

基于多尺度注意力自适应去噪网络的局部放电模式识别

郑尚坡¹, 刘俊峰¹, 曾 君², 廖晓青³, 陈 历³, 许建远³

(1. 华南理工大学自动化科学与工程学院, 广州 510641; 2. 华南理工大学电力学院, 广州 510641;
3. 广东电网有限责任公司茂名供电局, 茂名 525000)

摘 要: 局部放电的故障类型与气体绝缘开关(gas insulated switchgear, GIS)绝缘故障的严重程度紧密相关, 精确识别局部放电故障类型对保障供电系统的稳定性至关重要。传统局部放电模式识别方法缺乏自适应去噪和对多尺度故障特征的处理机制, 并且过于依赖专家经验, 以至于在处理含有大量噪声和固有多尺度特性的复杂局部放电信号时存在显著局限性, 从而限制了模型对于局部放电故障识别准确率的进一步提升。为解决这些问题, 提出一种多尺度注意力自适应去噪网络(multi-scale attention adaptive denoising network, MAADNet), 该网络集成了多尺度特征学习模块、卷积注意力模块(convolutional block attention module, CBAM)以及软阈值函数, 具备强大的自适应去噪和多尺度故障特征学习能力。具体而言, 多尺度特征学习模块通过采用不同空洞率的空洞卷积以提取多尺度特征; 而 CBAM 注意力机制和软阈值函数协同工作, 依据输入局部放电信号的特性自适应调整去噪阈值, 有效实现噪声抑制。此外, 为验证所提网络有效性, 通过搭建局部放电试验平台, 设计并制作 4 种典型局放故障模型以收集不同故障类型的局部放电数据集。试验结果表明, 所提方法在局部放电数据集上取得 94.34% 的识别准确率, 优于其他先进方法, 显示出良好的应用前景。

关键词: 气体绝缘开关; 局部放电; 模式识别; 多尺度特征; 注意力机制

Partial Discharge Pattern Recognition Based on Multi-scale Attention Adaptive Denoising Network

ZHENG Shangpo¹, LIU Junfeng¹, ZENG Jun², LIAO Xiaoqing³, CHEN Li³, XU Jianyuan³

(1. School of Automation Science and Engineering, South China University of Technology, Guangzhou 510641, China;
2. School of Electric Power Enineering, South China University of Technology, Guangzhou 510641, China;
3. Maoming Power Supply Bureau, Guangdong Power Grid Co., Ltd., Maoming 525000, China)

Abstract: The types of partial discharge faults are closely related to the severity of insulation failures in gas insulated switchgear (GIS), thus the precise identification of these faults is crucial for maintaining the stability of power supply systems. Traditional methods of partial discharge pattern recognition lack adaptive denoising capabilities and mechanisms to handle multi-scale fault features, and they primarily rely on expert experience. This results in significant limitations when dealing with complex partial discharge signals that contain substantial noise and inherent multi-scale characteristics, thereby constraining further improvements in the accuracy of fault type recognition. To address these challenges, this paper introduces a multi-scale attention adaptive denoising network (MAADNet), which integrates a multi-scale feature learning module, a convolutional block attention module (CBAM) attention mechanism module, and a soft threshold function. This network possesses robust adaptive denoising and multi-scale fault feature learning capabilities. Specifically, the multi-scale feature learning module employs dilated convolutions with varying dilation rates to extract features at multiple scales; the CBAM attention mechanism and soft threshold function collaboratively adjust the denoising threshold based on the characteristics of the input partial discharge signals, effectively suppressing noise. Moreover, to validate the effectiveness of the proposed network, a partial discharge experimental platform was set up, and four typical partial discharge fault models were designed and constructed to collect a dataset of different fault types. Experimental results

demonstrate that the proposed method achieves a recognition accuracy of 94.34% on the partial discharge dataset, outperforming other advanced methods and showing promising application prospects.

Key words: gas insulated switchgear; partial discharge; pattern recognition; multi-scale features; attention mechanism

0 引言

局部放电是反映气体绝缘开关(gas insulated switchgear, GIS)内部绝缘缺陷的重要因素之一, 对其进行准确的检测在有效评估 GIS 设备绝缘状况以及提高供电可靠性等方面起着至关重要的作用^[1-4]。GIS 一旦发生绝缘故障, 可能将导致电网大面积停电, 给社会稳定和经济发展带来巨大损失, 因此对 GIS 设备开展有效的局部放电模式识别方法对避免其发生重大绝缘事故具有重要意义^[5-7]。

在现有研究中, 基于局部放电模式识别主要分为 2 种: 1) 基于机器学习的模式识别方法。此类方法主要包括: K 近邻(K-nearest neighbors, KNN)^[8]、支持向量机(support vector machine, SVM)^[9]、随机森林(random forest, RF)^[10]、人工神经网络(backpropagation neural network, BPNN)^[11-12]以及 XGBoost^[13]等。传统的机器学习方法具有一定对局部放电故障类型的识别能力, 然而, 这些方法大多需要手工提取和选择包含局部放电故障信息的关键特征参数, 在很大程度上取决于事先掌握的信号处理技术和诊断专业知识, 并且此类模型结构较简单, 导致识别准确率受限^[14-15]。2) 基于深度学习的模式识别方法。相比传统机器学习模型, 深度学习方法由于其深层结构和大量网络参数, 具备强大的非线性处理能力, 能够更有效地学习和提取故障特征, 展现出优异的泛化性能。卷积神经网络(convolutional neural networks, CNN)^[16-19]及其变体(如 MobileNet^[15]、ResNet^[20]、DenseNet^[21]等)在局部放电故障类型识别领域中已取得显著成果。例如, 文献[17]构建了应用于局部放电模式识别的深层 CNN 模型, 利用多层卷积神经网络提取局放脉冲信号图谱(phase resolved partial discharge signature, PRPS)深层特征以提高复杂数据源下的识别正确率。文献[18]基于 CNN 提出了一种新的模式识别方法, 以区分高压电缆中由不同绝缘缺陷引起的局部放电, 其效果优于 BPNN 和 SVM 等传统机器学习方法。文献[20]提出一种基于深度残差网络 ResNet 的局放相位分布图谱(phase resolved partial discharge, PRPD)模式识别, 能有效应对庞大数据量和

复杂数据的问题。上述方法主要针对 PRPD 或 PRPS 等结构化数据, 需要进一步将采集到的数据进行格式转换, 无法直接处理时域波形数据。在实际应用中, 大部分局部放电传感器输出的电压信号都以构成时域波形的样本点存储于示波器中, 属于非结构化数据^[21]。为进一步提高模型计算效率和识别准确率, 文献[19]和文献[21]分别提出了基于一维卷积神经网络(one-dimensional convolutional neural network, 1DCNN)和密集连接卷积网络(densely connected convolutional network, DenseNet)的端到端的局部放电模式识别框架, 并在原始时间序列波形数据上进行试验, 所得试验结果优于许多先进方法。然而, 这些方法在处理含有噪声及具有多尺度特性的复杂局部放电信号时, 仍存在局限性, 需要通过额外设计去噪算法以及人工设置去噪阈值对局放进行去噪预处理, 依赖于专家经验。此外, 这些方法采用的都是具有固定卷积核大小的模型, 难以捕捉丰富的多尺度故障特征, 识别准确率存在进一步提升空间。

为了解决上述提到的问题, 本文提出一种多尺度注意力自适应去噪网络, 通过集成多尺度特征学习模块、卷积注意力模块(convolutional block attention module, CBAM)以及软阈值函数, 旨在实现对原始局部放电时域波形信号的自适应去噪以及对多尺度故障特征的学习和捕捉。所提方法能够大大提高模型在局部放电故障识别中的准确率, 具有较高的准确率、计算效率、鲁棒性和泛化性。此外, 为提高试验可靠性, 本文构建在高压实验室构建一个局部放电试验平台, 并设计了 4 种局放故障模型来收集不同故障类型的一维时间序列样本格式构建局部放电数据集用于模型训练和测试。

1 多尺度注意力自适应去噪网络

考虑到局部放电信号的固有多尺度特性和复杂性, 基于单一尺度的 CNN 可能无法充分捕捉局放的故障特征信息, 因此学习多尺度局部放电故障特征至关重要。此外, 从局放传感器采集到的原始时间序列数据往往包含大量噪声和冗余信息, 会直接影响模型在故障识别的准确率^[22], 有效减少这些

噪声特征对提高模型性能具有重要意义。受多尺度卷积神经网络(multi-scale convolutional neural network, MSCNN)^[22]、深度残差网络(deep residual shrinkage networks, DRSN)^[23]和 CBAM^[24]启发, 开发了新的多尺度注意力自适应去噪网络(multi-scale adaptive denoising network, MAADNet), MAADNet 的模型结构由多个 MAAD 模块堆叠构成, 如图 1 所示, “/2”表示模块内的卷积核以步长为 2 进行移动从而减少输出特征图的长度, B 、 C 和 L 分别表示批量大小、特征图的通道数和特征图长度。MAAD 模块基于 ResNet 网络结构设计, 以防止梯度消失^[25], 同时集成了多尺度特征学习模块(multi-scale feature learning module, MFLM)、CBAM

注意机制和软阈值函数。在多尺度特征学习模块中, 采用多个不同扩张率的空洞卷积^[26]进行多尺度特征提取, 其通过调整扩张率控制卷积核中的空洞大小, 从而改变卷积核的感受野大小, 使得模型在不同的时间尺度上捕获特征。具体来说, 扩张率为 1 的空洞卷积用于捕捉局部放电信号中的短期依赖关系和细节特征, 而扩张率为 6、12 和 18 则使得网络层能够接触到在时间序列中相隔较远的数据点, 帮助模型捕捉到长时间范围内的信号变化, 同时探索局放信号中的长期依赖关系并提高模型对更大尺度的上下文特征信息提取能力。与 MSCNN^[22]和 MSN^[27]不同的是, 本文采用空洞卷积而不是池化或标准卷积提取多尺度特征的原因在于它能够在不增




图1 多尺度注意力自适应去噪网络详细结构

Fig.1 Detailed architecture of MAADNet

加参数数量或计算量的情况下提取更多不同尺度的故障特征。相比之下, 池化在扩大感受野的同时可能会丢失详细信息, 而标准卷积需要更大的卷积核或更深的网络才能实现更大的感受野, 以至于增加了计算成本。随后, 将经过空洞卷积产生的多个不同尺度特征图沿着通道维度进行拼接得到多尺度特征图 $F_c \in \mathbb{R}^{B \times 4C \times L}$, 其中 $\mathbb{R}$ 为实数域。然后通过卷积核大小为 1 的一维卷积层(Conv1D)进行降维处理, 得到多尺度特征融合后的特征图 $F_M \in \mathbb{R}^{B \times C \times L}$, 计算式表达为:

$$F_{d_1} = \text{Conv1D}(F, k=1, p=0, r=1) \quad (1)$$

$$F_{d_2} = \text{Conv1D}(F, k=3, p=6, r=6) \quad (2)$$

$$F_{d_3} = \text{Conv1D}(F, k=3, p=12, r=12) \quad (3)$$

$$F_{d_4} = \text{Conv1D}(F, k=3, p=18, r=18) \quad (4)$$

$$F_M = \text{Conv1D}(\text{Concat}[F_{d_1}; F_{d_2}; F_{d_3}; F_{d_4}], k=1, p=0, r=1) \quad (5)$$

式中: Conv1D 表示用于处理输入时间序列数据的一维卷积层; k 为卷积核大小; r 为扩张率用于调整卷积的感受野大小; F 为输入特征图; p 为填充大小; Concat 表示在通道维度上的拼接操作, F_{d_1} 、 F_{d_2} 、 F_{d_3} 和 F_{d_4} 分别表示由不同扩张率的空间卷积生成的多尺度特征图。

经过绝对值处理后的特征图 $|F_M|$ 被输入到 CBAM 注意力机制模块中。采用注意力机制可以使模型更加聚焦于输入信号中的关键故障特征, 同时忽略不相关的特征信息^[24], 该机制能够显著提升模型处理复杂且含噪数据的效率与分类性能。由于 CBAM 最初是针对图像设计, 本文对该模块进行改进, 使其有效处理基于时间序列的局放样本数据。CBAM 的设计旨在通过顺序应用通道注意力模块(channel attention module, CAM)和空间注意力模块(spatial attention module, SAM)来细化局部放电故障特征。在 CAM 中, 自适应平均池化(adaptive average pooling, AAP)和自适应最大池化(adaptive max pooling, AMP)作用于特征图的第三维度(序列长度), 分别产生保留通道信息的特征图: $F_a \in \mathbb{R}^{B \times C \times 1}$ 和 $F_m \in \mathbb{R}^{B \times C \times 1}$, 这些特征图随后通过 2 个全连接层进行处理并求和, 得到特征图 $\beta \in \mathbb{R}^{B \times C \times 1}$, 经过 sigmoid 激活函数后, 生成范围为(0, 1)之间的通道注意力图, 该特征图与多尺度特征图的绝对值 $|F_M|$ 相乘, 得到通道增强后特征图 $z \in \mathbb{R}^{B \times C \times L}$ 。此步骤确保阈值不仅是正的, 而且不会过大, 否则将导致

经软阈值处理后的特征全部为零。该模块可被公式化为:

$$F_a = \text{AAP}(|F_M|), F_m = \text{AMP}(|F_M|) \quad (6)$$

$$\beta = F_{C_2}(F_{C_1}(F_a)) + F_{C_2}(F_{C_1}(F_m)) \quad (7)$$

$$z = \text{sigmoid}(\beta) \cdot |F_M| \quad (8)$$

式中: sigmoid($\cdot$) 表示激活函数; F_{C_2} 和 F_{C_1} 均表示全连接层; 函数 AAP($\cdot$) 和 AMP($\cdot$) 分别表示自适应平均池化和自适应最大池化。

在 SAM 中, AAP 和 AMP 则同时作用于特征图 z 第 2 维度, 分别产生 2 种保留长度信息的特征图: $F'_a \in \mathbb{R}^{B \times 1 \times L}$ 和 $F'_m \in \mathbb{R}^{B \times 1 \times L}$ 。然后将这 2 个特征图沿通道维度进行拼接, 并通过卷积核大小为 3 的 Conv1D 层和 sigmoid 激活函数进行处理, 生成特征图 $\gamma \in \mathbb{R}^{B \times 1 \times L}$ 。最后, γ 与 z 相乘得到空间增强后的特征图 $\tau \in \mathbb{R}^{B \times C \times L}$ 。值得注意的是, τ 也被用作软阈值函数中的去噪阈值, 下文将详细介绍。该模块可表示为:

$$F'_a = \text{AAP}(z, \text{dim}=1), F'_m = \text{AMP}(z, \text{dim}=1) \quad (9)$$

$$\gamma = \text{Conv}(\text{Concat}[F'_a; F'_m], k=3, s=1, p=1) \quad (10)$$

$$\tau = \text{sigmoid}(\gamma) \cdot z \quad (11)$$

式中: dim 表示维度; Conv 为卷积层。

相比于 DRSN 主要关注通道特征的处理, 所提出的 MAAD 模块通过整合 CBAM, 有效实现对局放信号特征在不同维度(通道和长度)的细致处理, 使模型能够提取更为丰富和关键的特征表达, 从而进一步增强了模型的性能。

除此之外, 软阈值函数在去噪过程中也起着至关重要的作用, 它将绝对值低于特定阈值的特征设置为 0。由于该函数的导数产生的梯度为 0 或 1, 这一操作不仅减少了特征缩放, 还防止了如梯度爆炸或消失等问题。通过利用 CBAM 提取重要特征, 并根据这些特征的大小使用软阈值函数自适应调整去噪阈值, 以有效消除无关冗余特征和噪声信息。这种方法解决了传统去噪算法需要人工设置阈值的局限性。软阈值函数以及偏导函数可以表示如下:

$$y = \begin{cases} x - \tau, & x > \tau \\ 0, & -\tau \leq x \leq \tau \\ x + \tau, & x < -\tau \end{cases} \quad (12)$$

$$\frac{\partial y}{\partial x} = \begin{cases} 1, & x > \tau \\ 0, & -\tau \leq x \leq \tau \\ 1, & x < -\tau \end{cases} \quad (13)$$

式中: x 为输入特征; y 为输出特征; τ 为去噪阈值

(正参数)。相比于 ReLU 激活函数, 软阈值函数的优点在于它能保留那些有用的负特征, 从而在去噪或特征选择过程中更精细地调节信息流。

MAAD 模块的最终输出 F_o 可以表述为:

$$F_o = F + \text{sign}(F_M) \cdot \max(|F_M| - \tau, 0) \quad (14)$$

式中: $\text{sign}(\bullet)$ 用来返回输入 x 的符号, 其中正值返回 1, 负值返回 -1; $\max(\bullet)$ 将任何小于 0 的结果设为 0; τ 为可学习的训练参数和去噪阈值, 通过 CBAM 模块根据输入信号的特征进行自适应调节。式(14)第 2 项表示利用软阈值机制进行去噪的过程。

2 局部放电试验平台搭建

为使试验获取的局部放电数据能够真实反映 GIS 在运行条件下的绝缘状况, 本文在高压实验室建立了局部放电试验平台, 采用抗干扰能力强、灵敏度高、精度高的脉冲电流法检测和采集故障模型内部的局部放电信号, 如图 2 所示。局部放电试验平台具体包括变压器、保护电阻、限流电阻、故障模型、耦合电容、检测阻抗和示波器。电压控制台与变压器配合使用, 产生故障模型所需的试验电压; 保护电阻用于限制电路中大电流的产生, 确保测试设备的安全; 耦合电容用于耦合高频信号并隔离直流高压同时起到分压作用; 高频电流互感器用于测量检测阻抗上的脉冲电流; 示波器以 50 MHz 的采样频率对 4 种故障类型的放电波形进行采样, 并存储构成每种故障波形的时序样本点, 试验中使用的 4 种故障放电模型如图 3 所示。图 3(a)通过在高压电极端安装弧度为 30° 的尖锐金属物体对直径为 50 mm 的接地线铜板施加电压以模拟尖端放电; 图 3(b)通过直径为 10 mm 的铜柱对直径为 100 mm 并带有气孔的 3 层环氧树脂板施加电压以模拟气隙放电, 其中 2 层环氧树脂板厚度为 5 mm, 中间夹着 1 层厚度为 1 mm、带有 10 mm 直径气孔的环氧树脂板; 图 3(c)通过在环氧树脂板上放置直径为 10 mm 的金属螺母以模拟悬浮金属放电过程; 图 3(d)通过铜柱对环氧树脂板表面施加电压模拟沿面放电的过程。

试验中采用逐步加压方法, 通过电压控制台向故障模型施加电压, 并逐渐增加电压, 从较低电压增加到较高电压, 直到出现稳定的局部放电波形。表 1 记录了示波器采样时, 电压控制台在每种故障模型上施加的试验电压。




图 2 局部放电试验平台示意图

Fig.2 Schematic diagram of partial discharge experiment platform




图 3 4 种故障放电模型

Fig.3 Four types of fault discharge models

表 1 每种故障模型的试验电压

Table 1 Test voltage for each fault model

故障类型	试验电压/kV
尖端放电	2.56
气隙放电	14.19
悬浮金属放电	8.78
沿面放电	7.76

3 试验结果与分析

3.1 试验数据集介绍

在试验中, 用于模型训练和测试的数据格式为一维时间序列格式^[28], 即采用构成每种波形信号的时序样本点作为训练样本, 构建数据集的每个样本

包含 2 048 个时序数据点, 为避免类别不平衡, 4 种局部放电故障类型均分别采集了 4 882 个样本, 总共样本个数为 19 528。局放数据集按照 8:2 的比例划分为训练集和测试集, 从而分别得到 3 905 个训练样本和 977 个测试样本, 所有样本均经过最小-最大归一化处理, 以确保数据一致性和可比性^[28]。图 4 显示了由示波器采集到的样本点所构建的 4 种局部放电时域波形, 其中尖端放电相比其他放电波形更为明了, 主要原因在于尖端放电发生在尖锐物体的尖端, 该放电过程较为剧烈和集中, 产生的电信号更加强烈和明显, 而其余放电发生在绝缘材料上, 表现为爬电或者存在隔离, 此类放电强度分布不均, 信号较弱, 较难被检测, 容易受到噪声和环境干扰。

3.2 试验环境与模型参数设置

试验使用的硬件环境包括 NVIDIA GeForce RTX 3070 GPU(8 GB 显存)和 Intel Core i9-2.50 GHz 处理器; 软件运行环境包括 Python 3.8、Pytorch 1.10.1 深度学习框架以及 CUDA 11.3。在模型训练期间, 学习率设定为 0.000 1, 批处理大小为 128, 采用 Adam 优化器对每个模型进行训练, 同时采用交叉熵损失以评估模型故障分类结果与真实标签之间差异。提出的 MAADNet 模型参数设置在表 2 中展示。Conv1D 模块和 MAAD 模块的参数分别代表[输入通道数, 输出通道数, 卷积核大小, 卷积步长大小]。AAP 模块的参数表示[特征图输出大小], FC 模块的参数代表[输入通道数, 输出通道数]。最后的 FC 层输出为 4 个神经元, 相等于局部放电故障类型数量。不同层特征图的输出尺寸在表 2 的最后一栏显示, 三维形式表示批处理大小×通道数×长度, 二维形式表示批处理大小×通道数。MAAD 模块的其余参数设置在图 1 中给出。

3.3 试验评价指标

在试验中, 使用识别准确率 A 、精确度 P 、调和平均值 F_1 来评估所提出方法的性能。准确率是评估分类模型性能的重要指标, 衡量正确分类结果占样本总数的比例; 精确度反映模型预测为阳性的样本中实际为阳性的样本比例; F_1 能够综合反映模型在精确度 P 和召回率 R 上的指标。各指标的表达式为:

$$A = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \quad (15)$$

$$R = \frac{T_p}{T_p + F_N}, P = \frac{T_p}{T_p + F_p} \quad (16)$$




图 4 4 种故障类型下的局部放电时域波形

Fig.4 Time-domain waveforms of partial discharges under four fault types

$$F_1 = \frac{2PR}{P+R}$$

(17)

式中： T_p 为正确预测的阳性样本； T_N 为正确预测的阴性样本； F_p 为阴性样本被错误预测为阳性样本； F_N 为阳性样本被错误预测为阴性样本。

3.4 模型性能对比

为了验证所提 MAADNet 在局部放电模式识别中的有效性，将 MAADNet 与 6 种基于深度学习的先进方法(1DCNN^[17]、DenseNet^[21]、MobileNet^[15]、ResNet^[20]、DRSN^[23]、Swin Transformer^[5])和 4 种传统机器学习方法(SVM^[9]、RF^[10]、BPNN^[11]、XGBoost^[13])进行比较，结果展示在表 3 中。所有网络的训练策略保持一致，结果表示为 4 种局部放电故障类型在每个指标下的平均值。

通过观察表 3 可得，基于机器学习的方法准确率均低于深度学习方法，主要归因于它们相对简单的模型结构。对于深度学习模型，1DCNN 由于网络层较浅且缺乏残差结构，识别准确率受限。相比之下，如 ResNet、MobileNet、DenseNet、DRSN 和 Swin Transformer 等深层网络架构能够进一步提高识别准确率。其中 DRSN 虽然具备一定去噪能力，但其采用注意力机制较简单，仅关注到通道特征，难以提取更全面的故障特征表达；基于多头自注意力机制的 Swin Transformer 具备强大的全局特征提取能力和长距离依赖建立能力^[5]，在各指标上达到

了大约 92% 的识别准确率。然而，该模型在处理含噪复杂局放信号时存在限制，且由于多头自注意力机制在大数据集上涉及复杂的矩阵运算，计算效率较低。

本文提出的 MAADNet 在识别准确率、精确度和调和平均值上分别达到了 94.34%、94.36%和 94.35%，显著优于其他先进方法。相比于 1DCNN，MAADNet 在识别准确率、精确度以及调和平均值上分别提高了 21.4%，21.47%和 21.41%；与 DRSN 相比，MAADNet 则分别提升了 8.16%、7.96%和 8.06%。此外，相比于 Swin Transformer，MAADNet 同样展现出更高的识别准确率，在各指标上提升了大约 2%，这些性能的提升主要归功于 MAADNet 具备出色的自适应去噪能力和多尺度故障特征学习能力。

为了直观地展示不同模型对局部放电故障类型分类的有效性，采用 t 分布随机邻域嵌入 (t-distributed stochastic neighbor embedding, t-SNE) 算法^[29]以可视化模型对 4 种故障特征的分类效果，结果如图 5 所示，不同颜色表示不同的放电类型，详见图例标签。可视化聚类结果表明，BPNN 的性能最差，不同故障类别的特征之间存在明显重叠，难以清晰区分 4 种故障类型。1DCNN、ResNet、DRSN 和所提 MAADNet 表现出一定的区分能力，但不同类别之间仍存在不同程度的特征重叠现象。相比于其他方法，本文所提方法则表现出更优越的故障分类性能，但由于悬浮金属放电和气隙放电之间波形较相似，所提方法在这 2 种故障特征之间仍有一定的重叠现象，t-SNE 可视化结果进一步证明了所提方法的有效性。图 6 通过混淆矩阵以进一步评估不

同模型在 4 种局部放电故障类型上的具体分类性能。在混淆矩阵中，标签 0、1、2 和 3 分别对应尖端放电、气隙放电、悬浮金属放电和沿面放电，右轴表示混淆矩阵中每个元素的数值大小。模型在不同故障类型上的分类性能可通过对角线上颜色的

表 2 MAADNet 模型参数设置

Table 2 MAADNet model parameter settings

网络层数	模块名称	网络参数	输出大小
1	Input	None	128×1×2048
1	Conv1D	[1, 64, 3, 2]	128×64×1024
1	MAAD	[64, 128, 3, 2]	128×128×512
3	MAAD	[128, 128, 3, 1]	128×128×512
1	MAAD	[128, 256, 3, 2]	128×256×256
3	MAAD	[256, 256, 3, 1]	128×256×256
1	AAP	[1]	128×256×1
1	Reshape	None	128×256
1	FC	[128,64]	128×64
1	FC	[64,4]	128×4

表 3 所提方法与其他先进方法的性能比较

Table 3 Performance comparison of the proposed method with other excellent methods

评价指标	数值										
	SVM	RF	XGBoost	BPNN	1DCNN	ResNet	MobileNet	DenseNet	DRSN	Swin-T	MAADNet
A/%	45.57	56.32	66.73	64.59	72.94	81.83	83.70	85.31	86.18	92.37	94.34
P/%	42.27	56.31	67.26	66.65	72.89	82.13	84.21	85.39	86.40	92.58	94.36
F ₁ /%	37.83	56.31	67.00	65.60	72.94	81.98	83.94	85.34	86.29	92.48	94.35




图5 不同模型的 t-SNE 聚类特征可视化结果

Fig.5 Visualization results of t-SNE clustering features for different models

直观判断。观察图 6 可知大部分模型能够准确识别出尖端放电,但在识别其他类型的放电时则表现出不同程度的混淆现象。相比于其他方法,所提 MAADNet 能够更为准确地识别出每种故障类型,进一步证实了所提方法的有效性。

3.5 消融试验

为验证所设计的 MFLM 以及 CBAM 注意力机制和软阈值函数共同构成的自适应去噪模块 (adaptive denoising module, ADM),本文在现场局部放电数据集上进行消融试验,所得结果如表 4 所示。试验中采用 ResNet 作为基准模型进行比较,并依次将每个模块加入到基准模型中。此外,为进一步验证 ADM 的自适应去噪能力,本文还引入典型的去噪算法——奇异值分解(singular value decomposition, SVD)、小波变换(wavelet transform, WT)和经验模式分解(empirical mode decomposition,

EMD)进行比较。这些去噪算法首先对局部放电信号进行去噪,然后将去噪后的信号输入到基准模型中进行比较,所有试验均在相同的训练参数和环境条件下进行。如表 4 所示,与基线相比,使用 SVD、EMD 和 WT 算法在输入网络前首先进行去噪预处理能够在一定程度上提高故障识别准确率,其中 WT 去噪算法的表现优于 SVD 和 EMD。相比之下,包含 ADM 模块的基准模型在识别准确率、精确度和调和平均值指标上均优于 WT 去噪算法,分别提高 3.24%、3.1%和 3.18%。此外,仅添加 MFLM 模块同样表现出性能的提升,与基准模型相比,在准确率、精确度和调和平均值方面分别提高了 2.64%、4.29%和 3.46%,这些结果的提升证明了所提各个模块的有效性。此外,表 4 中最后一行显示,结合 MFLM 和 ADM 模块构成的 MAADNet,能够充分发挥 2 种模块优势,相比于仅添加单一模块的基准模型,识别准确率得到进一步提高。

4 结论

1) 本文所提 MAADNet 通过集成多尺度特征学习模块、CBAM 注意力机制模块和软阈值函数,有效实现了模型对输入时序局放信号的自适应去噪能力以及丰富的多尺度故障特征提取能力,该方法无须额外设计去噪算法,避免了人工设置去噪阈值产生的误差以及对专家经验的依赖。

2) 本文通过搭建局部放电试验平台并设计 4 种局放故障模型以模拟 GIS 内部不同放电类型的产生过程,通过采用原始含噪一维时间序列的样本数据构建局部放电数据集用于模型训练和测试。

3) 本文通过引入多种先进方法与所提 MAADNet 进行对比,包括 6 种基于深度学习的方法——1DCNN、DenseNet、MobileNet、ResNet、DRSN、Swin Transformer 和 4 种基于机器学习的传统方法——SVM、RF、BPNN 和 XGBoost。试验结果表明,所提 MAADNet 在识别准确率、精确度和调和平均值指标上均表现优异,分别高达 94.34%、94.36%和 94.35%,明显优于其他先进方法。与 1DCNN 相比,所提 MAADNet 在各指标上则分别提高 21.4%、21.47%和 21.41%;相比于 Swin Transformer,所提 MAADNet 同样展现出性能优势,在各指标上分别提升约 2%。

4) 本文利用 t-SNE 算法和混淆矩阵对不同模型的故障分类结果进行可视化分析,所得试验结果




图 6 不同模型的混淆矩阵比较

Fig.6 Comparison of confusion matrices for different models

表 4 所提模块的消融试验

Table 4 Ablation experiments for the proposed module

方法	ADM	MFLM	$A\%$	$P\%$	$F_1\%$
基准模型	—	—	81.83	82.13	81.98
SVD	—	—	85.37	85.46	85.41
WT	—	—	87.62	87.77	87.69
EMD	—	—	86.26	86.31	86.28
MAADNet	√	—	90.86	90.87	90.87
	—	√	84.47	86.42	85.44
	√	√	94.34	94.36	94.35

注: “√”表示包含该模块, “—”表示未添加该模块。

进一步证明 MAADNet 相比于其他先进方法在各故障类型识别上具有更优秀的分类性能。

5) 本文通过开展消融试验以进一步验证所提多尺度特征学习模块以及自适应去噪模块的有效性。通过将 ResNet 作为基准模型, 并引入 SVD、WT 以及 EMD 等去噪算法进行对比, 试验结果证实这 2 个模块均能显著提升模型性能。其中添加自适应去噪模块的基准模型在识别准确率、精确度和调和平均值指标上均优于其他典型去噪算法, 相比于 WT 算法, 包含自适应去噪模块(ADM)的基准模型在各指标上实现了 3.24%、3.1%和 3.18%的提升。

参考文献 References

[1] 杨朝锋, 王 敏, 赵胜男, 等. 基于深度学习融合的高压电缆局部放电诊断算法研究[J]. 高压电器, 2023, 59(11): 65-73.
YANG Chaofeng, WANG Min, ZHAO Shengnan, et al. Research on partial discharge diagnosis algorithm for high voltage cable based on deep learning fusion[J]. High Voltage Apparatus, 2023, 59(11): 65-73.

[2] 孙 源, 宋颜峰, 王昊天, 等. 开关柜局部放电超声-TEV 融合检测技术[J]. 高电压技术, 2023, 49(12): 5052-5060.
SUN Yuan, SONG Yanfeng, WANG Haotian, et al. Ultrasonic-TEV combined detection technology of partial discharge in switchgear[J]. High Voltage Engineering, 2023, 49(12): 5052-5060.

[3] 刘 健, 张薛鸿, 张小庆, 等. 预防电缆沟起火的小电流接地系统单相接地故障处理[J]. 电力系统保护与控制, 2023, 51(6): 21-29.
LIU Jian, ZHANG Xuehong, ZHANG Xiaoqing, et al. Treatment of a single-phase grounding fault in a small current grounding system to prevent fire in a cable trench[J]. Power System Protection and Control, 2023, 51(6): 21-29.

[4] 蒋 超, 徐 妍, 王江彬, 等. 单局放传感器电缆局部放电源点定位方法研究[J]. 电子设计工程, 2022, 30(2): 24-27, 32.
JIANG Chao, XU Yan, WANG Jiangbin, et al. Research on localization method of cable partial discharged point by single partial discharged sensor[J]. Electronic Design Engineering, 2022, 30(2): 24-27, 32.

[5] 张雨啸, 张 贲, 宋 辉, 等. 非典型数据集下基于 Swin Transformer 的局部放电模式识别[J/OL]. 高电压技术, 2024: 1-11 [2024-05-24]. <https://doi.org/10.13336/j.1003-6520.hve.20231854>.

ZHANG Yuxiao, ZHANG Ben, SONG Hong, et al. Partial discharge pattern recognition based on Swin Transformer in atypical datasets[J/OL]. High Voltage Engineering, 2024: 1-11 [2024-05-24]. <https://doi.org/10.13336/j.1003-6520.hve.20231854>.

[6] 周远翔, 赵健康, 刘 睿, 等. 高压/超高压电力电缆关键技术分析及展望[J]. 高电压技术, 2014, 40(9): 2593-2612.
ZHOU Yuanxiang, ZHAO Jiankang, LIU Rui, et al. Key technical analysis and prospect of high voltage and extra-high voltage power cable[J]. High Voltage Engineering, 2014, 40(9): 2593-2612.

[7] 万中一, 胡 岳, 陈炳树, 等. 基于能量谱分析和 DBSCAN 改进算法的多源局部放电分类识别方法[J]. 高电压技术, 2023, 49(10): 4335-4344.
WAN Zhongyi, HU Yue, CHEN Bingshu, et al. Multi-source partial discharge classification and recognition method based on energy spectrum analysis and DBSCAN improved algorithm[J]. High Voltage Engineering, 2023, 49(10): 4335-4344.

[8] HUSSEIN R, SHABAN K B, EL-HAG A H. Robust feature extraction and classification of acoustic partial discharge signals corrupted with noise[J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(3): 405-413.

[9] LI X, WANG X H, YANG A J, et al. Partial discharge source localization in GIS based on image edge detection and support vector machine[J]. IEEE Transactions on Power Delivery, 2019, 34(4): 1795-1802.

[10] 刘文浩, 吴毅江, 李文泽, 等. 基于随机决策森林的高压电缆局部放电模式识别[J]. 高压电器, 2022, 58(6): 165-170, 177.
LIU Wenhao, WU Yijiang, LI Wenze, et al. Partial discharge pattern recognition of high-voltage cables based on random forest method[J]. High Voltage Apparatus, 2022, 58(6): 165-170, 177.

[11] LI L P, TANG J, LIU Y L. Partial discharge recognition in gas insulated switchgear based on multi-information fusion[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2015, 22(2): 1080-1087.

[12] 艾嘉伟, 牛海清, 陈泽铭, 等. 基于神经网络的 D-S 多信息融合 GIL 局部放电联合识别方法[J]. 高电压技术, 2022, 48(12): 4925-4932.
AI Jiawei, NIU Haiqing, CHEN Zeming, et al. D-S multi information fusion GIL partial discharge joint recognition method based on neural network[J]. High Voltage Engineering, 2022, 48(12): 4925-4932.

[13] 刘维功, 王昊展, 时振堂, 等. 基于改进 XGBoost 算法的 XLPE 电缆局部放电模式识别研究[J]. 电测与仪表, 2022, 59(4): 98-106.
LIU Weigong, WANG Haozhan, SHI Zhentang, et al. Research on partial discharge pattern recognition of XLPE cable based on improved XGBoost algorithm[J]. Electrical Measurement & Instrumentation, 2022, 59(4): 98-106.

[14] 苏审言, 张建德. 基于概率神经网络的变压器局部放电模式识别[J]. 电气自动化, 2022, 44(3): 91-93.
SU Shenyang, ZHANG Jiande. Pattern recognition of partial discharge of transformer based on probabilistic neural network[J]. Electrical Automation, 2022, 44(3): 91-93.

[15] WANG Y X, YAN J, YANG Z, et al. GIS partial discharge pattern recognition via lightweight convolutional neural network in the ubiquitous power Internet of Things context[J]. IET Science, Measurement & Technology, 2020, 14(8): 864-871.

[16] 潘如政, 李怀宇, 崔 巍, 等. 基于卷积神经网络与可视图像的类滑动放电模式识别[J]. 高电压技术, 2024, 50(1): 423-431.
PAN Ruzheng, LI Huaiyu, CUI Wei, et al. Pattern recognition of microsecond pulsed sliding-like discharge based on convolutional neural network and visual image[J]. High Voltage Engineering, 2024, 50(1): 423-431.

- [17] 宋 辉, 代杰杰, 张卫东, 等. 复杂数据源下基于深度卷积网络的局部放电模式识别[J]. 高电压技术, 2018, 44(11): 3625-3633.
SONG Hui, DAI Jiejie, ZHANG Weidong, et al. Partial discharge pattern recognition based on deep convolutional neural network under complex data sources[J]. High Voltage Engineering, 2018, 44(11): 3625-3633.
- [18] PENG X S, YANG F, WANG G J, et al. A convolutional neural network-based deep learning methodology for recognition of partial discharge patterns from high-voltage cables[J]. IEEE Transactions on Power Delivery, 2019, 34(4): 1460-1469.
- [19] KHAN M A, CHOO J, KIM Y H. End-to-end partial discharge detection in power cables via time-domain convolutional neural networks[J]. Journal of Electrical Engineering & Technology, 2019, 14(3): 1299-1309.
- [20] 许辰航, 陈继明, 刘伟楠, 等. 基于深度残差网络的 GIS 局部放电 PRPD 谱图模式识别[J]. 高电压技术, 2022, 48(3): 1113-1123.
XU Chenhang, CHEN Jiming, LIU Weinan, et al. Pattern recognition of partial discharge PRPD spectrum in GIS based on deep residual network[J]. High Voltage Engineering, 2022, 48(3): 1113-1123.
- [21] FU Y W, LIANG L J, HUANG W H, et al. Partial discharge pattern recognition method based on transfer learning and DenseNet model[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2023, 30(3): 1240-1246.
- [22] TONG J Y, LIU C, BAO J H, et al. A novel ensemble learning-based multisensor information fusion method for rolling bearing fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-12.
- [23] ZHAO M H, ZHONG S S, FU X Y, et al. Deep residual shrinkage networks for fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16(7): 4681-4690.
- [24] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//Proceedings of the 15th European Conference on Computer Vision-ECCV 2018. Munich, Germany: Springer, 2018: 3-19.
- [25] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, USA: IEEE, 2016: 770-778.
- [26] 林天骄, 宋浏阳, 李 石, 等. 基于空洞卷积神经网络的旋转机械故障诊断方法[J]. 测控技术, 2020, 39(12): 98-104.
- LIN Tianjiao, SONG Liuyang, LI Shi, et al. Fault diagnosis of rotating machinery based on atrous convolution-convolutional neural network[J]. Measurement & Control Technology, 2020, 39(12): 98-104.
- [27] 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.
- [28] LIU Z L, WANG H, LIU J J, et al. Multitask learning based on lightweight 1DCNN for fault diagnosis of wheelset bearings[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 3501711.
- [29] 史 强, 刘 鹏, 李金嵩, 等. 基于 t-SNE 与 CFSFDP 算法的多源局部放电脉冲分类技术[J]. 中国电力, 2022, 55(5): 102-110.
SHI Qiang, LIU Kun, LI Jinsong, et al. Multi-source partial discharge pulse classification technology based on t-SNE and CFSFDP algorithms[J]. Electric Power, 2022, 55(5): 102-110.



ZHENG Shangpo

郑尚坡

2001—, 男, 硕士生

主要从事电气设备状态监测、绝缘故障诊断、机器学习和深度学习等方面的研究

E-mail: auzhengshangpo@mail.scut.edu.cn



ZENG Jun

曾 君(通信作者)

1979—, 女, 博士, 教授, 博导

主要从事微电网能量管理、功率变换、电力电子装置和可再生能源发电系统等方面的研究

E-mail: junzeng@scut.edu.cn

Ph.D., Professor

Corresponding author

收稿日期 2024-05-29 修回日期 2025-01-19 编辑 曾文君