristics in distribution networks, the waveform of high-impedance fault signals is deeply mined using discrete wavelet transform, and a multi-scale time-frequency feature graph and global statistical feature matrix are constructed to enhance the expression of high-impedance fault characteristics. Second, combining a lightweight residual network structure and self-attention mechanism, a deep feature extraction network is designed to realize the fusion extraction of local and global time-frequency features. Then, the metric meta-learning is introduced to calculate the feature class prototype and the distance between the class prototype and the sample in the metric space, so as to realize the construction of a high-impedance fault classifier. Finally, the effectiveness of the proposed method is verified by case studies with different complex operating conditions and field data sets.

This work is supported by the National Natural Science Foundation of China (No. 52377071).

Key words: distribution network; high impedance fault; time-frequency feature fusion; small sample; self-attention mechanism

0 引言

中压配电网由于受自然环境、架空线路短等因素的影响, 经常会形成接触混凝土地面、草地、沙地等介质的高阻接地故障^[1-2](后文简称高阻故障)。由于接地介质的高阻抗特性, 导致故障电流小、故

障特征微弱, 难以被传统零序保护方案有效识别并切除^[3-5]。一旦高阻故障在配电网中长期存在, 容易导致配电线路的绝缘受到破坏, 将间接引起火灾和触电危险。因此, 尽快检测并排除高阻故障, 对维护配电网的安全和可靠运行具有重要意义。

现有的高阻故障识别方法主要分为物理模型法和数据驱动法。基于物理模型的高阻故障识别方法通过分析高阻故障的电气量变化提出故障检测依

基金项目: 国家自然科学基金项目资助(52377071)

据, 由指标阈值的对比实现高阻故障的判定。常见的故障电气量信息包括有功功率^[6]、零序电压^[7]和零序电流^[8-9]等。该类方法结构简单、物理意义明确, 但阈值设定多以专家经验设置为准, 无法充分覆盖不同运行场景的故障判定界限。另一方面, 电容器投切(capacitor switching, CS)、负荷投切(load switching, LS)和励磁涌流(inrush current, IC)等配电网正常运行工况与高阻故障(high impedance fault, HIF)呈现出相似的电气特征, 使得故障识别方案很容易混淆故障与扰动的区别, 从而导致高阻故障识别方案可靠性不足^[10-11]。

随着计算机科学和信息技术的发展, 机器学习(machine learning, ML)技术为配电网故障诊断带来机遇^[12-13], 新兴的数据驱动相关算法在高阻故障识别中得到越来越多的应用。文献[14]中定义了离散小波分解后的3个相关特征序列作为改进极限学习机的输入, 用于多种运行模式下配电网的高阻故障识别。文献[15]将电弧电压信息采用变分模态分解和奇异值分解后输入到支持向量机中, 在主动配电网中实现弧光高阻故障识别。此外, 随着人工智能的突破, 基于深度学习的高阻故障识别获得更好的应用效果。文献[16]中使用连续小波变换处理功率波形信息, 并将变换后的波形输入到卷积神经网络(convolutional neural network, CNN)中区分高阻故障与正常扰动。文献[17]利用小波能量熵构建暂态电压时频特征图作为CNN的训练样本, 并结合支持向量机技术将高阻故障从电容器投切、励磁涌流和负荷投切3种正常扰动中识别。然而上述方法中, 高阻故障信息的表达和提取大多只单一考虑样本的局部特征或全局特征, 忽略了不同维度特征的融合, 限制了高阻识别准确度的提高。

另一方面, 现有高阻故障识别模型大都在足够的样本上训练, 在实际的高阻识别任务中很难获得充足的样本支持分类检测模型的构建。一些学者采用对抗式生成网络和变分自编码器对故障样本进行扩充, 可以改善基于数据驱动的高阻故障识别方法面临的小样本及样本不平衡问题。另有部分学者采用迁移学习^[18-20]和半监督迁移学习^[21-22], 利用实际样本分布对仿真阶段构建的模型进行更新和微调。实际上, 该问题的关键难点在于小样本学习, 即采用很少的标记样本实现目标分类器的构建。与上文样本生成方法和模型迁移方法不同, 元学习能够从少量标记样本中学习分类任务知识^[23]。用于学习新知识的标记样本集通常称为支持集, 而需要分类的新样本集称为查询集。基于度量的元学习方法通过将支持集和查询集的样

本特征转换为度量向量, 并以此作为分类依据, 然后对样本相似度进行测量, 从而更新预测标签。该方法可有效避免小样本训练的弊端, 为现场高阻故障诊断任务提供一种新型解决方案。

为解决配电网高阻故障识别准确度低及数据驱动算法在小样本条件下可靠性差的问题, 提出了一种轻量型残差网络(lightweight resNet, LRN)和自注意力机制网络(self-attention mechanism, SAM)融合的高阻故障识别度量元学习模型。针对高阻故障特征微弱且易混淆的特点, 设计了零序电流信号局部图像信息和全局统计矩阵融合的输入结构, 提出了一种深度特征提取网络, 实现局部和全局时频信息的表征。针对模型的泛化能力低的特点, 引入度量元学习, 结合伪标签思想提出了一种基于原型网络的分类策略, 从近邻损失和边界损失两方面提高故障识别能力。最后在10 kV配电网真型试验现场测试了所提方法的准确度, 并选取多个ML高阻识别模型进行对比实验, 验证了所提方案在现场小样本条件下高阻故障识别的优势。

1 高阻故障识别特征构造

1.1 高阻故障特性分析

当发生高阻故障时, 馈线电感、电阻与消弧线圈电阻可以忽略, 此时不同接地系统零序等效网络如图1所示。其中, 经消弧线圈接地系统由于补偿电流的存在削弱了原有的故障特征, 使得高阻故障识别更加困难。本文以经消弧线圈接地系统为例, 分析配电网高阻故障特性。

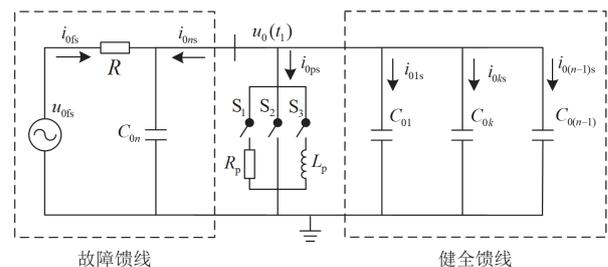


图1 不同接地系统下的零序网络

Fig. 1 Zero-sequence network for different grounding systems

图1系统中共有 n 条馈线, 假定第 n 条馈线为故障馈线, i_{0fs} 、 i_{0ps} 分别为故障点电流与中性点电流, i_{0ks} 为第 k 条馈线的零序电流($k=1, 2, \dots, n$), $u_0(t_1)$ 、 u_{0fs} 分别为 t_1 时刻的母线零序电压和故障点零序电压, R 为线路等效电阻, C_{0k} 为线路对地电容, R_p 、 L_p 分别为串联阻尼电阻和消弧线圈电感, S_1 、 S_2 和 S_3 为闭合开关。当闭合开关 S_3 时, 中性

点经消弧线圈接地, 过补偿度取值范围为 5%~10%。

依据基尔霍夫电压定律, 由图 1 列写电路方程, 如式(1)所示。

$$\begin{cases} u_{0fs} = R(C_{0sum} \frac{du_0(t_1)}{dt_1} + i_{0ps}) + u_0(t_1) \\ u_0(t_1) = L_p \frac{di_{0ps}}{dt_1} \end{cases} \quad (1)$$

式中, C_{0sum} 为各馈线对地电容之和, $C_{0sum} = \sum_{k=1}^n C_{0k}$ 。

即可获得式(1)的微分方程形式, 如式(2)所示。

$$RC_{0sum} L_p \frac{d^2 i_{0ps}}{dt_1^2} + L_p \frac{di_{0ps}}{dt_1} + Ri_{0ps} = u_{0fs} \quad (2)$$

已知 $u_{0fs} = U_{ms} \sin(\omega_0 t_1 + \theta_s)$, U_{ms} 、 θ_s 分别为故障点故障前的相电压幅值与初相角, ω_0 为工频角频率, 定义中间变量阻尼因子 δ_s 、主谐振频率 ω_f 为

$$\begin{cases} \delta_s = \frac{1}{2RC_{0sum}} \\ \omega_f^2 = \frac{1}{L_p C_{0sum}} - \left(\frac{1}{2RC_{0sum}}\right)^2 = \frac{1}{L_p C_{0sum}} - \delta_s^2 \end{cases} \quad (3)$$

则流经中性点电流 i_{0ps} 设为

$$i_{0ps} = B \sin(\omega_0 t_1 + \theta_s - \varphi_s) + e^{-\delta_s t_1} (A_1 \cos(\omega_f t_1) + A_2 \sin(\omega_f t_1)) \quad (4)$$

式中, B 、 A_1 、 A_2 和 φ_s 为待求参数。

通过式(4)推导 i_{0ps} 的一阶导数和二阶导数, 利用 i_{0ps} 的初始条件 $i_{0ps}(0_-) = i_{0ps}(0_+) = 0$, $t_1 = 0$, 得

$$\begin{cases} B = U_{ms} / \sqrt{R^2(1 - \omega_0^2 L_p C_{0sum})^2 + (\omega_0 L_p)^2} \\ A_1 = -B \sin \varphi_s \\ A_2 = -(\delta_s B \sin \varphi_s + \omega_0 B \cos \varphi_s) / \omega_f \\ \varphi_s = \arctan[\omega_0 L_p / (R(1 - \omega_0^2 L_p C_{0sum}))] \end{cases} \quad (5)$$

式中, U_{ms} 为故障点故障前的相电压幅值。

进一步, 通过计算母线零序电压 $u_0(t_1)$ 和健全馈线零序电流 i_{0ks} 可得故障馈线零序电流 i_{0ms} 为

$$i_{0ms} = -\sum_{k=1}^{n-1} i_{0ks} - i_{0ps} = -B[1 - C_1 \omega_0^2 L_p] \sin(\omega_0 t_1 + \theta_s - \varphi_s) - e^{-\delta_s t_1} [A_1 + L_p C_1 K_1] \cos(\omega_f t_1) - e^{-\delta_s t_1} [A_2 + L_p C_1 K_2] \sin(\omega_f t_1) \quad (6)$$

式中: $C_1 = C_{0sum} - C_{0n}$, C_{0n} 为第 n 条馈线对地电容, 即故障馈线对地电容; $K_1 = (A_1 \delta_s^2 - A_1 \omega_f^2 - 2A_2 \omega_f \delta_s)$;

$K_2 = (A_2 \delta_s^2 - A_2 \omega_f^2 + 2A_1 \omega_f \delta_s)$ 。

分析式(6)可知, 高阻故障的零序电流由稳态趋

势分量和暂态衰减分量组成, 其波形能够展现出故障信号的时-频故障信息。若能以零序电流为特征信号, 构建一套具有可靠有效的故障特征表征结构, 则可将其作为数据驱动模型的输入实现高阻故障的识别。

1.2 识别模型输入特征构造

在获取零序电流后, 必须采用有效的时频分析方法提取波形信息内在的时频特征。离散小波变换可以将原始信号分解成不同频段的子信号, 但仅通过细节系数难以有效区分配电网高阻故障、电容器投切、负荷投切和励磁涌流运行工况。为此, 设计一种多域特征融合的零序电流故障信息表征结构, 其过程如图 2 所示。构造多尺度时频特征图和全局统计特征矩阵的融合结构以充分利用深度学习模型的局部图像特征提取和全局统计特征降维的能力, 在本文中将其称为信号处理模块。

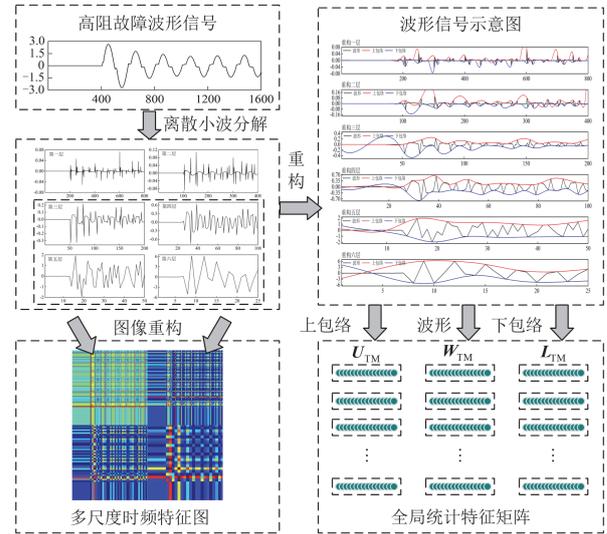


图 2 多域特征融合的信息表征结构

Fig. 2 Information representation structure of multi domain feature fusion

1) 多尺度时频特征图: 离散小波分解是一种时频分析方法, 可以有效地分析和处理非线性、非平稳电气信号。为充分利用高阻接地故障带来的丰富谐波分量且避免基波分量的影响^[24], 本文对电气信号进行 6 层小波分解, 采用小波分解后的第 3、4、5 和 6 层细节分量作为故障特征。然后, 将每层细节分量去噪后通过格拉姆角场^[25]变换构造一个表示时序序列关系的 32×32 的特征图。最后, 如图 2 中多尺度时频特征图所示, 拼接 4 个特征图得到 1 张 64×64 的多尺度时频特征图用于后续的局部特征提取网络的输入。

2) 全局统计特征矩阵: 高阻故障在时域或频域

都会产生动态响应，时频分析方法是提取故障特征的有效手段。因此，选择电气信号的时频统计特征对提高故障识别性能起着关键作用。对于分析峰度、偏度、能量熵等时频特征在高阻故障识别中的作用，已有学者进行了大量的研究^[2,17]。在这些研究工作的基础上，本文选择表 1 中 7 个统计特征作为全局初始特征，其中设定 $x(i)$ 为含有 q 个元素的波形序列数据。

对原始信号离散小波分解后的 6 层细节信号进行波形重构并计算 6 个支路信号的上下包络线。然后，计算重构波形和上下包络线的每个分支信号的 7 个统计特征作为高阻故障信号的全局统计特征。具体而言，将 6 个信号的某一特征(如振幅)打包成一个 6 维向量，得到统计特征矩阵 $W_{TM} \in R^{7 \times 6}$ 。

同理，得到上下包络线的统计特征矩阵 $U_{TM} \in R^{7 \times 6}$ 和 $L_{TM} \in R^{7 \times 6}$ 。最后，将矩阵 W_{TM} 、 U_{TM} 和 L_{TM} 拼接，作为后续全局特征降维网络的输入。

表 1 统计特征及其计算方法

序号	特征	计算方法
1	振幅	$T_1 = \max(x(i)) - \min(x(i))$
2	平均值	$T_2 = (1/q) \sum_{i=1}^q x(i)$
3	标准差	$T_3 = \sqrt{(1/q) \sum_{i=1}^q (x(i) - T_2)^2}$
4	峭度	$T_4 = \sum_{i=1}^q (x(i) - T_2)^4 / ((q-1)T_3^4)$
5	均能量	$T_5 = (1/q) \sum_{i=1}^q x(i) ^2$
6	能量熵	$T_6 = -\sum_{i=1}^q (x(i) ^2 / (qT_5)) \lg(x(i) ^2 / (qT_5))$
7	偏度	$T_7 = \sum_{i=1}^q (x(i) - T_2)^3 / ((q-1)T_3^3)$

2 深度特征融合的小样本高阻识别方法

本节提出一种用于配电网高阻故障识别的小样本度量元学习方法，主要包含深度特征融合网络、度量元学习分类策略和复合损失函数构建 3 个方面，小样本高阻故障识别网络总体框架如图 3 所示。

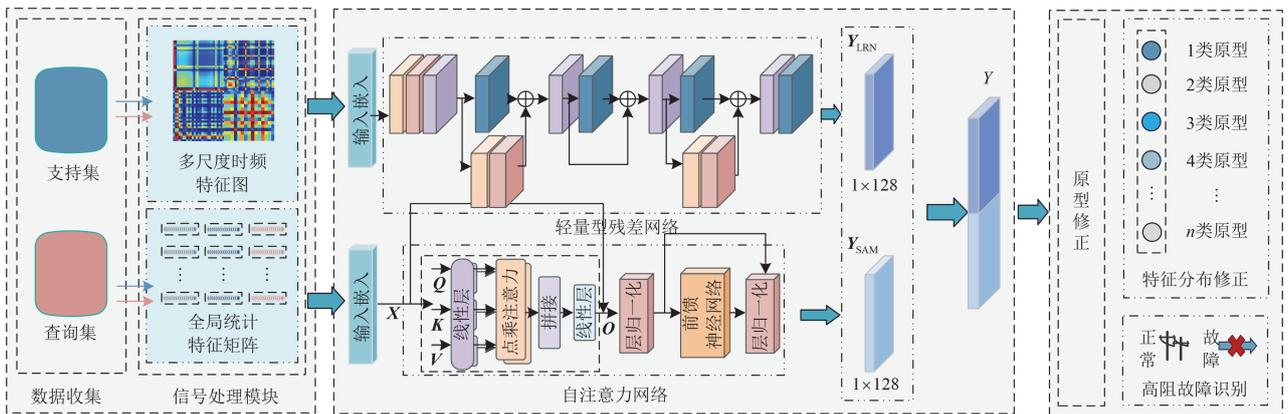


图 3 小样本高阻故障识别网络架构

Fig. 3 Framework of high impedance fault identification network in small sample condition

2.1 深度特征融合网络

具有局部特征提取能力的 CNN 难以把控电气故障信号中多尺度时频特征的整体趋势，以及波形信号之间的内在关系^[26]。基于此，受 SAM 的启发，提出了一种由 LRN 和 SAM 两个模块组成的深度融合特征提取网络。各模块的设计原则和细节如下所述。

1) LRN

残差网络通过设计残差模块消除传统神经网络中容易出现的梯度消失和网络退化问题，在图片信息特征提取任务中表现优异。高阻故障信号通常在零序电流信号中以不同的时频段表示，即高阻故障特征分散在多尺度时频特征图中。由于多尺度时频特征图的图像尺寸较小，故而在残差网络模型基础上改进设计了一种轻量型残差网络结构，卷积堆叠残差单元如图 4 所示，避免了网络过于复杂而导致

模型泛化能力下降，同时降低网络参数和计算量，易于后续识别算法部署应用。

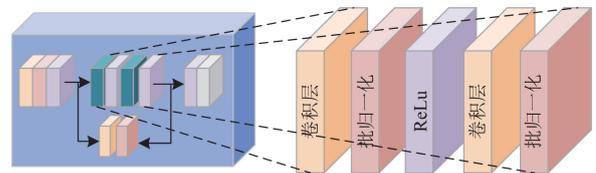


图 4 卷积堆叠残差单元

Fig. 4 Convolutional stacking residual unit

改进的内容主要为模型缩减方面，使用大小为 3×3 的卷积核，卷积步长设置为 1，填充设置为 1 或 0。同时，LRN 仅使用 3 个卷积堆叠残差单元结构，并且消除了中间层的池化操作。在输出层的最后保留全局平均池化层，并形成全连接层 $Y_{LRN} \in R^{1 \times 128}$ 以便后续特征向量的拼接。

2) SAM

不同于卷积和神经网络通过堆叠实现上下文信息的集成, SAM 网络通过计算输入数据中任意两个位置之间的相关系数获得序列数据之间的依赖关系^[27], 其实现细节如图 5 所示。通过对输入序列 X 进行线性变换得到查询 $Q = XW_Q$ 、键 $K = XW_K$ 和值 $V = XW_V$, 其中, W_Q 、 W_K 、 W_V 分别对应为查询 Q 、键 K 、值 V 的线性变换矩阵。然后, 经过缩放点积并使用 SoftMax 函数计算 Q 、 K^T , 以得到自注意力值矩阵 A (称为注意力分数)。矩阵 A 描述了输入特征序列中所有元素之间的相关性, 用于增强主导特征的表达, 减少不相关冗余特征的干扰。最后, 将 V 与注意矩阵 A 相乘, 得到输出 O , 表示全局信息加权后的特征序列。本文使用 SAM 从波形信号的全局统计特征中提取关键特征信息用于后续高阻故障的识别。

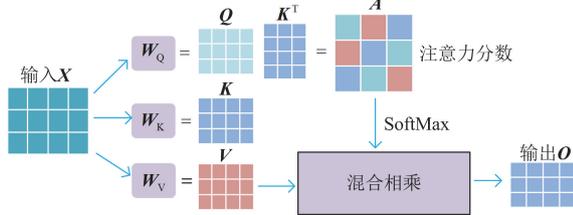


图 5 自注意力网络实现机制

Fig. 5 Implementation mechanism of SAM

SAM 网络有 4 层, 每一层都由一个“多头”自关注模块、一个前馈层、一个添加层和一个正常层组成。设 X_a 为 SAM 网络的输入序列, $X_a = [x_1, x_2, \dots, x_N] \in \mathbf{R}^{L_M \times D_1}$, 其中 L_M 为序列的长度, D_1 为序列元素的维度。输入序列 X_a 通过线性投影 $W^P \in \mathbf{R}^{D_1 \times D_M}$ 得到序列 $X_s = [x_1^s, x_2^s, \dots, x_N^s] \in \mathbf{R}^{L_M \times D_M}$ 。多头自注意力层的输出序列 O 表示注意力分数和序列数值混合加权相乘得到的特征序列, $O \in \mathbf{R}^{L_M \times D_M}$, 其计算如式(7)所示。

$$\begin{cases} O = \text{Concat}(h_1, \dots, h_i)W^O \\ h_i = \text{softmax}\left(\frac{Q_i K_i^T}{\sqrt{D_M}}\right)V_i \\ Q_i = X \cdot W_i^Q, K_i = X \cdot W_i^K, V_i = X \cdot W_i^V \end{cases} \quad (7)$$

式中: $\text{Concat}(\cdot)$ 表示向量的拼接函数; h_i 表示第 i 个注意力头部; $\text{softmax}(\cdot)$ 表示注意力头部 h_i 的激活函数; W^O 表示多个线性变换操作, $W^O \in \mathbf{R}^{D_M \times D_M}$; $W_i^Q \in \mathbf{R}^{D_M \times D_M}$ 、 $W_i^K \in \mathbf{R}^{D_M \times D_M}$ 和 $W_i^V \in \mathbf{R}^{D_M \times D_M}$ 分别表示第 i 个注意力头部中查询 Q_i 、键 K_i 、值 V_i 的权重矩阵。

根据输入数据维度的大小, 在 SAM 网络输出之后设置全连接层 $Y_{\text{SAM}} \in \mathbf{R}^{1 \times 128}$, 以提取全局时频信息的特征。最后, 将局部特征信息和全局特征信息连接在一起, 得到深度融合特征向量 Y , 并将其结果作为深度特征提取网络的输出。

2.2 度量元学习分类策略

针对在稀缺数据分布下训练得到的原型网络模型容易存在类别中心误差, 导致分类不准确且易受到噪声影响的问题, 本文结合“伪标签”思想提出了一种原型更新的分类策略。

为了修正原型网络中聚类特征点的拟合偏差, 找到产生误差的类内原型特征点, 通过使用查询集中的未标记样本信息对现有数据集原型特征点进行偏移更新。具体而言, 为每个查询集样本预测类别标签, 设定每个查询集样本预测概率最高的类别为查询集类别, 并将该类别的伪标签添加到查询集中。输入样本数据 x 的预测标签是类别 j 的概率设为 P_ϕ , 计算如式(8)所示。

$$P_\phi(y = j|x) = \frac{e^{-\cos(f_\phi(x_m), c_j)}}{\sum_{j=1}^{n_k} e^{-\cos(f_\phi(x_m), c_j)}} \quad (8)$$

式中: $-\cos(f_\phi(x_m), c_j)$ 为查询集中样本 x_m 属于类别 j 的概率; c_j 为原型点; $f_\phi(x_m)$ 为嵌入函数; n_k 为样本的类别数。

通过将查询集中按照“伪标签”策略赋予标签值构造一个重组后的支持集, 再使用修正过的原型网络用于小样本高阻故障识别中。使用新的支撑集计算每个类别的新原型点, 预测概率 P_j 计算如式(9)所示。

$$P_j = \frac{1}{|D_j^s|} \sum_{D_j^s} g_\phi(x_i) \quad (9)$$

式中: $|D_j^s|$ 为支持集中类别 j 的样本个数; $g_\phi(x_i)$ 为新数据集映射函数。

2.3 复合损失函数构建

考虑在度量空间中同类数据样本的特征分布越分散会导致与其他类别的样本发生重叠现象, 容易导致原型边界不够明确。本文通过设计一种组合型损失函数, 对样本的原型特征进行更新和修正, 损失函数 L_{NB} 具体表达如式(10)所示。

$$L_{\text{NB}} = y_{il} \frac{1}{2n_k} \sum_{i=1}^{n_k} F(p_i, x_i^{S_c}) + (1 - y_{il}) \frac{1}{n_k} \sum_{i,j=1}^{n_k} [F(p_i, x_i^{S_c}) - F(p_i, x_j^{S_c})]_+ \quad (10)$$

式中: y_{il} 为类型标签; $F(\cdot)$ 为欧式距离的计算; p_i

为标签为 i 的类原型； $\mathbf{x}_i^{S_c}$ 、 $\mathbf{x}_l^{S_c}$ 分别为标签为 i 、 l 的支持集样本的高维特征向量； $[\cdot]_+$ 为误差校准， $[\cdot]_+ = \max(\cdot, 0)$ 。

两种不同的特征损失表示函数用于完善样本特征点在特征空间的分布。当 $i=l$ 、 $y_{il}=1$ 时，计算第一项损失(近邻损失)，其目的在于减小类内样本与原型聚类特征点之间的距离，使得类别相同的样本在特征空间中更加集中。通过计算标记为类别 i 的原型聚类特征点 p_i 与所有特征点之间的欧式距离(称为近邻距离)，然后将计算所得的所有近邻距离相加，得到全局近邻损失值。当 $i \neq l$ 、 $y_{il}=0$ 时，计算第二项损失(边界损失)，其目的在于增大原型数据集中类与类特征点之间的距离，使得类内原型附近不存在其他类别的样本。通过计算标记为类别 i 的类原型 p_i 与样本类别标记为 l 的所有特征之间的欧氏距离(称为入侵距离)，再计算出近邻损失，并通过误差校准计算近邻距离与入侵距离的差值，如果误差校准大于 0，则表明存在有不同类别的样本入侵到另一类样本的表征方位边界内。

3 小样本高阻识别应用流程

本文采用了一种批量训练策略，即在训练过程中模拟测试过程中的小样本设置，通过从训练集中抽取多个小样本来优化网络，从而将训练好的模型推广到测试环境中。如图 6 所示，在标记数据较少的情况下，使用所提方法进行高阻故障识别的流程可以分为原始数据准备、元模型训练和更新测试验证 3 个部分，各部分的详细说明如下。

1) 原始数据准备

高阻故障识别的目的是正确预测无标签数据集 T_l 中每个样本的类别。在实际应用中，现场实际配电网会收集到一些真实故障样本，该类样本记作少量有标签样本 Φ_l (甚至只有一个样本)。此外，需要准备一个大规模的有标签数据集 Φ_b 用作训练和测试(通常由仿真数据集充当)。在 Φ_b 中，随机抽取部分样本组成训练集 Φ_{b-t} ，剩余的仿真样本组成验证集 Φ_{b-v} 。

2) 元模型训练

在模型训练开始之前，设置训练轮次和测试轮次，初始化元学习器模型参数。在每个训练任务中计算损失函数，并通过反向传播更新网络参数。为了提高测试效率，设置测试阈值参数 β ，即每隔 β 轮训练进行一次测试。测试任务的构造方式与训练任务相同。然后，通过计算预测正确的样本数量与查询样本总数的比值作为模型识别准确度。

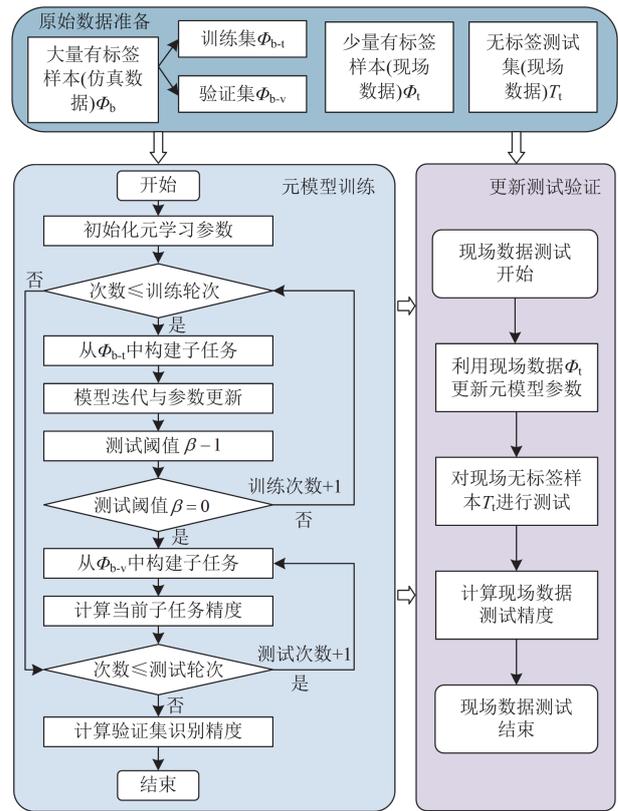


图 6 基于度量元学习的小样本高阻故障识别应用流程

Fig. 6 Application flowchart of small sample high impedance fault identification based on metric meta-learning

3) 更新测试验证

在测试过程中，通过将 Φ_l 作为支持集、 Φ_{b-t} 作为查询集构造元测试任务。然后，使用该过程中更新获得的元学习器预测 T_l 中每个样本的标签。最终，将预测正确的标签数量与无标签测试集 T_l 样本总数的比值作为最终测试结果，用于评估所提方法的识别性能。

4 算例分析与讨论

4.1 实验参数设置

4.1.1 数据采集信息

本文通过 Matlab/Simulink 仿真平台搭建图 7 所示的 10 kV 辐射状配电网模型，线路参数如表 2 所示。由于中性点经消弧线圈接地方式在故障快速切除方面具有优势，因此将测试系统中性点运行方式设置为经消弧线圈接地，过补偿度为 5%，其中消弧线圈电感 L_1 为 0.1543 H，电阻 R_1 为 5.115 Ω 。系统电容电流为 32.257 A。分布式电源 DG₁、DG₂ 容量均为 2 MVA，分别经过隔离变压器接入馈线 L1、L6。

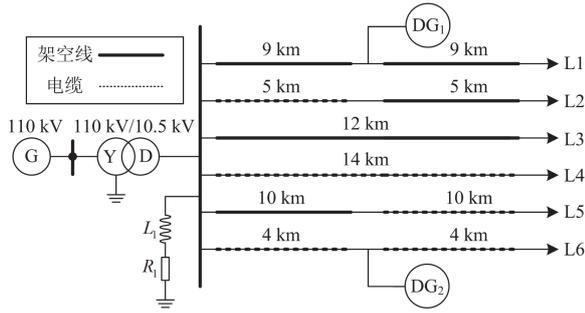


图 7 含 DG 接入的 10 kV 配电系统

Fig. 7 The 10 kV distribution network with DGs

表 2 10 kV 配电系统线路参数

Table 2 Line parameters of 10 kV distribution system

线路	相别	电阻/(Ω /km)	电感/(mH/km)	电容/(μ F/km)
架空线路	正序	0.1700	1.2100	0.0097
	零序	0.2300	5.4800	0.0060
电缆线路	正序	0.2650	0.2550	0.1700
	零序	2.5400	1.0190	0.1530

在配电系统馈线出口处安装零序电流波形信息记录装置, 采样频率设置为 10 kHz, 对高阻故障和正常扰动工况展开仿真分析。为了有效记录工况变换前后的录波数据, 同时避免识别算法的频繁启动, 本文采用零序电压大于正常运行电压的 15% 作为算法启动判据^[24]。波形数据截取检测算法启动前 2 个和后 6 个周波的零序电流波形作为识别模型的信息输入, 以此构造多尺度时频特征图和全局统计特征矩阵进行特征提取和类别判定。

先前的研究内容表明, 与高阻故障极难区分的工况多为电容器投切、负荷投切和励磁涌流 3 种正常扰动^[14,17,19,21], 因此, 在本文的算例测试中仅区分识别高阻故障、电容器投切、负荷投切和励磁涌流 4 种工况。此外, 考虑到高阻接地故障常常伴随着电弧发生, 在建立高阻接地故障模型时应考虑电弧特性, 本文使用 Emanuel 模型作为高阻故障模型^[24,28], 通过改变 Emanuel 高阻模型中参数以改变高阻故障的过渡电阻大小、不对称程度和非线性程度。为验证所提算法的有效性, 根据录波时刻、故障初相角、故障位置和工况参数值的不同, 在图 7 配电系统中生成了 2700 组仿真数据样本。其中, 电容器投切的功率值为 1.2~6 Mvar; 负荷投切有功功率为 1.5~2.5 MW, 无功功率为 0.3~0.5 Mvar; 励磁涌流变压器连接方式为 YN/D1 和 YN/D11。表 3 为数据集样本中不同工况的数据分布。每类工况数据中 80% 样本用作模型训练, 记作仿真训练集; 剩余的 20% 样本用作模型测试, 记作仿真测试集。

为了验证所提方法在现场配电网的应用价值,

在中国某电科院配电网真型试验场地采集数据作为真型测试集, 其简要拓扑及现场如图 8 所示。真型试验现场由 4 根馈线组成, 可模拟不同接地系统多种高阻故障类型和扰动的运行工况。在线路首端安装有采样频率为 6.4 kHz 的故障录波器(M01、M02、M03、M04)以模拟微型 PMU 采样。通过设置不同类型接地方式、故障初相角、故障位置的高阻故障以及扰动共 150 组数据进行测试验证。

表 3 数据集不同工况样本分布

Table 3 Samples distribution in different operating conditions in the datasets

数据集	类别	高阻故障	负荷投切	负载接入	励磁涌流
仿真数据	训练集	540	540	540	540
	测试集	135	135	135	135
真型数据	测试集	45	35	35	35

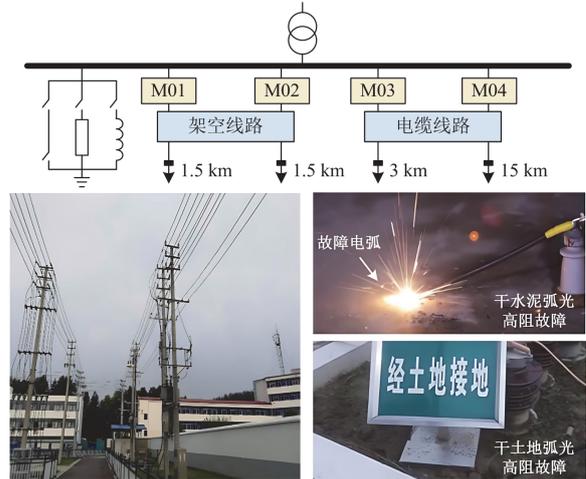


图 8 真型试验现场及简要拓扑图

Fig. 8 Real-type test field and brief topology diagram

4.1.2 实验环境设置

采用 PyTorch 框架在 Windows 11 系统上进行实验, 使用 12 GB 的 Nvidia GeForce RTX 3060 Ti GPU 和 32 GB CPU 内存。所有 Dropout 层的概率设为 0.2, 训练批大小为 64。采用 Adam 优化器对网络进行训练, 权值衰减设为 0.0005, 初始学习率 α 为 0.000 05。训练轮次设置为 100 次, 每 20 个训练周期学习率下降 0.2 倍。测试轮次为 20 次, 测试阈值参数 β 为 20。

4.2 故障识别结果分析

4.2.1 分类模型对比分析

本节将所提的分类模型记作方法 1, 与现有常见的小样本分类处理方法展开对比分析。对比的基准模型选择原型网络^[29](方法 2)、原型修正网络^[30]

(方法 3)和边界损失原型网络^[31](方法 4)。为了保证对比的公平性,所有方法的特征提取器和参数设置均与本文所提分类模型相同。同时,增加可以处理小样本的域自适应迁移网络^[21](方法 5)和生成式对抗网络^[18](方法 6)作为对照组进行对比分析。为了突出不同方法在小样本条件下的识别性能,还使用了对现场数据直接训练的方法(方法 7)进行对比测试。不同方法和样本数在现场测试集上的测试结果如图 9 所示。其中,1-shot、5-shot、10-shot、15-shot 和 20-shot 分别指在测试集中随机抽取 1 个、5 个、10 个、15 个和 20 个现场数据样本对模型进行更新,然后在 150 个样本中除去更新样本后的剩余样本分别进行测试。测试过程进行 5 轮,并取所有结果的平均值作为测试准确度。

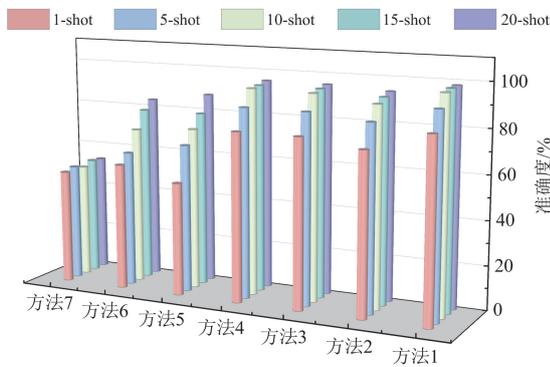


图 9 不同方法和样本数的测试结果

Fig. 9 Test results of different methods and sample numbers

从图 9 可以看出,基于度量元学习方法(方法 1、2、3 和 4)的识别准确度随着样本数 K_N 值的增大而提高,在 K_N 值为 10 时,测试结果开始趋于稳定。当 K_N 值达到 15 后几乎不增加。此外,在域自适应迁移学习(方法 5)中,识别准确度随 K_N 值的增大而提高,但却始终远低于度量元学习方法。同时,生成对抗网络(方法 6)在这项研究中的准确度低于 85%。与原型网络相比,本文所提方法在现场测试集中分别针对 1-shot、5-shot、10-shot、15-shot 和 20-shot 的识别准确度提高了 8.77%、7.39%、6.58%、5.46% 和 4.25%。由此可以发现现场可用数据越少,本文所提方法的识别准确度提高越多,说明所提分类策略对样本较少的任务具有更好的分类效果。考虑到 $K_N = 10$ 时故障诊断的准确度已经超过 95%,随着 K_N 值的不断增大,识别准确度的提高程度与 $K_N = 10$ 前相比并不明显。同时,在小样本学习的范式中,当实际有标签样本数量较少时,高准确度识别则更有提升价值。因此,考虑到现场故障信号

的稀缺性,本节后续测试将默认选择 $K_N = 10$ 作为前置分析条件。

当 $K_N = 10$ 时,所提方法(方法 1)在现场测试集中的识别准确度为 96.97%,相比方法 2—方法 7 的准确度分别提高了 6.58%、3.71%、3.22%、23.54%、27.69%、45.62%。所提方法与原型修正网络(方法 3)相比,利用近邻边界损失修正了样本的空间分布,明确了原型类别表征范围的边界,在一定程度上解决了度量空间的样本分布问题。与边界损失原型网络(方法 4)相比,原型校正分类策略在分类过程中增加了查询集数据,扩大了模型的信息量,提高了故障识别准确度。同时,结合两种方案优点的方法 1 的性能高于任何一种,证明了所提方法的应用优势。

为了进一步直观展示本文提出的基于深度特征融合的高阻故障识别方法的优势,图 10 展示不同方法的 t 分布随机邻居嵌入(t-SNE)可视化结果,其展示了测试样本在特征空间的映射分布,无量纲。由于原型网络(方法 2)的分类特性,其故障特征分布呈现出明显的聚类现象,但仍然存在分类样本混淆和叠加现象,如图 10(a)所示。原型修正网络(方法 3)结合特征偏移查询集中未标记样本的总体信息,使每个故障类别的分布更加聚类,如图 10(b)所示。边界损失原型网络(方法 4)增加了原型聚类特征点之间的距离,使故障聚类群体之间的疏离更加明显,如图 10(c)所示。本文所提方法结合了方法 3 和方法 4 的优点,更好地调整了特征的空间分布,域内距离更加集中,类间距离更加分散,如图 10(d)所示。即使对于难以分离的类别也有明显的分离效果,使得每种故障类型的特征都具有最佳的聚类分布。

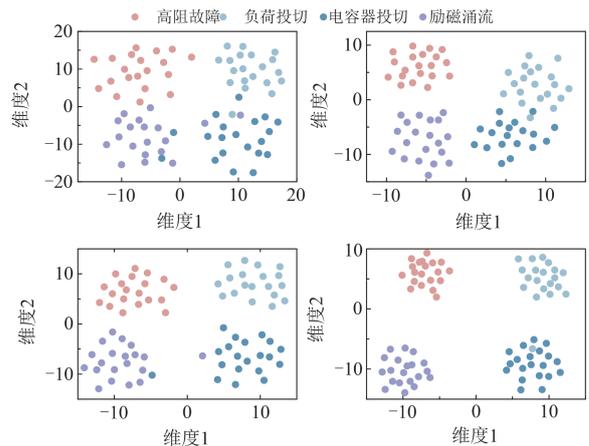


图 10 不同类型识别方法的可视化结果

Fig. 10 Visual results of different identification methods

4.2.2 特征提取方法对比分析

为了说明本文所提特征提取器的优势,本节选

择堆叠自编码器(SAE)、SAM、CNN、LRN、CNN + SAE 和 LRN + SAM 作为特征提取网络进行对比。其中, SAE 和 SAM 网络关注全局统计矩阵, CNN 和 LRN 网络聚焦于多尺度时频特征图。在特征提取网络的参数设置中, CNN、LRN 和 SAM 与本文多特征融合提取模块参数相同。

图 11 展示了不同特征提取器下的识别结果。本文所提的深度特征融合网络的识别准确度比 SAE、SAM、CNN 和 LRN 分别提高了 23.75%、20.00%、15.00%和 11.25%, 这主要是由于深度特征融合网络增强了特征提取能力, 充分融合了局部图像特征和全局统计特征, 从而提高了整体识别性能。从标准差来看, 深度特征融合网络的标准差最低。与 CNN+SAE 相比标准差减小了 0.04, 具有更强的鲁棒性, 其主要原因是通过注意力机制充分学习了输入信号的全局统计信息, 不受局部交互的限制, 同时 LRN 也在一定程度上解决了卷积核可视域有限的问题。

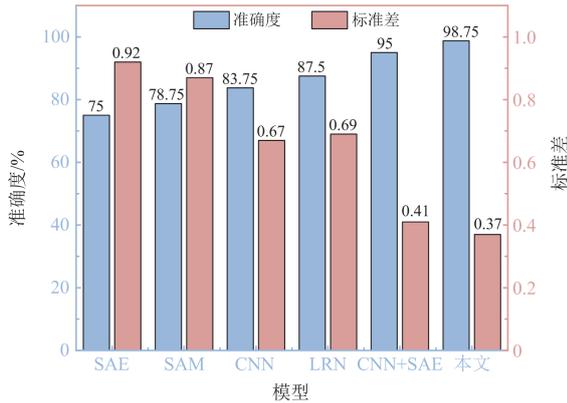


图 11 不同特征提取网络条件下的识别结果
Fig. 11 Identification results in different feature extraction networks

4.3 噪声适应性分析

为验证噪声信号对模型识别性能的影响, 在仿真测试集中选取 100 个测试样本(4 种类别各 25 个), 分别添加信噪比为 50、40、30 和 20 dB 的高斯噪声信号, 测试模型识别准确度, 测试结果如表 4 所示。

由表 4 结果可知, 在 20~50 dB 级的噪声干扰下, 模型对故障的识别准确度仍能达到较高水平, 表明噪声干扰未能对模型分类性能造成较大影响。无论是何种程度的噪声样本下, 关于负荷投切和电容器投切的错误分类最多。但是在 50 dB、40 dB 和 30 dB 噪声条件下, 所提方法均能对高阻故障进行有效识别, 准确度高达 100%。

表 4 染噪样本测试结果

Table 4 Noisy sample test result

类别	不同程度噪声条件下的样本测试结果			
	50 dB	40 dB	30 dB	20 dB
高阻故障	25/25	25/25	25/25	24/25
电容器投切	24/25	24/25	23/25	23/25
负荷投切	25/25	25/25	24/25	23/25
励磁涌流	25/25	25/25	25/25	24/25

在 20 dB 噪声条件下, 负荷投切和电容器投切的波形特征形似, 容易造成扰动工况判别错误。然而, 3 种扰动之间的误判造成的影响较小, 而对于高阻故障类别的误判产生的影响较大。尤其在噪声条件下, 高阻故障和励磁涌流工况的波形特征相似, 容易发生误判, 但是在本节的算例测试中, 20 dB 染噪条件下的 25 组高阻故障样本中仅产生了一次误判, 验证了所提方法的有效性。

4.4 系统参数适应性分析

为进一步验证所提方法在不同复杂系统的适应性^[32], 另搭建如图 12 所示的 3 馈线配电测试系统, 验证所提方法在系统参数改变时的应用效果。测试系统包含 3 条馈线, R_2 、 L_2 分别为中性点接地电阻和电感, 总电容电流为 72.770 A, 其线路具体参数如表 5 所示。

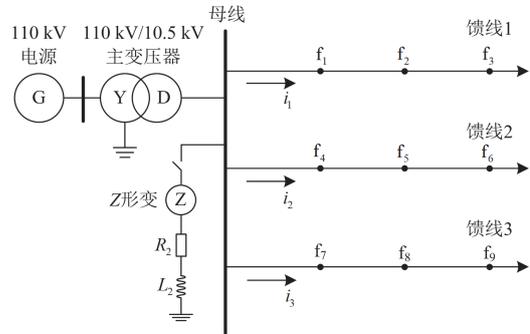


图 12 3 馈线配电测试系统拓扑结构图

Fig. 12 Topology of 3-feeder distribution test system

表 5 测试系统线路参数设置

Table 5 Line parameter setting of test system

类型	馈线 1	馈线 2	馈线 3	系统	
分布电容	$C_A/\mu\text{F}$	4.064	6.107	3.343	13.514
	$C_B/\mu\text{F}$	4.071	5.819	3.027	12.917
	$C_C/\mu\text{F}$	4.243	6.285	3.161	13.689
分布电阻	$R_A/\text{k}\Omega$	43.085	28.694	56.370	13.193
	$R_B/\text{k}\Omega$	42.974	28.694	56.306	13.179
	$R_C/\text{k}\Omega$	42.717	28.530	56.054	13.106
阻尼率/%	1.797	1.831	1.781	1.809	
不对称度/%	1.420	2.238	2.885	1.750	

在图 12 所示的仿真测试系统中,根据 9 个故障点($f_1 - f_9$)分别设置不同工况、故障初相角的高阻故障,获得 200 条高阻故障录波信息。同时,分别设置不同线路和工况参数获得电容器投切、负荷投切、励磁涌流波形数据各 200 条。为验证所提方法在小样本场景下的有效性,通过设置两种测试场景进行讨论分析。

1) 场景一:将 4 种工况波形数据在每种类别中随机抽取 180 组直接输入到识别模型中,测试结果如图 13 所示。

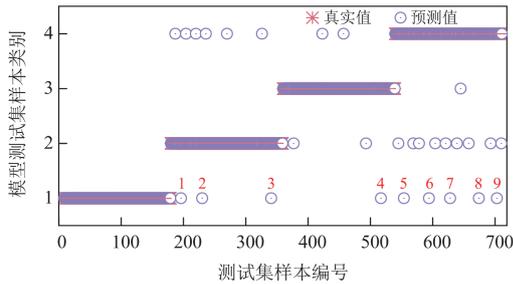


图 13 场景一条件下的模型测试结果
Fig. 13 Model test results in scenario 1

2) 场景二:将每个工况类型中的 20 条数据用于识别模型的更新,然后将场景一测试环节的 720 条数据输入到更新后的识别模型中,测试结果如图 14 所示。

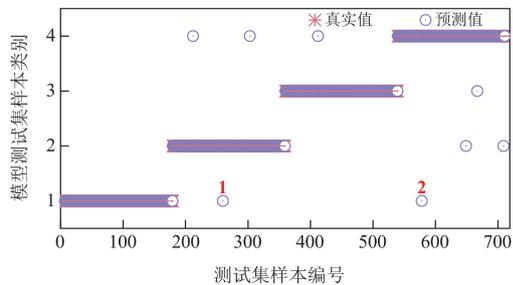


图 14 场景二条件下的模型测试结果
Fig. 14 Model test results in scenario 2

由测试结果可知,在场景一条件下,识别模型不更新直接应用到新系统的工况判断结果中有 9 次正常扰动被判定为高阻故障,其中电容器投切和励磁涌流的判定结果最易出现异常,但是未出现将高阻故障判定为其他正常工况扰动的情况。在场景二条件下,依然出现将正常工况判定为高阻故障的情形,但扰动误判为高阻故障的次数大幅度下降(仅出现 2 次),同时,场景二中电容器投切、负荷投切、励磁涌流 3 种扰动工况的测试结果也优于场景一。综合场景一和场景二的预测结果可知,该方法在不同配电网系统参数和故障条件之间具有一定适应能

力,且在有效样本对模型进行更新之后,准确度和可靠性进一步提升。

5 结论

针对基于数据驱动的故障识别方法在高阻故障情况下面临特征提取深度低、分类策略泛化性能弱和模型现场应用能力差的问题,本文提出了一种基于深度特征融合的小样本高阻故障识别方法。该方法基于高阻故障信号在离散小波分解后的时频域特征差异,设计了一种强特征表达的高阻故障识别模型,其融合现场样本的内在信息以更新故障识别策略,具有小样本条件下高阻故障识别的能力,提高了电力人工智能的泛化性能和现场应用可能。本文通过一系列仿真分析,验证了所提方法的有效性,得出以下结论。

1) 与单一局部特征和全局特征相比,深度特征融合网络在 10-shot 的诊断准确度分别提高了 26.38% 和 13.13%,验证了所提的特征提取模块可充分融合波形局部特征和全局特征,从而提升高阻故障整体识别准确度。

2) 提出的高阻故障识别方法在真型测试集上的识别准确度为 98.12%(20-shot),表明本研究中的分类策略对样本量较小的任务具有良好的分类效果。

3) 在真型测试集中,通过 t-SNE 技术对分类结果可视化,展示了所提方法在样本特征空间中分布表现更优,同类样本的聚类更加集中,不同类别样本的距离更加分散。

参考文献

[1] 王宾,崔鑫,董新洲. 配电线路弧光高阻故障检测技术综述[J]. 中国电机工程学报, 2020, 40(1): 96-107.
WANG Bin, CUI Xin, DONG Xinzhou. Overview of arc high impedance grounding fault detection technologies in distribution system[J]. Proceedings of the CSEE, 2020, 40(1): 96-107.

[2] 郑鹏,韩鹏程,王国栋,等. 中压配电线路断线高阻接地故障精细化诊断方法[J]. 中国电力, 2024, 57(4): 220-228.
ZHENG Peng, HAN Pengcheng, WANG Guodong, et al. Refined diagnosis method for disconnected high-resistance grounding faults in medium-voltage distribution lines[J]. Electric Power, 2024, 57(4): 220-228.

[3] 刘硕,刘灏,毕天姝,等. 考虑高阻接地的配电网故障检测方法[J]. 电网技术, 2023, 47(8): 3438-3448.
LIU Shuo, LIU Hao, BI Tianshu, et al. Fault detection of distribution network considering high impedance faults[J]. Power System Technology, 2023, 47(8): 3438-3448.

- [4] 王宾, 崔鑫. 基于伏安特性动态轨迹的谐振接地系统弧光高阻接地故障检测方法[J]. 中国电机工程学报, 2021, 41(20): 6959-6968.
WANG Bin, CUI Xin. Detection method of arc high resistance grounding fault in resonant grounding system based on dynamic trajectory of volt-ampere characteristic[J]. Proceedings of the CSEE, 2021, 41(20): 6959-6968.
- [5] 刘健, 陈曦子, 张志华, 等. 基于消弧线圈调制信号相关检测的高阻单相接地选线[J]. 电力系统保护与控制, 2023, 51(1): 63-70.
LIU Jian, CHEN Xizi, ZHANG Zhihua, et al. High resistance single-phase grounding line selection in resonant grounding systems based on correlation detection[J]. Power System Protection and Control, 2023, 51(1): 63-70.
- [6] 许庆强, 许扬, 周栋骥, 等. 小电阻接地配电网线路保护单相高阻接地分析[J]. 电力系统自动化, 2010, 34(9): 91-94, 115.
XU Qingqiang, XU Yang, ZHOU Dongji, et al. Analysis of distribution network line relay protection during single-phase high-resistance grounding faults in low resistance neutral grounded system[J]. Automation of Electric Power Systems, 2010, 34(9): 91-94, 115.
- [7] 任伟, 薛永端, 徐丙垠, 等. 小电阻接地系统高阻接地故障纵联差动保护[J]. 电网技术, 2021, 45(8): 3276-3282.
REN Wei, XUE Yongduan, XU Bingyin, et al. Longitudinal differential protection of high resistance grounding faults in low-resistance grounding system[J]. Power System Technology, 2021, 45(8): 3276-3282.
- [8] 韦明杰, 石访, 张恒旭, 等. 基于零序电流波形区间斜率曲线的配电网高阻接地故障检测[J]. 电力系统自动化, 2020, 44(14): 164-171.
WEI Mingjie, SHI Fang, ZHANG Hengxu, et al. Detection of high impedance grounding fault in distribution network based on interval slope curves of zero-sequence current[J]. Automation of Electric Power Systems, 2020, 44(14): 164-171.
- [9] WANG X W, GAO J, WEI X X, et al. High impedance fault detection method based on variational mode decomposition and Teager-Kaiser energy operators for distribution network[J]. IEEE Transactions on Smart Grid, 2019, 10(6): 6041-6054.
- [10] CHAITANYA B K, YADAV A, PAZOKI M. An intelligent detection of high-impedance faults for distribution lines integrated with distributed generators[J]. IEEE Systems Journal, 2020, 44(1): 870-879.
- [11] KARTIKA D, PREMALATA J. A novel high impedance fault detection technique in smart active distribution systems[J]. IEEE Transactions on Industrial Electronics, 2024, 71(5): 4861-4872.
- [12] 柳守诚, 王淳, 邹智辉, 等. 基于 t-SNE 降维和放射传播聚类算法的低压配电网相位识别[J]. 中国电力, 2023, 56(5): 108-117.
LIU Shoucheng, WANG Chun, ZOU Zhihui, et al. Phase identification of low voltage distribution network based on t-SNE dimension reduction and affinity propagation clustering algorithm[J]. Electric Power, 2023, 56(5): 108-117.
- [13] WANG Y, WANG T, LIU L. A fault segment location method for distribution networks based on spiking neural P systems and Bayesian estimation[J]. Protection and Control of Modern Power Systems, 2023, 8(3): 1-11.
- [14] 刘科研, 詹惠瑜, 谭云耀, 等. 基于改进极限学习机的配电网高阻接地故障检测方案[J]. 电网技术, 2023, 47(5): 1886-1899.
LIU Keyan, ZHAN Huiyu, TAN Yunyao, et al. High impedance grounding fault detection scheme in distribution network based on improved extreme learning machine[J]. Power System Technology, 2023, 47(5): 1886-1899.
- [15] LALA H, KARMAKAR S. Detection and experimental validation of high impedance arc fault in distribution system using empirical mode decomposition[J]. IEEE Systems Journal, 2022, 14(3): 3494-3505.
- [16] WANG S, DEGHANIAN P. On the use of artificial intelligence for high impedance fault detection and electrical safety[J]. IEEE Transactions on Industry Applications, 2020, 56(6): 7208-7216.
- [17] 史鸿飞, 邓丰, 钟航, 等. 基于暂态时-频特征差异的配电网高阻接地故障识别方法[J]. 中国电机工程学报, 2024, 44(16): 6455-6470.
SHI Hongfei, DENG Feng, ZHONG Hang, et al. Identification method of high impedance fault in distribution network based on transient time-frequency characteristic difference[J]. Proceedings of the CSEE, 2024, 44(16): 6455-6470.
- [18] GUO M, LIU W, GAO J, et al. A data-enhanced high impedance fault detection method under imbalanced sample scenarios in distribution networks[J]. IEEE Transactions on Industry Applications, 2023, 59(4): 4720-4733.
- [19] 杨耿杰, 王康, 高伟. 基于相空间重构和迁移学习的配电网高阻接地故障检测[J]. 电力系统保护与控制, 2022, 50(13): 151-162.
YANG Gengjie, WANG Kang, GAO Wei. High impedance fault detection in a distribution network based on phase space reconstruction and transfer learning[J]. Power System Protection and Control, 2022, 50(13): 151-162.
- [20] GUO M, GUO Z, GAO J, et al. High-impedance fault

- detection methodology using time-frequency spectrum and transfer convolutional neural network in distribution networks[J]. IEEE Systems Journal, 2023, 17(3): 4002-4013.
- [21] 白浩, 潘姝慧, 邵向潮, 等. 基于小波去噪与随机森林的配电网高阻接地故障半监督识别方法[J]. 电力系统保护与控制, 2022, 50(20): 79-87.
BAI Hao, PAN Shuhui, SHAO Xiangchao, et al. High impedance grounding fault semi-supervised identification method based on wavelet denoising and random forest[J]. Power System Protection and Control, 2022, 50(20): 79-87.
- [22] CUI Q, WENG Y. Enhance high impedance fault detection and location accuracy via μ -PMUs[J]. IEEE Transactions on Smart Grid, 2020, 11(1): 797-809.
- [23] 刘畅宇, 王小君, 尚博阳, 等. 基于渐进式认知发现的新型配电网故障定位方法[J]. 高电压技术, 2024, 50(3): 1156-1164.
LIU Changyu, WANG Xiaojun, SHANG Boyang, et al. Fault location method based on stepwise cognition-discovery in distribution network[J]. High Voltage Engineering, 2024, 50(3): 1156-1164.
- [24] 刘伟博. 中压配电网不同接地方式下高阻故障检测新方法研究[D]. 西安: 西安理工大学, 2023.
LIU Weibo. Research on a new method for high impedance faults detection under different grounding methods in medium voltage distribution networks[D]. Xi'an: Xi'an University of Technology, 2023.
- [25] SHI Y, XU H, ZHANG Y, et al. GAF-MAE: a self-supervised automatic modulation classification method based on Gramian angular field and masked autoencoder[J]. IEEE Transactions on Cognitive Communications and Networking, 2024, 10(1): 94-106.
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA: 770-778.
- [27] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[M]// Advances in Neural Information Processing Systems, 2017, 30: 1-11.
- [28] 柯亮, 李波, 廖凯, 等. 基于 XGBoost 的配电网高阻接地故障检测方法[J]. 电力系统保护与控制, 2024, 52(6): 88-98.
KE Liang, LI Bo, LIAO Kai, et al. High impedance fault detection method in a distribution network based on XGBoost[J]. Power System Protection and Control, 2024, 52(6): 88-98.
- [29] YAN J, WANG Y, YANG Z, et al. Few-shot mechanical fault diagnosis for a high-voltage circuit breaker via a transformer convolutional neural network and metric meta-learning[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-11.
- [30] HUANG L, YANG Q, WU J, et al. Generated data with sparse regularized multi-pseudo label for person re-identification[J]. IEEE Signal Processing Letters, 2020, 27: 391-395.
- [31] 韩延, 李超, 黄庆卿, 等. 小样本下时序注意力边界增强原型网络的齿轮箱故障诊断方法[J]. 电子测量与仪器学报, 2023, 37(2): 90-98.
HAN Yan, LI Chao, HUANG Qingqing, et al. Boundary enhanced prototype network with time-series attention for gearbox fault diagnosis under limited samples[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(2): 90-98.
- [32] 曾超, 喻锬, 曾祥君, 等. 并阻尼谐振接地系统对地参数测量与高阻故障选线新方法[J]. 电力系统保护与控制, 2024, 52(4): 67-76.
ZENG Chao, YU Kun, ZENG Xiangjun, et al. A new method for measuring ground parameters and selecting high resistance fault lines in parallel damping resonant grounding systems[J]. Power System Protection and Control, 2024, 52(4): 67-76.

收稿日期: 2024-07-09; 修回日期: 2024-10-08

作者简介:

尚博阳(1996—), 男, 博士研究生, 研究方向为配电网故障诊断与定位、人工智能在电力系统中的应用; E-mail: 75690901@qq.com

罗国敏(1983—), 女, 通信作者, 博士, 副教授, 研究方向为电力系统继电保护、人工智能在电力系统中的应用; E-mail: gmluo@bjtu.edu.cn

刘畅宇(1997—), 男, 博士研究生, 研究方向为电力系统故障诊断、人工智能在电力系统中的应用。E-mail: 21121456@bjtu.edu.cn

(编辑 张颖)