

多任务元学习网络的气体绝缘组合电器 局部放电同时诊断与定位

王艳新, 闫静, 耿英三, 刘志远, 王建华

(西安交通大学电工材料电气绝缘全国重点实验室, 710049, 西安)

摘要: 针对气体绝缘组合电器(GIS)局部放电诊断和定位作为两个独立的任务来完成而忽略了两个任务间的联系、且难以部署和泛化到现场小样本场景下的问题,提出了多任务元学习网络以同时实现现场小样本场景下的GIS局部放电诊断与定位。首先,为了充分挖掘两个任务间的关联关系并保留每一任务的差异特征,构建了多任务网络,在特定任务层引入注意力机制,为每个任务从浅到深选择重要特征,保证每一任务特征差异化提取的质量。其次,为了将所开发的多任务网络部署应用到现场小样本场景下,采用元训练的方法对模型进行训练。再次,在元测试阶段使用目标任务的少量数据进行微调,实现了小样本下GIS局部放电诊断和定位。最后,在现场样本上对模型性能进行了验证。实验结果表明,提出的多任务元学习网络在GIS局部放电诊断上的准确率达到94.53%,定位平均误差和均方根误差分别为10.78 cm和12.97 cm,与单任务网络和其他模型相比性能提升明显,为GIS局部放电诊断和定位提供了新颖的解决思路。

关键词: 局部放电;诊断;定位;多任务网络;元学习

中图分类号: TM85 **文献标志码:** A

DOI: 10.7652/xjtuxb202407010 **文章编号:** 0253-987X(2024)07-0105-11

Research on Gas-Insulated Switchgear Partial Discharge Diagnosis and Location Method Based on Multi-Task Meta-Learning

WANG Yanxin, YAN Jing, GENG Yingsan, LIU Zhiyuan, WANG Jianhua

(State Key Laboratory of Electrical Insulation and Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To address the issue where gas-insulated switchgear (GIS) partial discharge diagnosis and localization are treated as separate tasks without considering their connection and in response to challenging deployment and generalization to on-site small sample scenarios, this paper introduces a multi-task meta-learning network to simultaneously achieve GIS partial discharge diagnosis and localization in on-site small sample scenarios. Initially, a multi-task network is developed to fully explore the correlation between the two tasks while preserving their differential characteristics. An attention mechanism is introduced at specific task layers to select important features from shallow to deep levels for each task, ensuring the quality of differentiated extraction of features for each task. Subsequently, a meta-training method is adopted for model training to deploy the developed multi-task network in on-site small sample scenarios. Fine-tuning is performed using a small amount of data from the target task in the meta-testing stage, and GIS

partial discharge diagnosis and location with small samples are enabled. Finally, the model performance is verified using field samples. Experimental results demonstrate that the multi-task meta-learning network proposed in this paper shows an accuracy of 94.53% in GIS partial discharge diagnosis, with an average error in the location of 10.78 cm and a root mean square error of 12.97 cm. Exhibiting superior performance relative to the single-task network and other models, the proposed multi-task meta-learning network presents a novel solution for GIS partial discharge diagnosis and location.

Keywords: partial discharge; diagnosis; location; multi-task network; meta-learning

气体绝缘组合电器(GIS)是由断路器、隔离开关、接地开关、电流互感器、电压互感器、避雷器、母线、出线套管、电缆终端等电气元件组合而成的成套开关设备,具有占地面积小、环境适应性强、维护工作量小、运行可靠性高等优点^[1]。局部放电是在高压应力下发生在绝缘介质中部分区域的放电,而没有贯穿施加电压的导体之间^[2]。在GIS中,由于高压或接地电极上的不规则突出缺陷、游离或漂浮的金属颗粒、绝缘子表面的污染以及电极/介电界面上的间隙,都会导致局部放电发生。这些缺陷可能是由于运行过程中导体的机械磨损运动、制造过程中质量控制不严格、GIS设备运输和组装过程中的振动、未检测到的电极划伤以及不良的电接触等^[3]造成的。局部放电会引起电晕和击穿电压的降低,导致GIS绝缘性能逐渐劣化,最终造成其失效。因此,有效识别并诊断GIS中局部放电的活动并对局部放电位置进行判别对保障其可靠运行至关重要。

局部放电诊断作为识别放电类型的有效手段,是GIS状态评估的基础。局部放电定位则是验证检测有效性的必要步骤,同时又可为诊断提供详细的放电环境信息,因此在局部放电带电检测中准确定位也至关重要。为此,许多GIS局部放电诊断和定位方法得到研究和应用^[4-6]。随着人工智能的发展,以深度学习为代表的驱动方法在GIS局部放电诊断和定位领域取得了长足的发展,尤其是卷积神经网络、长短时记忆网络以及自编码器等在该领域取得显著成效^[7-8]。

然而,现有研究均是GIS局部放电诊断和定位作为两个独立任务,存在不足之处:一方面忽略了两个任务间的关联关系,导致模型性能难以进一步提升;另一方面将二者作为两个独立任务开发模型造成了更大的开销。多任务学习作为深度学习的一个重要分支,因能够挖掘任务间的耦合关系,在负荷预测^[9]、机械设备状态预测与健康管理等^[10-11]等多个领域取得了令人满意的性能。

另外,如何将所开发的模型部署和泛化到现场小样本场景也是亟待解决的问题。尽管分别以生成对抗网络^[12]和迁移学习^[13]为核心的方法被引入到小样本学习问题中,但目标样本的数量仍然是模型取得优异性能的关键,导致二者对样本量的依赖问题未从根源上解决。元学习作为一种新颖的机器学习范式^[14],通过学习本身能够适应或泛化到训练期间从未遇到过的新任务和新环境,近年来在小样本局部放电诊断^[15]、故障诊断^[16-17]等领域被广泛的研究。

受启发于多任务学习和元学习,本文提出了多任务元学习网络以同时实现现场小样本场景下的GIS局部放电诊断与定位。为了充分挖掘GIS局部放电诊断和定位间的关联关系,并学习每一任务的差异化特征来提升其性能,本文构建了新颖的多任务网络结构。在网络结构中引入注意力机制,提升模型对GIS局部放电诊断和定位可鉴别特征的提取。为了将所开发的模型部署和泛化到小样本场景下,本文引入元学习策略。利用A-way K-shot的训练模式,从元训练集中获得局部放电诊断和定位知识,通过元测试集对初始参数进行微调即可实现小样本下GIS局部放电诊断和定位。在现场小样本场景下,所提出的多任务元学习网络能够同时实现高精度的GIS局部放电诊断与定位。

1 多任务元学习网络

1.1 用于局部放电诊断与定位的多任务网络

人类能够同时学习多个任务,并且利用其他相关任务中包含的有用知识来帮助另一个任务更好地学习。受人类这种学习能力的启发,提出了多任务学习,目的是共同学习多个相关的任务,从而利用其他任务中包含的信息来帮助每个任务的学习^[18],在充分挖掘局部放电诊断和定位关联关系的同时,提升局部放电诊断和定位每一任务的性能。

图1给出了单任务网络和多任务网络的结构

图。图 1(a)中两个独立的网络分别用于局部放电诊断和定位,称为单任务学习。由于它们之间没有联系,所以每个网络的特征不能被共享或用来帮助学习另一个网络。图 1(b)给出了一个具有两个输出的网络,每个输出对应于图 1(a)中的一个任务。值得注意的是,这些输出可以连接它们共享的隐藏层中的所有神经元。然后,在共享隐藏层之后构建独立的子网,并分别训练相应的参数。由于底层与两个任务共享,因此一个任务的特征表示也可以被其他任务使用,从而挖掘两个任务间的关联关系,提升每一任务的性能。




图 1 单任务网络和多任务网络的结构

Fig. 1 The structure of single-task and multi-task networks

为了充分挖掘两个任务间的关联关系并保留每一任务的差异特征,实现 GIS 局部放电高精度、高鲁棒的诊断和定位,本文构建的多任务网络具体结构如图 2 所示,主要由任务共享层和特定任务层两个部分组成。其中任务共享层旨在从输入信号中学习丰富的任务共享特征,从而挖掘局部放电诊断和定位两个任务的关联关系。特定任务层从任务共享层学习到的特征中学习每一任务相关的特征,从而保留每一任务的特征差异。

1.1.1 任务共享层

共享特征在任务共享层的不同深度特征映射中进行编码,以学习局部放电诊断和定位任务的共享特征。然后,每个特定任务层中的一组注意力模块与任务共享层连接,以学习特定任务的特征。通过这种方式,每个注意力模块^[19]都充当任务共享层的特征选择器,并允许以端到端的方式学习特定任务的特征,而任务共享层则学习一个紧凑的全局特征。考虑到局部放电定位对时间特征的依赖性,本文选择一维卷积神经网络作为基准网络来挖掘局部放电信号中的时间细粒度信息。如图 2 所示,本文构建了一个由 6 个卷积块组成的轻量级任务共享层。每个卷积块包含 3 层:一维卷积层,批量归一化层和激

活函数^[20]。批量归一化层用于加速训练并减少由每层输入的不同分布引起的内部协变量偏移。

1.1.2 特定任务层

特定任务层以任务共享层提取的共享特征为输入,进一步挖掘每一任务的差异特征,实现 GIS 局部放电诊断与定位。每个特定任务层包含 3 个注意力模块、3 个最大池化层、3 个 1×1 卷积层组成。3 个注意力模块在 3 个位置链接到任务共享层的不同深度,自动为每个任务从浅到深选择重要特征。 1×1 卷积层用于增加通道数以匹配任务共享特征的通道数,然后再送入下一个注意力模块。




图 2 本文所构建的多任务网络

Fig. 2 Multi-task network constructed

对注意力模块^[21],假设注意力的输入是 $x_i \in \mathbf{R}^{C \times W}$ 。首先,每个通道的全局空间信息被全局平均层压缩为标量,计算过程如下

$$z_i = \frac{1}{W} \left[\sum_{k=1}^W x_i(x, k) \right]_{c=1}^C \quad (1)$$

式中: $x_i(x, k)$ 表示 $x \in \mathbf{R}^{C \times W}$ 的第 c 个通道中的第 k 个元素; $z_i \in \mathbf{R}^{C \times 1}$ 表示压缩后的数据。然后构建卷积层和 sigmoid 激活函数,捕获局部跨通道交互,得到 $0 \sim 1$ 范围内的权向量 $\omega \in \mathbf{R}^{C \times 1}$ 。sigmoid 激活函数定义为

$$f_{\text{sig}} = \frac{1}{1 + e^{-x}} \quad (2)$$

为了避免权重过小以更好地传递信息,本文增加了一个快捷连接,将 ω 增加到 $1 \sim 2$ 范围内。注意力模块的最终输出为 $y_i = x_i \otimes \omega + x_i$, 其中 $\otimes$ 表示逐元素乘法。

1.2 多任务元学习网络训练过程

本文提出多任务元学习网络实现 GIS 局部放电诊断与定位,其目标由两个部分组成。其中局部放电诊断任务为多标签分类任务,可通过交叉熵损失函数 l_1 进行优化^[22],计算公式如下

$$l_1 = -\frac{1}{N} \sum_{i=1}^N (y_i \log p_i + (1 - y_i) \log(1 - p_i)) \quad (3)$$

式中: y_i 和 p_i 分别表示期望和预测概率; N 为训练样本数。

局部放电定位任务可视为回归问题,可采用此均方差损失^[23]优化此任务,损失函数 l_2 可表示如下

$$l_2 = \frac{1}{N} \sum_{i=1}^N \|\hat{y}_i - y_i\|^2 \quad (4)$$

式中: $\hat{y}_i$ 和 y_i 分别为第 i 个样本的预测值和真实值。

为此本文提出的多任务网络的损失函数可由上述两个任务的损失函数联合得到。考虑到局部放电诊断和定位任务的数据分布和重要性存在差异,多任务网络损失值计算如下

$$L_{\text{MTL}} = \lambda_1 l_1 + \lambda_2 l_2 \quad (5)$$

式中: L_{MTL} 为多任务学习模型损失; λ_1 和 λ_2 为平衡因子。

为了将所开发的多任务网络部署应用到现场小样本场景下,本文采用元训练的方法对模型进行训练。模型无关元学习(MAML)作为一种小样本学习范式,可以很好地适应和泛化到训练期间从未遇到过的新任务和新环境^[24]。MAML 采用 A-way K-shot 的训练模式,可自适应选择最优的初始化参数,进而使用这些参数快速调整模型以适应数据量较少的新任务。MAML 分为两个阶段:元学习和元测试。在元学习阶段,从构建的学习任务中获得局部放电诊断和定位知识,并作为初始参数 θ 嵌入到基于多任务网络的 GIS 局部放电诊断和定位模型中。在元测试阶段,使用目标任务的少量数据对初始参数 θ 进行微调。最后,通过微调模型实现小样本下 GIS 局部放电诊断和定位。

图 3 为 MAML 算法示意图,其在元学习阶段对初始参数进行优化,在元测试阶段对新的目标任务进行微调,图中 T_i 为任务集中的第 i 个任务。初始参数在元学习阶段更新两次,一次在内部循环,一次在外部循环。在内部循环中,使用从构建的学习任务中训练基于多任务网络的 GIS 局部放电诊断和定位模型。在外部循环中,使用几个不同的样本为每个任务验证训练好的多任务网络,以提供关于模型泛化性能的反

馈,从而更新初始参数。

在内循环结构中,MAML 的参数更新^[25]过程如下

$$\theta' = \theta - \alpha \nabla_{\theta} L_{\text{MTL}_i}(f_{\theta}) \quad (6)$$

式中: θ 为在该任务上更新得到的最优参数; α 为内循环网络的学习率; f_{θ} 为参数 θ 的内循环网络结构; L_{MTL_i} 为某一具体任务上的损失; $\nabla_{\theta} L_{\text{MTL}_i}(f_{\theta})$ 为损失梯度。




图 3 MAML 算法示意图

Fig. 3 Schematic diagram of MAML algorithm

在外循环结构中,MAML 算法要求对新任务能够快速适应。因此,要求最优参数 θ 对所有不同任务的损失误差最小,具体形式如下

$$\min_{\theta} \sum_{T_i \sim p(T)} L_{\text{MTL}_i}(f_{\theta_i}) = \sum_{T_i \sim p(T)} L_{\text{MTL}_i} f(\theta - \alpha \nabla_{\theta} L_{\text{MTL}_i}(f_{\theta})) \quad (7)$$

式中: $p(T)$ 为任务集的分布。

最后,MAML 算法通过随机梯度下降法即可完成参数 θ 的更新,其过程如下

$$\theta = \theta - \beta \nabla_{\theta} \sum_{T_i \sim p(T)} L_{\text{MTL}_i}(f_{\theta_i}) \quad (8)$$

式中: β 为元学习器的学习率。

1.3 GIS 局部放电诊断与定位流程

本文提出的多任务元学习网络以多任务网络为基准模型,在挖掘两个任务耦合关系的同时保留每一任务的差异,实现 GIS 局部放电高精度、高鲁棒诊断与定位。同时以元训练的方式,将开发的多任务网络部署应用到小样本场景,尤其是现场数据匮乏的场景。整个模型以局部放电信号为输入,对于局部放电诊断而言,模型输出是所属局部放电类型的概率;对局部放电定位而言,模型输出是坐标值,即局部放电位置的空间坐标。本文所构建的多任务元学习网络的 GIS 局部放电诊断与定位流程如图 4

所示,具体过程如下。

(1)数据集划分:构建元训练集和元测试集。本文将实验模拟法和理论模拟法得到的数据集作为元训练集,将含有少量样本的现场数据集作为元测试集。然后,依据 A-way K-shot 的方式,分别将元训练集和元测试集划分为支撑集和查询集。

(2)多任务网络构建:构建本文提出的多任务网

络,两个任务分别用于 GIS 局部放电诊断和定位。

(3)元学习和元测试:在元学习阶段,从元训练集中获得局部放电诊断和定位知识,并作为初始参数,嵌入到基于多任务网络的 GIS 局部放电诊断和定位模型中。在元测试阶段,使用元测试集对初始参数进行微调。最后,通过微调模型实现小样本下 GIS 局部放电诊断和定位。




图 4 多任务元学习网络的 GIS 局部放电诊断与定位流程

Fig. 4 GIS partial discharge diagnosis and localization flowchart based on multi-task meta-learning network

2 案例分析

2.1 局部放电数据集构建

本文所提出的多任务元学习网络以元训练集辅助实现现场小样本场景下的局部放电诊断和定位。为获得能够学习局部放电诊断和定位知识的元训练集,本文构建了局部放电仿真样本集和实验样本集作为元训练集。对局部放电仿真样本集,采用时域有限差分法,模拟 GIS 局部放电过程,并获取不同类型和位置的局部放电信号^[26]。仿真模型如图 5 所示。腔体两端设置为金属封闭层,使其更加接近

实际腔体金属封闭结构。为模拟实际测试中传感器检测特高频信号,在绝缘子的浇注孔处设置探针作为观测点,探针内阻为 50 Ω,剖分单元为 6 mm×6 mm×6 mm,仿真时间步长为 19.23 ps,总仿真时间为 192.28 ns。仿真过程中模拟了 GIS 设备中 4 种常见的典型绝缘缺陷,分别为金属尖端缺陷、自由金属微粒缺陷、沿面放电和悬浮电极缺陷。不同缺陷类型下的局部放电样本如图 6 所示。最终获取每一缺陷在不同位置的 500 组数据并构建仿真样本集。本文选择如图 5 所示的参考坐标为原点,而后获取整个 GIS 腔体内不同坐标数据以完成 GIS 局部放电定位。




图 5 本文 GIS 仿真模型

Fig. 5 GIS simulation model




图 6 不同缺陷类型下的局部放电样本

Fig. 6 Partial discharge samples for different defect types

为获得足够的局部放电实验样本用于训练模型,本文在实验室搭建了一个 252 kV GIS 局部放电实验平台,如图 7 所示。由额定容量为 $100 \text{ kV} \cdot \text{A}$ 、额定电压为 252 kV 的无晕工频实验变压器进行供电。将 4 个局部放电 U-G2 特高频传感器安装到盆式绝缘子处以检测局部放电信号,频率范围为 $0.3 \sim 1.5 \text{ GHz}$,增益大于等于 20 dB。采用 WavePro 254HD 四通道数字示波器采集局部放电信号,该示波器采样带宽 2 GHz,最大采样率 $20 \times 10^9 / \text{s}$ 。实验中,通过改变缺陷模型位置来模拟不同位置的放电,将缺陷模型中心处记为局部放电的实际位置。除沿面放电缺陷外,其他 3 类缺陷模型均固定在绝缘支架上。此支架可伸缩,为此可通过移动支架位置并改变支架的伸缩模拟不同位置的局部放电。具体而言,首先固定支架位置,然后伸缩支架 6 次,记录每一次缺陷的具体位置并进行局部放电实验,保存相应的局部放电信号。然后改变支架的固定位置,重复上述工作多次,即可获取多组组局部放电信号。对沿面放电而言,首先选择不同的盆式绝缘子进行

实验,然后在每一盆式绝缘子上改变缺陷具体位置来获取局部放电样本。随机选择某一局部放电源位置下 4 个特高频传感器检测到的局部放电信号,如图 8 所示,最终获取每一缺陷在不同位置的 300 组数据构建实验样本集。






图 7 局部放电实验平台原理图


Fig. 7 Experimental wiring schematic diagram




(a) 传感器 1



(b) 传感器 2



(c) 传感器 3



(d) 传感器 4

图 8 4 个特高频传感器检测到的局部放电信号

Fig. 8 Partial discharge signals detected by four UHF sensors

元测试集为最终要实现的现场小样本场景下的 GIS 局部放电样本。现场数据来源于某电力公司多年来运行检修积累的数据,以及对多台长期运行的 GIS 进行测试所获得的数据。为获取 GIS 局部放电现场样本,该电力公司关注挂网运行多年且检测到局部放电的 GIS,加强监测并获取了从局部放电出现到停电检修的整个周期内的运行数据。最终获取每一缺陷在不同位置下的 50 组数据作为元测试集。

2.2 实验设置

本文所有方法都是在硬件环境为 Intel 10700F、NVIDIA RTX 3080Ti、32 GB RAM 的计算机上实现的。此外,所有模型都是基于 Python 3.8、Pytorch 1.8.1 和 CUDA 10.2 构建的。采用动量为 0.9、权重衰减为 5×10^{-4} 的随机梯度下降优化器进行参数更新。平衡因子 λ_1 和 λ_2 在 $[0.1, 1]$ 中凭经验搜索以获得最佳结果,迭代次数和批量大小分别设置为 120 和 32,初始学习率为 0.01。在元训练和元测试中,支撑集与查询集的划分比例分别为 8:2 和 1:1。本文中的所有结果均为通过 15 次实验进行平均获得,以减少随机性误差带来的影响。为评估本文方法在 GIS 局部放电诊断和定位上的性能,选择诊断准确率、定位平均误差和均方根误差作为评价指标。

为验证本文提出的多任务元学习网络(MTMLN)在 GIS 局部放电诊断与定位上的优势,选择了如下方法进行对比实验。

(1)单任务学习网络(STLN):网络的特征提取器结构与本文相同,区别在于将局部放电诊断与定位作为两个独立的任务进行。为保证公平与客观性,训练也采用元学习的方法。

(2)直接训练(DT):网络基本结构与本文相同,差别仅在于采用传统方法直接训练。

(3)域适应多任务学习网络(DAMLN):网络基本结构与本文相同,差别仅在于采用域适应迁移学习进行训练。

(4)特定任务层无注意力模块(TLWAM):网络结构中在特定任务层中去掉注意力模块,其他部分和训练过程与本文相同。

(5)联合损失卷积神经网络(JLCNN):特征提取器和训练方法与本文方法相同,其余部分与文献[27]相同。

2.3 结果与分析

首先,本文研究不同元训练集对现场小样本 GIS 局部放电诊断和定位的影响。为此,本文分别将仿真样本、实验样本和仿真+实验样本作为元训练集进行实验,结果如表 1 所示。从表 1 可以看出,以仿真加实验样本作为元训练集的 GIS 局部放电诊断精度最高,定位平均误差和均方根误差最低。以仿真样本作为元训练集的诊断精度低于以实验样本作为元训练集,定位平均误差和均方根误差高于以实验样本作为元训练集。主要原因是,理想化的仿真样本相对于实验样本而言未考虑运行条件和背景噪声的影响,所学到的辅助知识与现场差异更大。另外,将仿真+实验样本作为元训练集能够学习更多的辅助知识,同时样本数量更大,其代表性和全面性更强,从而提升了现场小样本下的 GIS 局部放电诊断精度,降低了定位误差。另外,从表 1 可以看出,随着支撑集样本数量的增加,MTMLN 方法的诊断精度均有提升,定位平均误差和均方根误差均有所降低。但是,当支撑集样本数量达到 10 后,诊断精度的增加变得平缓,定位平均误差和均方根误差的降低也不再明显。考虑到现场样本稀缺,本文后续均选择支撑集样本数为 10 进行分析。

表 1 不同元训练集下现场小样本 GIS 局部放电诊断和定位结果
Table 1 Diagnosis and localization results of small-sample GIS partial discharge in the field under different meta-training sets

样本数量	仿真样本			实验样本			仿真+实验样本		
	精度/%	平均 误差/cm	均方根 误差/cm	精度/%	平均 误差/cm	均方根 误差/cm	精度/%	平均 误差/cm	均方根 误差/cm
1	52.63	21.36	25.61	54.56	20.92	25.24	55.05	20.45	25.03
3	69.25	18.25	22.42	70.68	17.98	22.05	71.26	17.51	21.87
5	81.36	14.03	17.86	82.85	13.43	17.03	83.09	13.12	16.74
10	93.38	11.23	13.52	94.16	10.93	13.15	94.53	10.78	12.97
15	93.52	11.15	13.42	94.31	10.85	13.08	94.76	10.67	12.89
20	93.67	11.02	13.35	94.52	10.79	13.01	94.83	10.60	12.78

表 2 给出了不同方法的现场 GIS 局部放电诊断和定位结果。从表 2 中可以看出,本文 MTMLN 方法的诊断精度达到了 94.53%,定位平均误差和均方根误差分别为 10.78 cm 和 12.97 cm。相比于 STLN 诊断精度提升了 4.97%,定位平均误差降低了 3.78 cm,均方根误差降低了 4.35 cm。可以看出,本文方法在挖掘局部放电诊断与定位两个任务的耦合关系的同时,能够提升 GIS 局部放电诊断和定位两个任务的性能。另外,相对于 GIS 局部放电诊断而言,多任务网络在 GIS 局部放电定位上的性能提升更为明显,可见多任务网络提出的必要性。

从不同训练方法的角度来看,与 DT 方法相比,MTMLN 方法的诊断精度提升了 58.28%,定位平均误差降低了 10.27 cm,均方根误差降低了 11.66 cm。此时,DT 方法难以实现现场小样本 GIS 局部放电诊断和定位,这主要和深度模型的训练需要充足的样本有关。与 DAMLN 方法相比,MTMLN 方法的诊断精度提升了 14.9%,定位平均误差降低了 7.67 cm,均方根误差降低了 8.22 cm。尽管 DAMLN 方法的诊断和定位性能相对于 DT 方法均有少许提升,但是仍无法满足现场应用要求。主要原因是,域适应训练方法在训练过程中尽管降低了对目标域样本数量的需求,但是相对于元学习而言其样本需求量依然较大。

表 2 不同方法的 GIS 局部放电诊断和定位结果
Table 2 Diagnosis and localization results of GIS partial discharge by different methods

方法	定位结果		
	诊断精度/%	平均误差/cm	均方根误差/cm
STLN	89.56	14.56	17.32
DT	36.25	21.05	24.63
DAMLN	79.63	18.45	21.19
TLWAM	92.86	12.01	14.15
JLCNN	92.05	12.27	14.68
MTMLN	94.53	10.78	12.97

另外,从不同的多任务网络对比来看,与 JLCNN 方法相比,MTMLN 方法的诊断精度提升了 2.48%,定位平均误差降低了 1.49 cm,均方根误差降低了 1.71 cm。由于 JLCNN 方法中没有特定任务层,而是将任务共享层提取的特征直接进行诊断和定位,忽略了两个任务的差异化提取,导致模型性能下降。与 TLWAM 方法相比,MTMLN 方法的诊断精度提升了 1.67%,定位平均误差降低了 1.23 cm,

均方根误差降低了 1.18 cm。可见,在特定任务层将 3 个注意力模块在 3 个位置链接到任务共享层的不同深度,自动为每个任务从浅到深选择重要特征,有效提升了整个模型的性能。

为了进一步验证不同方法在 GIS 局部放电诊断上的性能,图 9 给出了不同方法的混淆矩阵。从混淆矩阵中可以看出,相比于其他方法,本文提出的 MTMLN 方法提升了在每一类缺陷上的诊断精度。另外,所有方法在沿面放电的诊断精度最低,在悬浮放电上的诊断精度最高,这与放电机理相关^[9]。图 10 给出了不同方法的二维特征可视化结果,可以看出,相比于 DT 方法,尽管 DAMLN 方法能够拉近异类样本,拉近同类样本,但是不同类别间的混叠依然严重。相比于 STLN 方法,本文 MTMLN 方法在拉近同类样本的同时,尽可能使得异类样本远离,分类边界更加清晰。这进一步看出多任务网络在 GIS 局部放电诊断上的优势。





图 9 不同方法的混淆矩阵

Fig. 9 Confusion matrix for different methods






图 10 不同方法的二维特征可视化结果

Fig. 10 Two-dimensional feature visualization results of different methods

图 11 给出不同方法在现场 GIS 局部放电定位上的累积概率密度。由图可以看出,MTMLN 方法在误差 10 cm 的累积概率密度可达 93%,相比于其他方法有明显提升。与 STLN 方法相比,MTMLN 方法的累积概率密度曲线一直高于 STLN 方法,可见通过挖掘局部放电诊断与定位两个任务的耦合关系能够有效提升 GIS 局部放电定位的精度。与 JLCNN 方法和 TLWAM 方法相比,MTMLN 方法的累积概率密度曲线也一直高于这两种方法,可见除了挖掘两个任务的耦合关系外,在特定任务层中挖掘每个任务的差异化特征也是提升多任务网络性能的关键。




图 11 不同方法在 GIS 局部放电定位上的累积概率密度

Fig. 11 Cumulative probability density of different methods on GIS partial discharge location

表 3 给出了 6 种方法不同缺陷类型下的 GIS 局部放电定位结果。可以看出,在所有方法中,沿面放电的平均误差和均方根误差最低。这主要是沿面放电仅发生在盆式绝缘子上,此时缺陷位置在 x 轴上坐标跨度小,从而导致其具有更小的平均误差和均方根误差。同时,自由金属微粒的平均误差和均方根误差要略高于其他缺陷。这主要和微粒的运动有关,当施加电压时微粒的跳动会影响位置的判断。另外,金属尖端和悬浮电极缺陷的定位平均误差和均方根误差的规律相近。可见,GIS 局部放电位置与缺陷类型之间存在着联系。

表 3 6 种方法不同缺陷类型下的 GIS 局部放电定位结果

Table 3 GIS partial discharge localization results for different defect types at 6 methods

方法	金属尖端		自由金属微粒		沿面放电		悬浮电极	
	平均 误差/cm	均方根 误差/cm	平均 误差/cm	均方根 误差/cm	平均 误差/cm	均方根 误差/cm	平均 误差/cm	均方根 误差/cm
STLN	14.63	17.39	13.98	16.75	15.02	17.73	14.61	17.41
DT	21.11	24.75	20.73	24.21	21.15	24.84	21.21	24.72
DAMLN	18.59	21.33	17.95	20.65	18.74	21.42	18.52	21.36
TLWAM	12.15	14.25	11.42	13.8	12.36	14.34	12.11	14.21
JLCNN	12.37	14.85	11.91	14.09	12.42	14.95	12.38	14.83
MTMLN	10.91	13.16	10.27	12.3	11.05	13.29	10.89	13.13

3 结 论

(1)提出了多任务网络实现 GIS 局部放电高精度诊断和定位。所提出的双任务网络能够充分挖掘两个任务间的关联关系并保留每一任务的差异特征,在 GIS 局部放电诊断上的准确率达到 94.53%,定位平均误差和均方根误差分别为 10.78 cm 和 12.97 cm。与单任务网络相比性能提升明显,为

GIS 局部放电诊断和定位提供了新颖的解决思路。

(2)提出了元训练的方式,将开发的多任务网络部署应用到现场数据匮乏的场景。与直接训练和域适应训练相比,在支撑集数量为 10 时便可实现满意的诊断精度和定位性能。在 GIS 局部放电诊断上,相比于直接训练将所有样本混叠在一起,元训练能够在拉近同类样本的同时,尽可能使得异类样本远离,分类边界更加清晰。

(3)探究了元训练集对模型性能的影响,确定了元训练集的选取原则。不仅元训练集样本的全面性和代表性是限制模型性能的重要因素,而且元训练集与元测试集间的分布差异也是影响模型性能的重要指标。以仿真样本作为元训练集,由于理想化的仿真样本相比于实验样本而言,未考虑运行条件和背景噪声的影响,所学到的辅助知识与现场差异比实验样本集更大,导致其诊断和定位性能不如实验样本集。以仿真+实验样本作为元训练集的 GIS 局部放电诊断和定位性能最好。

参考文献:

- [1] 宋颜峰, 郑中原, 于金山, 等. 机-电联合作用下 SF₆ 气体中金属微粒运动行为与局部放电特性研究 [J]. 西安交通大学学报, 2023, 57(7): 74-83.
SONG Yanfeng, ZHENG Zhongyuan, YU Jinshan, et al. Study on the motion behavior and partial discharge characteristics of metal particles in SF₆ gas under the combined action of mechanical and electrical [J]. Journal of Xi'an Jiaotong University, 2023, 57(7): 74-83.
- [2] 唐炬, 杨东, 曾福平, 等. 基于分解组分分析的 SF₆ 设备绝缘故障诊断方法与技术的研究现状 [J]. 电工技术学报, 2016, 31(20): 41-54.
TANG Ju, YANG Dong, ZENG Fuping, et al. Research status of SF₆ insulation equipment fault diagnosis method and technology based on decomposed components analysis [J]. Transactions of China Electrotechnical Society, 2016, 31(20): 41-54.
- [3] KHAN Q, REFAAT S S, ABU-RUB H, et al. Partial discharge detection and diagnosis in gas insulated switchgear: state of the art [J]. IEEE Electrical Insulation Magazine, 2019, 35(4): 16-33.
- [4] 王艳新, 闫静, 王建华, 等. 基于多级二阶注意力孪生网络的小样本 GIS 局部放电诊断方法 [J]. 电工技术学报, 2023, 38(8): 2255-2264.
WANG Yanxin, YAN Jing, WANG Jianhua, et al. Few-shot partial discharge diagnosis for gas-insulated switchgear using a novel multi-level second-order attention Siamese network [J]. Transactions of China Electrotechnical Society, 2023, 38(8): 2255-2264.
- [5] 陈轩, 王立宪, 朱超, 等. 基于振动信号的气体绝缘金属封闭输电线路局部放电诊断方法 [J]. 电气技术, 2021, 22(12): 34-39.
CHEN Xuan, WANG Lixian, ZHU Chao, et al. Partial discharge diagnosis method of gas insulated transmission line based on vibration signal [J]. Electrical Engineering, 2021, 22(12): 34-39.
- [6] WANG Yanxin, YAN Jing, YANG Zhou, et al. Deep domain-invariant long short-term memory network for partial discharge localization in gas-insulated switchgear [J]. IEEE Transactions on Power Delivery, 2023, 38(4): 2810-2820.
- [7] WANG Yanxin, YAN Jing, YANG Zhou, et al. A domain adaptive deep transfer learning method for gas-insulated switchgear partial discharge diagnosis [J]. IEEE Transactions on Power Delivery, 2022, 37(4): 2514-2523.
- [8] 张翼, 朱永利. 基于深度-广度联合剪枝的电力设备局部放电轻量化诊断方法 [J]. 电工技术学报, 2023, 38(7): 1935-1945.
ZHANG Yi, ZHU Yongli. A lightweight partial discharge diagnosis method of power equipment based on depth-width joint pruning [J]. Transactions of China Electrotechnical Society, 2023, 38(7): 1935-1945.
- [9] 吴晨, 姚菁, 薛贵元, 等. 基于 MMoE 多任务学习和长短时记忆网络的综合能源系统负荷预测 [J]. 电力自动化设备, 2022, 42(7): 33-39.
WU Chen, YAO Jing, XUE Guiyuan, et al. Load forecasting of integrated energy system based on MMoE multi-task learning and LSTM [J]. Electric Power Automation Equipment, 2022, 42(7): 33-39.
- [10] ZHANG Yong, XIN Yuqi, LIU Zhiwei, et al. Health status assessment and remaining useful life prediction of aero-engine based on BiGRU and MMoE [J]. Reliability Engineering & System Safety, 2022, 220: 108263.
- [11] YAN Jianhai, HE Zhen, HE Shuguang. Multitask learning of health state assessment and remaining useful life prediction for sensor-equipped machines [J]. Reliability Engineering & System Safety, 2023, 234: 109141.
- [12] WANG Yanxin, YAN Jing, YANG Zhou, et al. GAN and CNN for imbalanced partial discharge pattern recognition in GIS [J]. High Voltage, 2022, 7(3): 452-460.
- [13] 杨为, 朱太云, 张国宝, 等. 电力物联网下基于卷积神经网络和迁移学习的 GIS 局部放电模式识别分类方法研究 [J]. 高压电器, 2020, 56(9): 20-25.
YANG Wei, ZHU Taiyun, ZHANG Guobao, et al. Research on partial discharge pattern recognition and classification in GIS based on convolutional neural network and transfer learning in power internet of things [J]. High Voltage Apparatus, 2020, 56(9): 20-25.
- [14] 刘颖, 雷研博, 范九伦, 等. 基于小样本学习的图像分类技术综述 [J]. 自动化学报, 2021, 47(2): 297-315.
LIU Ying, LEI Yanbo, FAN Jiulun, et al. Survey on

- image classification technology based on small sample learning [J]. *Acta Automatica Sinica*, 2021, 47(2): 297-315.
- [15] WANG Yanxin, YAN Jing, YANG Zhou, et al. Novel metric-based meta-learning model for few-shot diagnosis of partial discharge in a gas-insulated switchgear [J]. *ISA Transactions*, 2023, 134: 268-277.
- [16] 王艳新, 闫静, 王建华, 等. 基于特征融合度量学习的高压断路器机械故障诊断 [J]. *仪器仪表学报*, 2022, 43(9): 98-105.
- WANG Yanxin, YAN Jing, WANG Jianhua, et al. Mechanical fault diagnosis for high voltage circuit breaker via a novel feature fusion metric learning [J]. *Chinese Journal of Scientific Instrument*, 2022, 43(9): 98-105.
- [17] ZHANG Shen, YE Fei, WANG Bingnan, et al. Few-shot bearing fault diagnosis based on model-agnostic meta-learning [J]. *IEEE Transactions on Industry Applications*, 2021, 57(5): 4754-4764.
- [18] 邓旭晖, 陈中, 杨凯, 等. 基于多任务学习卷积网络的非侵入式负荷监测方法 [J]. *电力系统自动化*, 2023, 47(8): 189-197.
- DENG Xuhui, CHEN Zhong, YANG Kai, et al. Non-intrusive load monitoring method based on multi-task learning convolutional network [J]. *Automation of Electric Power Systems*, 2023, 47(8): 189-197.
- [19] XIE Zongliang, CHEN Jinglong, FENG Yong, et al. End to end multi-task learning with attention for multi-objective fault diagnosis under small sample [J]. *Journal of Manufacturing Systems*, 2022, 62: 301-316.
- [20] LI Yang, KAZEMEINI A, MEHTA Y, et al. Multi-task learning for emotion and personality traits detection [J]. *Neurocomputing*, 2022, 493: 340-350.
- [21] 王照伟, 刘传帅, 赵文祥, 等. 多尺度多任务注意力卷积神经网络滚动轴承故障诊断方法 [J/OL]. *电机与控制学报*: 1-12[2023-10-22]. <http://kns.cnki.net/kcms/detail/23.1408.tm.20230524.1025.018.html>.
- WANG Zhaowei, LIU Chuanshuai, ZHAO Wenxiang, et al. Rolling bearing fault diagnosis with multi-scale multi-task attention convolutional neural network [J/OL]. *Electric Machines and Control*: 1-12 [2023-10-22]. <http://kns.cnki.net/kcms/detail/23.1408.tm.20230524.1025.018.html>.
- [22] BHUKYA A, KOLEY C. Bi-long short-term memory networks for radio frequency based arrival time detection of partial discharge signals [J]. *IEEE Transactions on Power Delivery*, 2022, 37(3): 2024-2031.
- [23] BOSMAN A S, ENGELBRECHT A, HELBIG M. Visualising basins of attraction for the cross-entropy and the squared error neural network loss functions [J]. *Neurocomputing*, 2020, 400: 113-136.
- [24] CHEN Jianjun, HU Weihao, CAO Di, et al. A meta-learning method for electric machine bearing fault diagnosis under varying working conditions with limited data [J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(3): 2552-2564.
- [25] WANG Yanxin, YAN Jing, YANG Zhou, et al. A novel hybrid meta-learning for few-shot gas-insulated switchgear insulation defect diagnosis [J]. *Expert Systems with Applications*, 2023, 233: 120956.
- [26] 王艳新, 闫静, 王建华, 等. 基于域对抗迁移卷积神经网络的小样本 GIS 绝缘缺陷智能诊断方法 [J]. *电工技术学报*, 2022, 37(9): 2150-2160.
- WANG Yanxin, YAN Jing, WANG Jianhua, et al. Intelligent diagnosis for GIS with small samples using a novel adversarial transfer learning in convolutional neural network [J]. *Transactions of China Electrotechnical Society*, 2022, 37(9): 2150-2160.
- [27] LIU Ruonan, YANG Boyuan, HAUPTMANN A G. Simultaneous bearing fault recognition and remaining useful life prediction using joint-loss convolutional neural network [J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(1): 87-96.

(编辑 杜秀杰)