

DOI: 10.19650/j.cnki.cjsi.J2209589

基于特征融合度量学习的高压断路器机械故障诊断*

王艳新, 闫 静, 王建华, 耿英三
(西安交通大学电力设备电气绝缘国家重点实验室 西安 710049)

摘 要:数据驱动的深度学习方法在高压断路器机械故障诊断中取得了一定的成效,然而这些方法实现优异性能的前提是可获取海量训练样本,在现场数据匮乏场景下其诊断性能明显下降。为此,提出了一种新颖的特征融合度量学习模型用于现场小样本高压断路器机械故障诊断。首先构建了特征融合卷积神经网络,有效提升了可鉴别特征提取能力。然后以 K 近邻算法作为度量学习器实现小样本数据的匹配和分类。最后通过改进中心损失进一步提升特征表示的分辨能力,并通过情景训练从实验室构建的大样本集中学习可迁移知识。实验结果表明,本文方法在每类支持集样本数为 5 时便可达到 94.58% 的诊断精度,相对于卷积神经网络提升了 63.71%。同时,得益于情景训练方式本文方法有效避免了非平衡样本的问题。

关键词:特征融合卷积神经网络;度量学习;故障诊断;小样本;高压断路器

中图分类号: TM561 TH17 文献标识码: A 国家标准学科分类代码: 470.40

Mechanical fault diagnosis for high voltage circuit breaker via a novel feature fusion metric learning

Wang Yanxin, Yan Jing, Wang Jianhua, Geng Yingsan
(State Key Laboratory of Electrical Insulation for Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: The data-driven deep learning methods have achieved excellent performance in the mechanical fault diagnosis of high-voltage circuit breakers. However, the premise of these methods to achieve excellent performance is the ability to obtain massive training samples. The diagnostic performance is severely degraded in scenarios where field data are scarce. To address this issue, this article proposes a novel feature fusion metric learning model for mechanical fault diagnosis of field high-voltage circuit breakers. First, a feature fusion convolutional neural network is established, which effectively improves the ability to extract discriminative features. Then, the K-nearest neighbor algorithm is used as the metric learner to realize the matching and classification of few-shot. Finally, the discriminative ability of feature representation is further improved by improving the center loss. And the transferable knowledge is learned from the large sample set constructed in the laboratory through episodic training. Experimental results show that the proposed method can achieve the diagnosis accuracy of 94.58% when the number of samples in each type of support set is 5. It is 63.71% higher than that of the convolutional neural network. In addition, the proposed method benefits from the episodic training method, which effectively avoids the problem of unbalanced samples.

Keywords: feature fusion convolutional neural network; metric learning; fault diagnosis; few-shot; high-voltage circuit breaker

0 引 言

作为电力系统中的重要保护和控制设备,高压断路器的运行状态直接关乎着整个电网的安全稳定^[1]。然而在分闸、合闸和储能等操动状态下,断路器部件动作产生

强烈的冲击,易引发铁芯卡涩、合闸弹簧疲劳、分闸弹簧疲劳等多种形式的故障^[2]。为此加强对高压断路器机械状态监测和故障诊断具有重要意义。目前,高压断路器机械故障诊断可采用分合闸线圈电流、行程曲线、振动、声音等信号进行^[3]。由于振动信号蕴含大量机械部件状态信息,利用非侵入式振动信号辨识断路器机械状态的方

收稿日期: 2022-04-11 Received Date: 2022-04-11

* 基金项目: 国家自然科学基金重点项目(51937009)资助

法得到广泛研究。为此,本文采用机械振动信号对高压断路器机械故障进行诊断。

在基于振动信号分析的高压断路器机械故障诊断研究中,数据驱动的故障诊断方法通过挖掘故障样本与故障类型间的映射关系而取得了优异的性能。传统数据驱动故障诊断方法先通过特征工程构建故障表征特征而后通过分类器进行故障分类^[4-5]。然而特征工程依赖专家经验且上述方法泛化能力不强^[6-7]。

随着人工智能技术的发展,卷积神经网络因能够自动学习故障特征与故障类型之间的非线性关系而备受关注。尤其是其强大的自动特征提取和优异的分类能力在高压断路器故障诊断上取得了显著效果^[8-9]。然而,目前构建的卷积神经网络都是在可获取海量样本的前提下进行的,随着样本量减小模型性能下降严重。现场运行中的高压断路器由于其故障概率和动作频率极低,且与实验室不同,现场运行中的高压断路器不可能人为设置故障获取样本。因此,现场获取到的某些工况模式下的高压断路器故障样本极其稀少,实际高压断路器故障诊断对小样本分类问题。

针对现场数据匮乏的小样本故障诊断问题,目前的主要解决思路分为两个方面,一方面是扩充数据^[10],不仅代价高昂,而且获取数据多为正常数据,难以获取有效的故障样本;另一方面则是依靠小样本学习方法来实现,主要包括迁移学习和元学习两种。迁移学习虽然能够提升分类精度^[11-13],但是其对源域数据的依赖严重。元学习作为一种如何获得学习能力而不是学习本身的学习,只需简单的调整即可适应实际工业场景中的新任务^[14]。其中基于度量的元学习方法通过测量查询集与支持集样本之间的距离,能够实现小样本分类,在变压器故障诊断^[15]、轴承故障诊断^[16]和数据匮乏下的防窃电检测^[17]领域取得了优异的效果。

受启发于度量元学习,本文提出了特征融合度量学习模型用于现场小样本高压断路器机械故障诊断。首先构建了特征融合卷积神经网络作为特征提取器来自动捕捉高压断路器故障可鉴别信息。然后,开发最近邻匹配网络作为度量分类器,对现场小样本高压断路器故障进行分类。通过情景训练和改进中心损失函数,实现特征融合度量学习模型在现场小样本上的训练和诊断。在样本匮乏条件下,特征融合度量学习模型能够实现现场小样本高压断路器机械故障的高精度、鲁棒诊断。

1 特征融合度量学习

为实现小样本下高压断路器故障的高精度、鲁棒诊断,本文引入了特征融合度量学习,在诊断模型构建过程中需要解决以下两个关键问题:1)设计能够捕捉高压断

路器故障可鉴别特征的特征提取器;2)开发一个能够有效对现场小样本下高压断路器故障分类的度量分类器。在特征提取器设计过程中,本文提出了一种特征融合卷积神经网络,并引入了中心损失函数^[18]来形成鲁棒的特征空间分布。在度量分类器设计过程中,本文采用最近邻匹配网络来实现高压断路器机械故障分类。在训练过程中采用情景训练^[19]的方式,利用单个振动信号样本的属性信息和故障信号样本组的相似性信息来实现小样本高压断路器机械故障的有效诊断。本文所构建的特征融合度量学习模型如图1所示。

1.1 特征融合卷积神经网络

为尽可能提取高压断路器机械故障信号的可鉴别特征,本文构建特征融合卷积神经网络作为特征提取器,其主要包括特征提取模块和特征融合模块两个部分组成。在特征提取过程中,为避免现场小样本条件下的过拟合问题,本文以带有4个卷积层的卷积神经网络作为特征提取器 f_ϕ ,其与原型网络^[20]中的特征提取器结构相同并通过反向传播来优化。

本文所提出的特征融合模块由高阶集成和关键区域定位两个部分组成。高阶集成能够捕捉高压断路器同一类别故障中更为相似的特征和不同类别故障之间有区别的特征。假设 $X \in R^{K \times M \times N}$ 为卷积层输出特征图,其中 $x \in X$ 是一个特定区域 $p \in M \times N$ 的 K 维描述符。 X 的高阶统计量的线性预测 W 可以表示为:

$$f(X) = \langle W, \sum_{x \in X} \phi(x) \rangle \quad (1)$$

其中, $\sum_{x \in X} \phi(x)$ 为由齐次多项式核^[18]表征的高阶统计量。在如图1所示的特征融合操作中,本文集成了二阶表示来捕获特征之间更复杂的高阶关系。之后,通过全局平均池化(GAP)^[21]来进一步聚合特性。




图1 特征融合度量学习模型

Fig. 1 Feature fusion metric learning model

关键区域定位能够发现目标之间的相似区域来提升模型小样本学习能力。在训练过程中, f_ϕ 可以通过 Grad-

CAM^[22]生成图像的关键区域,即:

$$L_{Grad-CAM}^c = \text{ReLU}\left(\sum_k \alpha_k^c A^k\right) \quad (2)$$

其中, α_k^c 为类别 c 的第 k 个特征图的权重, α_k^c 可通过下式计算:

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \quad (3)$$

其中, Z 为特征图中的像素数, y^c 为类别 c 对应的分类评分, A_{ij}^k 为第 k 个特征图中 i, j 位置的像素值。

1.2 度量学习

度量学习模块主要是利用一个类别中所有故障样本的深度特征描述来构造故障分类的局部特征空间。考虑到振动样本的离散性,本文采用 K 近邻算法^[23] 获得查询集样本与支持集中该类别样本的空间距离,实现现场小样本下高压断路器故障诊断。

具体来说,查询集 Q 中的每个样本 q 由特征提取器处理得到 $f_\phi(q)$ 。依次查找 x_i 在类别 c 中的 K 个最近邻,得到 x_i^j ($j = 1, \dots, K$)。然后,计算每个最近邻 x_i^j 和 x_i 之间的距离,最后将 m 个局部特征的距离与其 K 个最近邻相加,以获得与类别 c 匹配的查询集 Q 上样本 q 的相似度:

$$g(f(q), c) = \sum_{i=1}^m \sum_{j=1}^K \cos(x_i^j, x_i) \quad (4)$$

两个向量夹角的余弦值用来衡量它们之间的相关性。余弦距离可以降低对绝对值的敏感性,适用于离散数据之间距离的测量。向量 x_i^j 和 x_i 的余弦相似度可以计算如下:

$$\cos(x_i^j, x_i) = \frac{x_i^j \cdot x_i}{|x_i^j| \cdot |x_i|} \quad (5)$$

1.3 训练过程

为获得优异的特征融合度量学习模型实现现场小样本下高压断路器故障诊断,本文以情景训练机制进行模型训练。情景训练机制^[16] 已被证明是一种从训练数据集中学习可转移知识的有效方法。具体来说,网络通过 C 个任务进行训练。对于每个任务,有支持集 S 和查询集 Q 两个输入,每个样本的特征信息通过特征提取器处理得到,并根据度量学习模块将其与正确的类别进行匹配。为提升高压断路器故障特征表示的分辨能力,本文引入中心损失来进行模型训练。中心损失能够同时学习每个类的深度特征的中心,并惩罚深度特征与其对应的类中心之间的距离,其计算可表示如下:

$$\mathcal{L}_c = \frac{1}{2} \sum_i^n \|z_i - c_k\|^2 \quad (6)$$

其中, $z_i = f_\phi(x_i)$ 为从 x_i 中提取的深度特征, c_k 表示第 k 个类别中心的深度特征。

考虑到高压断路器故障类别之间的差异是非常小的,仅将特征向量引入类中心,难以形成良好的分布。为形成鲁棒嵌入空间分布,本文在中心损失中对难以接近中心的样本加入惩罚项,改进后的中心损失函数如下:

$$\mathcal{L}_s = \mathcal{L}_c + \beta \mathcal{L}_N \quad (7)$$

其中, β 为平衡因数。 $\mathcal{L}_N$ 是没有被分类到正确的类中心的样本的负对数概率。 $\mathcal{L}_N$ 可以表示如下:

$$\mathcal{L}_N = -\log \frac{\exp(-E(\bar{z}^k, c_k))}{\sum_{k \in K} \exp(-E(\bar{z}^k, c_k))} \quad (8)$$

$\bar{z}^k = \text{Avg}(\sum_{x_i \in x} f_\phi(x_i))$ 是每个批次包含的第 k 类平均特征向量, $E(\cdot)$ 为余弦距离。

2 特征融合度量学习高压断路器故障诊断流程

本文构建了特征融合度量学习模型用于现场高压断路器故障诊断。本文方法的整体框架如图2所示,主要包括数据集构建与划分、模型构建与训练、模型测试与部署3个部分组成。具体流程如下。




图2 本文方法的整体框架

Fig. 2 The overall structure of the proposed method

1) 数据集构建与划分:在构建训练数据集的过程中,以实验室数据作为训练集,以现场数据作为测试集。根据小样本学习数据集的设置形式,随机选取 C -way k -shot 的支持集 S 和查询集 Q 。为了训练出更好的特征融合度量学习模型,还需要将数据进行归一化处理。

2) 模型构建与训练:首先构建如图1所示的特征融合度量学习,并对参数进行初始化。然后以情景训练机制对模型进行训练。在模型训练过程中,支持集 S 用于训练故障分类模型,查询集 Q 用于评估模型的性能。

3) 模型测试与部署:用上述训练好的模型进行小样本高压断路器故障诊断。此时测试集中的支持集 S 作为目标集的支撑实现查询集 Q 的分类,并将模型部署到现有高压断路器在线监测软件平台以实现故障诊断。

3 案例分析

3.1 数据获取

为验证本文方法的有效性,首先在实验室内搭建基于 ZN63A-12 真空断路器的故障模拟系统以获取训练数据集,如图 3 所示。压电加速度传感器安装在断路器横梁上,用于振动信号采集,型号为 YD111 T,灵敏度为 10.06 mV/g,可测范围为 $\pm 5.00\text{ g}$ ($g=9.8\text{ m/s}^2$),最大输出电压为 5 V。数据采集单元采用 NI 公司生产的多功能设备(USB-6211),其更新速度为 250 KS/s。




图 3 故障模拟系统

Fig. 3 Fault simulation system

本文在该平台上模拟了 3 种典型的机械故障:铁芯卡涩、合闸弹簧疲劳和分闸弹簧疲劳。对每一类故障采集 200 个样本。同时,采集正常状态 200 个样本。4 种机械状态信号在多台样机上获得,典型信号如图 4 所示。




图 4 4 种机械状态信号

Fig. 4 Four mechanical status signals

为验证本文方法在现场小样本高压断路器故障诊断中的性能,本文利用某电力公司多年积累的现场运行中的断路器机械故障数据作为测试集进行验证。通过预处理,得到 4 种机械状态信号各 40 组。

3.2 结果验证与分析

为验证本文提出的特征融合度量学习 (feature fusion metric learning, F2ML) 模型的优势,与特征融合卷积神经网络 (feature fusion convolutional neural network, F2CNN)、以传统卷积神经网络为特征提取器的度量学习 (metric learning, ML)、级联微调迁移学习^[24] (fine-tuning transfer learning, FTL)、域适应迁移学习^[8] (domain adaptive transfer learning, DATL) 等主流方法进行对比。本文使用 Adam 优化^[25] 对所有模型进行训练。在训练过程中设置学习率为 0.000 1,小样本学习任务的查询样本数为 25,最大迭代次数为 100。本文实验均以 Pytorch 为框架,在配备 NVIDIA RTX3080-Ti 12 GB GPU,i9-10850K CPU 和 32 GB RAM 的计算机上进行。为消除参数初始化误差的影响,训练模型取 10 次的平均值作为最终结果。

图 5 给出了随着 β 变化模型诊断精度变化曲线。从曲线中可以看出,在 $\beta = 0$ 时,模型的诊断性能并不理想。由于 $\beta = 0$ 时对应的损失函数与中心损失相同,由此可见中心损失对于小样本分类问题不是一个好的选择。而改进后的中心损失能够提升模型的诊断性能,从图中可以看出 β 的取值范围在 0.4 ~ 0.6 之间模型能取得最佳性能,综合考量本文 β 值设置为 0.5。





图 5 随着 β 变化模型诊断精度变化曲线

Fig. 5 Curve of model diagnosis accuracy with β change

图 6 给出了不同损失函数下模型的二维可视化结果,通过颜色和形状区分不同的故障类别。从图 6 可以看出改进中心损失可以快速形成每个类的集群。另外,从故障样本的聚类结果上来看,改进中心损失函数使得相同类别故障更紧密地聚集在一起,而不同类别故障之间的距离更疏远。因此,中心损失能够获得更鲁棒的特征空间分布。表 1 给出不同损失函数下的精度,由表 1 可以看出,改进中心损失在高压断路器故障诊断任务上表现得更好,相对于其他方法明显提升。




图 6 二维可视化结果

Fig. 6 Two-dimensional visualization results

表 1 不同损失函数下的高压断路器故障诊断精度

损失函数	精度/%		
	1-shot	5-shot	20-shot
交叉熵损失	68.95	93.89	94.26
中心损失	69.29	94.17	94.45
改进中心损失	69.65	94.58	94.95

表 2 给出在不同支持集下各种方法的高压断路器故障诊断结果。从表 2 中可以看出,在 1-shot 时 F2ML 相对于 F2CNN、ML、FTL 和 DATL 分别提升了 38.06%、1.86%、37.87%、和 11.8%; 在 5-shot 时 F2ML 相对于 F2CNN、ML、FTL 和 DATL 分别提升了 63.71%、3.31%、32.99%和 13.73%。随着支撑集数量继续增加,诊断精度的提升不再明显。考虑到断路器故障概率和动作频率低,样本十分匮乏,支撑集数量较小时的高精度诊断的意义更大,为此本文后续以 5-shot 为基础进行分析与验证。

另外从 F2ML 和 ML 的对比中看出,特征融合能够有效提升故障诊断精度,这与其能够从高压断路器故障信号中获取更有分辨力的信息有关。通过与 F2CNN 的对比,可以看出传统训练方法难以实现小样本高压断路器故障的准确诊断。与迁移学习策略相比,度量学习方法能够显著提升现场小样本下高压断路器机械故障诊断精度,样本数量越小,其优势越明显。

表 2 不同支持集下各种方法的高压断路器故障诊断结果

方法	精度/%		
	1-shot	5-shot	20-shot
F2ML	69.65	94.58	94.95
F2CNN	31.59	30.87	30.98
ML	67.79	91.27	91.63
FTL	31.78	61.59	72.67
DATL	57.85	80.85	90.98

图 7 给出了各种方法在 10 次训练后的箱形图和散点图。由图 7 中可以看出,F2ML 除了具有最高精度外,箱形图的宽度、中位数等均最小,说明其波动也最小,意味着其具有更强的鲁棒性。而 F2CNN 直接在现场小样本上训练,其诊断精度在 30%左右波动,此时其处于盲猜状态。迁移学习方法也能够提升故障诊断精度,但是其效果不如本文方法明显,且鲁棒性弱于本文方法。




图 7 10 次训练后的箱形图和散点图

Fig. 7 Box plot and scatter plot of 10 training sessions

为了验证各种方法对每类缺陷的诊断结果,图 8 给出了其混淆矩阵。0,1,2 和 3 分别表示铁芯卡涩、合闸弹簧疲劳、分闸弹簧疲劳和正常等 4 种状态。混淆矩阵中的对角线为每类缺陷的诊断准确率。可以看出,本文方法对每一类缺陷的诊断准确率均最高,进一步

验证了其优越性。另外,本文对单一故障类型的最低诊断准确率达 90%,明显高于其他方法,充分体现其优越性。




图 8 各种方法的混淆矩阵

Fig. 8 Confusion matrixes of different methods

由于实际运行中的高压断路器多处于正常状态,获取到的数据多为非平衡数据。为验证本文方法在非平衡小样本下的性能,构建了如表 3 所示的非平衡样本。图 9 给出了各种方法在上述非平衡样本上的故障诊断结果。可以看出,F2ML 和 ML 的诊断精度几乎不变,这得益于情景训练方式。即诊断过程中严格按照 C -way k -shot 的形式进行,每个训练任务都是在整个样本上的随机采样,有效避免了非平衡样本的问题。而迁移学习是以传统的监督训练方式进行的,受限于卷积神经网络对非平衡样本的敏感性,随着样本非平衡率的增加则故障诊断性能下降越发明显。这体现了本文方法的优越性,也为现场高压断路器故障诊断提供了可行方案。

表 3 本文所构建的非平衡样本

数据集	训练集		测试集	
	正常样本	故障样本	正常样本	故障样本
1	200	200	40	40
2	400	200	80	40
3	800	200	160	40
4	1 200	200	240	40
5	2 000	200	400	40




图 9 各种方法在非平衡数据集上的故障诊断结果

Fig. 9 Fault diagnosis results of different methods on unbalanced datasets

4 结 论

针对现场数据匮乏的问题,本文提出了用于现场高压断路器机械故障诊断的特征融合度量学习方法,并利用现场数据验证了其优越性,主要结论如下:

- 1) 特征融合度量学习能够有效实现现场小样本下高压断路器机械故障的高精度、鲁棒诊断,在支撑集样本数量为 5 时诊断精度已达到 94.58%,明显优于迁移学习等其他方法。为现场数据匮乏场景下的高压断路器机械故障诊断提供了可行方案。
- 2) 度量学习的引入,能够在有限的支撑样本下实现小样本数据的匹配和分类。这种非参数的分类器有效避免了过拟合,解决了神经网络分类器在小样本场景下难以训练出高精度、鲁棒模型的问题。
- 3) 以情景训练方法对特征融合度量学习进行训练,能够从训练数据集中学习可迁移知识,实现小样本数据的可靠诊断。另外,由于其严格按照 C -way k -shot 的形式进行训练,直接避免了非平衡样本的问题。
- 4) 特征融合和改进中心损失的引入,有效提升了高压断路器机械故障诊断的精度和鲁棒性。特征融合可有效提取高压断路器机械故障信号的可鉴别特征,提升了模型小样本学习能力。而改进中心损失能够同时学习每个类的深度特征的中心,并惩罚深度特征与其对应的类中心之间的距离,有效提升了特征表示的分辨能力。

参考文献

[1] 陈欣昌,冯珂,林圣,等. 基于深度自编码网络的高压断路器操作机构机械故障诊断方法[J]. 高电压技术, 2020, 46(9): 3080-3088.
CHEN X CH, FENG D, LIN SH, et al. Mechanical fault diagnosis method of high voltage circuit breaker operating mechanism based on deep auto-encoder network [J]. High Voltage Engineering, 2020, 46(9): 3080-3088.
[2] 赵书涛,许文杰,刘会兰,等. 基于振动信号谱形状

- 熵特征的高压断路器操动状态辨识方法[J]. 电工技术学报, 2022, 37(9): 2170-2178.
- ZHAO SH T, XU W J, LIU H L, et al. Identification method for operation state of high voltage circuit breakers based on spectral shape entropy characteristics of vibration signals [J]. Transactions of China Electrotechnical Society, 2022, 37(9): 2170-2178.
- [3] 彭跃辉, 武艳蒙, 王岩妹, 等. 基于半监督学习的断路器弹簧机构机械特性监测及状态评估技术研究[J]. 高压电器, 2022, 58(5): 95-102, 111.
- PENG Y H, WU Y M, WANG Y M, et al. Research on mechanical characteristics monitoring and condition assessment technology of spring mechanism for circuit breaker based on semi supervised learning [J]. High Voltage Apparatus, 2022, 58(5): 95-102, 111.
- [4] 黄南天, 张书鑫, 蔡国伟, 等. 采用 EWT 和 OCSVM 的高压断路器机械故障诊断[J]. 仪器仪表学报, 2015, 36(12): 2773-2781.
- HUANG N T, ZHANG SH X, GAI G W, et al. Mechanical fault diagnosis of high voltage circuit breakers utilizing empirical wavelet transform and one-class support vector machine [J]. Chinese Journal of Scientific Instrument, 2015, 36(12): 2773-2781.
- [5] GAO W, QIAO S P, WAI R J, et al. A newly designed diagnostic method for mechanical faults of high-voltage circuit breakers via SSAE and IELM [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1-13.
- [6] 林琳, 陈志英. 基于粗糙集神经网络和振动信号的高压断路器机械故障诊断[J]. 电工技术学报, 2020, 35(S1): 277-283.
- LIN L, CHEN ZH Y. Mechanical fault diagnosis of high voltage circuit breakers based on rough set neural networks and vibration signals [J]. Transactions of China Electrotechnical Society, 2020, 35(S1): 277-283.
- [7] 孙曙光, 张强, 杜太行, 等. 基于灰色关联度的框架式断路器故障诊断方法[J]. 仪器仪表学报, 2017, 38(10): 2525-2535.
- SUN SH G, ZHANG Q, DU T H, et al. Fault diagnosis method of frame-type circuit breaker based on grey correlation degree [J]. Chinese Journal of Scientific Instrument, 2017, 38(10): 2525-2535.
- [8] YANG Q, RUAN J, ZHUANG Z, et al. Condition evaluation for opening damper of spring operated high-voltage circuit breaker using vibration time-frequency image [J]. IEEE Sensors Journal, 2019, 19(18): 8116-8126.
- [9] 曹宇鹏, 罗林, 王乔, 等. 基于卷积深度网络的高压真空断路器机械故障诊断方法[J]. 电力系统保护与控制, 2021, 49(3): 39-47.
- CAO Y P, LUO L, WANG Q, et al. Fault diagnosis of high-voltage vacuum circuit breaker with a convolutional deep network [J]. Power System Protection and Control, 2021, 49(3): 39-47.
- [10] 李东东, 刘宇航, 赵阳, 等. 基于改进生成对抗网络的风机行星齿轮箱故障诊断方法[J]. 中国电机工程学报, 2021, 41(21): 7496-7507.
- LI D D, LIU Y H, ZHAO Y, et al. Fault diagnosis method of wind turbine planetary gearbox based on improved generative adversarial network [J]. Proceedings of the CSEE, 2021, 41(21): 7496-7507.
- [11] WANG Y, YAN J, YANG Z, et al. A domain adaptive deep transfer learning method for gas-insulated switchgear partial discharge diagnosis [J]. IEEE Transactions on Power Delivery, 2021, 37(4): 1678-1688.
- [12] 陈保家, 陈学力, 肖文荣, 等. 小样本下滚动轴承故障的多源域迁移诊断方法[J]. 电子测量与仪器学报, 2022, 36(2): 219-228.
- CHEN B J, CHEN X L, XIAO W R, et al. Multi-source domain transfer diagnosis method for rolling bearing faults under small samples [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(2): 219-228.
- [13] 陈仁祥, 朱玉清, 胡小林, 等. 自适应正则化迁移学习的不同工况下滚动轴承故障诊断[J]. 仪器仪表学报, 2021, 41(8): 95-103.
- CHEN R X, ZHU Y Q, HU X L, et al. Fault diagnosis of rolling bearing under different working conditions using adaptation regularization based transfer learning [J]. Chinese Journal of Scientific Instrument, 2021, 41(8): 95-103.
- [14] 李凡长, 刘洋, 吴鹏翔, 等. 元学习研究综述[J]. 计算机学报, 2021, 44(2): 422-446.
- LI F ZH, LIU Y, WU P X, et al. A survey on recent advances in meta-learning [J]. Chinese Journal of Computers, 2021, 44(2): 422-446.
- [15] 朱瑞金, 郝东光, 胡石峰. 小样本条件下基于卷积孪生网络的变压器故障诊断[J]. 电力系统及其自动化学报, 2021, 33(1): 64-69, 84.
- ZHU R J, HAO D G, HU SH F. Transformer fault diagnosis based on convolutional siamese network with small samples [J]. Proceedings of the CSU-EPSC, 2021, 33(1): 64-69, 84.
- [16] WANG D, ZHANG M, XU Y, et al. Metric-based meta-learning model for few-shot fault diagnosis under multiple limited data conditions [J]. Mechanical Systems and

- Signal Processing, 2021, 155: 107510.
- [17] 高昂, 郑建勇, 梅飞, 等. 基于三元组孪生网络的窃电检测算法[J]. 中国电机工程学报, 2021, 33(1): 1-13.
GAO ANG, ZHENG J Y, MEI F, et al. Electricity theft detection algorithm based on triplet network [J]. Proceedings of the CSEE, 2021, 33(1): 1-13.
- [18] PHAM N, PAGH R. Fast and scalable polynomial kernels via explicit feature maps[C]. Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2013: 239-247.
- [19] SUN X, XU H, DONG J, et al. Few-shot learning for domain-specific fine-grained image classification [J]. IEEE Transactions on Industrial Electronics, 2020, 68(4): 3588-3598.
- [20] LI B, TANG B, DEBG L, et al. Multiscale dynamic fusion prototypical cluster network for fault diagnosis of planetary gearbox under few labeled samples [J]. Computers in Industry, 2020, 123: 103331.
- [21] JIAO J, ZHAO M, LIN J, et al. Deep coupled dense convolutional network with complementary data for intelligent fault diagnosis [J]. IEEE Transactions on Industrial Electronics, 2019, 66(12): 9858-9867.
- [22] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-cam: Visual explanations from deep networks via gradient-based localization[C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 618-626.
- [23] XU J, XU P, WEI Z, et al. DC-NNMN: Across components fault diagnosis based on deep few-shot learning[J]. Shock and Vibration, 2020, 2020:1-11.
- [24] 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): 20-25,32.
YANG W, ZHU T Y, ZHANG G B, 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): 20-25,32.

- [25] 陈刚, 段洁, 衣文索, 等. 基于 BOTDR 散射谱的应变提取方法研究[J]. 仪器仪表学报, 2021, 42(1): 75-81.

CHEN G, DUAN J, YI W S, et al. Research on the strain extraction method based on BOTDR scattering spectrum [J]. Chinese Journal of Scientific Instrument, 2021, 42(1): 75-81.


作者简介



王艳新, 2018 年于东北林业大学获得学士学位, 2021 年于西安交通大学获得硕士学位, 现为西安交通大学博士研究生, 主要研究方向为电力设备在线监测和故障诊断。

E-mail: xinxin199501@stu.xjtu.edu.cn

Wang Yanxin received his B.Sc. degree from Northeast Forestry University in 2018 and received his M.Sc. degree from Xi'an Jiaotong University in 2021. He is currently pursuing his Ph.D. degree at Xi'an Jiaotong University. His main research interests include on-line monitoring and fault diagnosis of power equipment.



闫静(通信作者), 1996 年、1999 年和 2006 年于西安交通大学分别获得学士、硕士和博士学位, 现为西安交通大学副教授, 主要研究方向为高压开关设备理论与应用、智能电器及电力设备状态评估。

E-mail: yanjing@mail.xjtu.edu.cn

Yan Jing (Corresponding author) received his B.Sc., M.Sc., and Ph.D. degrees all from Xi'an Jiaotong University in 1996, 1999 and 2006, respectively. He is currently an associate professor at Xi'an Jiaotong University. His research interests include theory and application of high voltage switchgear, intelligent electric apparatus and power equipment condition evaluation.