

DOI: 10.12158/j.2096-3203.2025.05.017

油纸绝缘缺陷多源局放超声混合脉冲识别方法

董冰冰¹, 李秉华¹, 李建生²

(1. 合肥工业大学电气与自动化工程学院, 安徽 合肥 230009;

2. 国网江苏省电力有限公司电力科学研究院, 江苏 南京 211103)

摘要:为解决传统模式识别分类器在变压器油纸绝缘缺陷局放超声混合脉冲识别中存在漏检的问题,文中提出一种基于改进 YOLOv8 的多源局放诊断模型。首先,采集 3 种变压器典型缺陷超声脉冲信号,使用连续小波变换(continuous wavelet transform, CWT)将单源脉冲映射为二维时频谱图并进行灰度化处理,在保留图谱时频特征相对强度信息下创建高对比度效果。然后,使用基于梯度惩罚生成对抗网络(Wasserstein generative adversarial network with gradient penalty, WGAN-GP)的数据增强方法对样本库进行扩充,解决超声脉冲缺陷训练用样本类间不平衡问题,并借助 t -分布随机邻域嵌入(t -distributed stochastic neighbor embedding, t -SNE)算法对部分生成样本进行降维分析,剔除低质量生成样本,保证生成样本数据集质量。最后,引入全局注意力机制(global attention mechanism, GAM)对目标检测算法 YOLOv8 进行改进,提出适用于变压器局放超声时频谱图的多源局放脉冲诊断模型,使用该模型对多源局放测试集进行识别,各类型局放平均识别准确率可达 95.67%,验证了文中方法的有效性。

关键词:变压器;油纸绝缘缺陷;超声波检测法;多源局放;模式识别;目标检测

中图分类号:TM854

文献标志码:A

文章编号:2096-3203(2025)05-0176-12

0 引言

变压器作为发电厂、变电站的核心设备之一,承担着输、变电的重要任务,其安全稳定运行保证着高质量电能对用户端的持续供给^[1-4]。局部放电(下文简称“局放”)是加速变压器内部油纸绝缘劣化的主要原因,对变压器进行局放在线监测,分析局放信号是有效诊断变压器内部绝缘状态的重要途径^[5-6]。不同类型的放电形成机理具有较大差异,对变压器绝缘造成的危害程度也不同。依据监测的局放信号准确识别局放类型^[7],对制定变压器检修与维护计划具有重要意义。

超声波检测法具有现场操作简单、应用便捷的特点,是现场运行人员进行电力设备局放检测的重要手段^[8-11]。为使用超声检测法对变压器局放类型进行诊断,国内外学者往往运用信号处理方法提取局放超声脉冲辅助特征量作为输入,并进行分类器设计实现模式识别。文献[12]针对一维局放超声信号建立其分段自仿射模型,并提取分形特征作为参量输入人工神经网络,对放电模式进行识别;文献[13]使用对称点模式(symmetrized dot pattern, SDP)算法将声信号映射为图像,并输入卷积神经网络模型完成识别任务,验证了使用单脉冲转化图谱

识别局放类型的有效性;文献[14]分别采集超声信号、特高频信号的典型缺陷样本,构造对应的汉克尔矩阵并提取奇异值特征作为输入,应用反向传播神经网络进行识别,结果显示,超声法识别准确率为 75%,低于特高频法。超声波检测法的识别准确率亟待提高,且以上方法构建的分类器仅可对变压器单类型局放脉冲进行识别。但变压器本身结构复杂,长时间运行下可能在不同位置出现多处放电源,致使局放监测系统所获取信号为多种放电脉冲的混合叠加,以单源局放为识别对象而设计的分类器在此情况下易出现漏检。

针对此类问题,有学者提出将多源局放脉冲进行聚类分离从而转换为单源脉冲进行识别^[15],即将多源局放诊断任务转化为多个单源局放诊断任务。文献[16]使用近邻传播聚类(affinity propagation clustering, APC)对多源脉冲进行分离,并提取脉冲相位-幅值特征结合支持向量机(support vector machine, SVM)分类器实现局放类型识别;文献[17]使用累计能量函数表征局放脉冲时频特征并提取上升陡度参量,验证了其在特高频局放脉冲分离方面的有效性;文献[18]对脉冲进行 S 变换时频分析,提取时频幅值特征与典型缺陷时频数据库混合,基于聚类方法实现多源脉冲分离。以上研究可有效解决时域可分的多源脉冲识别问题,但对于脉冲波形在时域上出现混合的情况,其分离性能可能会受影响,降低最终局放识别准确率。

收稿日期: 2025-01-03; 修回日期: 2025-03-12

基金项目: 安徽省自然科学基金资助项目(2508085ME114);
国家电网有限公司科技项目(SGAHBZ00TKJS2400327)

为实现对变压器多源局放时域混合脉冲的有效识别并降低漏检率, 文中搭建变压器典型油纸绝缘缺陷超声局放检测平台, 获取典型油纸绝缘缺陷(尖端、悬浮和气隙)单源局放超声信号脉冲时间分布模式样本, 使用连续小波变换(continuous wavelet transform, CWT)进行特征可视化获取时频图谱, 对其进行灰度化处理, 在保留图谱时频特征相对强度信息下创建高对比度效果, 增强特征辨识度; 将实测单源局放脉冲作为诊断模型训练集, 借助基于梯度惩罚生成对抗网络(Wasserstein generative adversarial network with gradient penalty, WGAN-GP)的数据增强方法对样本进行扩充以解决训练数据集类间不平衡问题; 引入全局注意力机制(global attention mechanism, GAM)对目标检测算法 YOLOv8 进行改进, 提出适用于变压器局放超声时频图谱的多源局放脉冲诊断模型, 使用扩充后的训练集数据对模型进行训练, 并使用多源局放数据作为测试集验证诊断模型的有效性。

1 超声局放数据获取与预处理方法

1.1 试验平台搭建与信号采集

为采集变压器典型局放缺陷超声信号, 构建超声局放脉冲数据库, 文中搭建变压器内部放电故障模拟试验平台, 实时获取超声局放信号^[19-22]。试验平台如图 1 所示, 主要包括无局放工频电压源、油纸绝缘缺陷模型以及用于监测局放脉冲的超声局放测量系统。




图 1 油纸绝缘缺陷超声局放检测平台

Fig.1 Ultrasonic localized discharge detection platform for oil paper insulation defects

考虑到局放发生机理与条件, 文中制作 3 种典型油纸绝缘缺陷模型模拟常见油浸式变压器内部缺陷。缺陷模型结构如图 2 所示, 分别用于模拟尖端放电、悬浮放电以及气隙放电。模型设置如下: (1) 尖端缺陷, 使用针板电极进行模拟, 尖端部分长 15 mm; (2) 悬浮缺陷, 将 20 mm 铁针水平插入绝缘圈进行固定, 放置于接地电极之上用于模拟悬

浮电位放电; (3) 气隙缺陷, 气隙结构使用 3 层厚度为 0.5 mm 的纸板层叠组合进行模拟, 对中间纸板中心部分进行切除。为确保所用厚魏德曼绝缘纸板内部无气泡、水分等杂质, 提前将其放入真空干燥烘箱进行处理, 真空干燥烘箱设置温度为 105 ℃, 压强为 50 Pa, 处理时间为 24 h。考虑到实际变压器长时间运行下油纸绝缘发生老化, 影响局放起始与发展特性, 故在清除杂质后, 对其注入老化油静置 48 h 以模拟变压器长时间运行下油纸绝缘老化状态。试验时缺陷模型各部分均浸入 25 号变压器油。




图 2 油纸绝缘缺陷模型

Fig.2 Oil-paper insulation defect models

变压器内部局放产生的超声波主要分布在 60~300 kHz 的频段内^[23], 故超声传感器 1 选用型号为 PXR15RMH 的超声波传感器, 其谐振频率为 150 kHz, 灵敏度为 65 dB, 该型号超声波传感器可以通过磁吸附安装于磁性材料表面。为增加超声波传感器与变压器油箱壁之间的接触, 在放置传感器前先使用砂布擦拭试验腔体油箱壁侧表面, 并在传感器耦合面和试验腔体油箱壁之间涂抹耦合剂, 在该传感器布置方式下, 所测超声波信号衰减程度进一步降低。所选用示波器型号为 YOKOGAWADLM 3054, 其采样率最高可达 2.5 GS/s, 频率带宽为 5 000 MHz, 并拥有 4 个模拟通道和 8 位逻辑通道。

试验过程中, 首先在油浸式变压器试验腔体内安装油纸绝缘缺陷模型, 然后注入变压器油直至淹没缺陷位置, 最后于试验腔体外侧布置超声传感器, 通过同轴电缆将超声传感器与高速示波器连接, 实时监测超声信号。试验前采用在线监测装置

分别对不同局放缺陷的局放信号进行局放脉冲相位分布(phase resolved partial discharge, PRPD)图谱分析,验证平台超声信号监测有效性。

1.2 频域特征分析

为选取高辨识度特征作为诊断模型输入进行局放识别,首先对超声脉冲进行频域特征统计分析。考虑到现场环境下由于监测系统路径的影响,不同缺陷超声信号幅值可能会存在较大差异,故将所有采集脉冲进行归一化处理,对处理结果使用快速傅里叶变换(fast Fourier transform, FFT)以获取频谱分量统计信息。

频谱分量最大值对应信号中最显著的频率成分,识别其主要频率分量可用于表征信号主要频率分布情况。提取频谱分量最大值与其对应的频率,绘制图3所示统计谱图。尖端缺陷频谱分量最大值出现在50、100、200 kHz附近,其分量最大值幅值分布在0~0.04 mV内;悬浮缺陷频谱分量最大值绝大部分集中出现在100 kHz附近,小部分出现在200 kHz附近,其分量最大值幅值均匀分布在0.01~0.07 mV内;气隙缺陷频谱分量最大值出现在50~100 kHz,其分量最大值幅值分布在0~0.045 mV内。




图3 多缺陷统计谱图

Fig.3 Statistical spectrum of multiple defects

1.3 时频谱图绘制及数据库建立

为进一步对单脉冲进行频域特征综合提取及特征可视化,使用CWT对脉冲进行处理。CWT通过使小波函数平移参数和尺度参数连续变化,实现对信号的过完备表示^[24],其数学计算如式(1)所示。

$$W_f(a,b) = \langle f, \psi_{a,b} \rangle = \int \frac{1}{\sqrt{a}} \psi_{a,b}^* \left(\frac{t-b}{a} \right) dt \quad (1)$$

式中: $W_f(a,b)$ 为信号 f 经连续小波变换后的时频分布结果; f 为待处理信号; ψ 为小波母函数; ψ^* 为 ψ 的复数共轭; a 为尺度因子; b 为位移因子; t 为时间变量。

典型局放超声脉冲信号经处理后映射为二维时频图谱,可视化结果如图4所示。尖端缺陷与悬

浮缺陷能量分布形态相似,时域上分布较窄,频域上分布较宽,高幅值频率分量集中聚集,但出现位置存在差异;气隙缺陷则在时域上分布较宽,频域上分布较窄,高幅值频率分量分布较为分散。




图4 缺陷时频图谱及灰度化处理结果

Fig.4 Time frequency spectrum and grayscale processing results of defect signals

综上,3种缺陷时频图谱存在明显差异,文中诊断模型选取不同类型缺陷局放时频图谱能量聚集区域纹理特征与轮廓差异作为特征进行识别。为增强该特征辨识度,同时保留原图谱相对强度信息,截取其显著频率分量分布区域并进行灰度化处理作为故障诊断模型训练样本,从而简化矩阵,提高算法运算速度。采用最大值方法进行灰度化处理,并调整强度范围,创建高对比度效果。

常规相似性分析方法通过计算处理前后图谱像素数值差值进行评价,考虑到灰度化过程对像素数值的固有影响,其计算结果不适用于表征图谱边缘纹理信息保留程度。边缘纹理信息主要体现在像素数值变化趋势,故引入统计梯度信息作为评估指标,通过计算偏导获取梯度矢量 ∇f 表征图谱中

信息相对强度变化^[25], 梯度幅值与方向计算见式(2)—式(4)。

$$\nabla f = \begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f(x,y)}{\partial x} \\ \frac{\partial f(x,y)}{\partial y} \end{bmatrix}$$

(2)

$$g = \sqrt{g_x^2 + g_y^2}$$

(3)

$$\theta = \arctan \frac{g_y}{g_x}$$

(4)

式中: $f(x, y)$ 为二维离散函数, x 为水平方向变量, y 为垂直方向变量; g_x 为水平方向梯度矢量; g_y 为垂直方向梯度矢量; g 为水平与垂直方向的合梯度幅值; θ 为梯度方向, 范围为 $0^\circ \sim 180^\circ$ 。

计算结果为梯度幅值矩阵与梯度方向矩阵, 据此可绘制梯度方向直方图, 如图 5 所示。使用 3 种常用相似度评价指标比较灰度处理前后梯度方向直方图, 结果如表 1 所示。3 种类型图谱均方误差均趋于 0, 余弦相似性与相关系数趋于 1, 表明处理前后图谱梯度统计信息呈强相关性, 边缘纹理特征损失极少, 可使用该灰度化处理后图谱进行模式识别。




图 5 梯度方向直方图
Fig.5 Histogram of gradient direction

试验采集得到的超声局放脉冲共 1 479 个, 其中尖端缺陷 425 个, 悬浮缺陷 500 个, 气隙缺陷 554 个。使用文献^[26]提出的多源局放脉冲构建方法, 在原始样本中分别抽取 100 个局放脉冲用于构造多源局放脉冲。多源局放为变压器内部不同位

表 1 梯度方向直方图相似度对比结果
Table 1 Gradient direction histogram similarity rating comparison results

局放类型	相似度评价指标		
	均方误差	余弦相似性	相关系数
尖端缺陷	0.001	0.982	0.979
悬浮缺陷	0.005	0.988	0.978
气隙缺陷	0.004	0.986	0.981

置出现局放, 并各自激发出超声信号, 各局放源在放电机理方面互相影响较小, 具有相对独立性; 且声学中认为声波是一种机械波, 遵循波的叠加原理, 故检测点超声传感器接收到的声波信号可以视为所有声源发出的声波信号的叠加。具体构造方法为参照缺陷信号 PRPD 谱图, 获取各类型缺陷脉冲在 20 ms 周波内的分布位置, 将抽取的各缺陷脉冲随机选取并按相位分布范围随机线性叠加, 依次构建多源局放脉冲。所采集的单源脉冲与构造的多源脉冲数量如表 2 所示, 多源脉冲构造完成后与单源局放脉冲使用相同方法绘制二维灰度化时频谱图。

表 2 油纸绝缘缺陷时频图谱绘制及分配结果
Table 2 Drawing and distribution results of time-frequency spectra with oil paper insulation defects

局放类型	放电类型	数量
单源局放	尖端	425
	悬浮	500
	气隙	554
多源局放	尖端-悬浮	100
	尖端-气隙	100
	悬浮-气隙	100
	多处尖端	100
	多处悬浮	100
	多处气隙	100

2 多源局放脉冲模式识别方法

2.1 数据增强模型

局放脉冲样本整体数量不足以及类间数量不均衡的问题将会影响模式识别算法训练过程, 降低最终识别准确率, 对局放脉冲样本进行数据增强操作, 建立数量充足且均衡的样本库是提高识别准确率的重要步骤。局放脉冲时频图谱表征局放脉冲在某时刻的频率以及该频率分量的强度, 具有特定物理意义, 传统数据增强方式如翻转、镜像、旋转等并不适用于该图谱。

基于机器学习的生成对抗网络(generative adver-

sarial network, GAN)作为新兴的数据增强技术在图像与声信号领域得到广泛应用^[27],其变种方法 WGAN-GP 基本框架如图 6 所示。

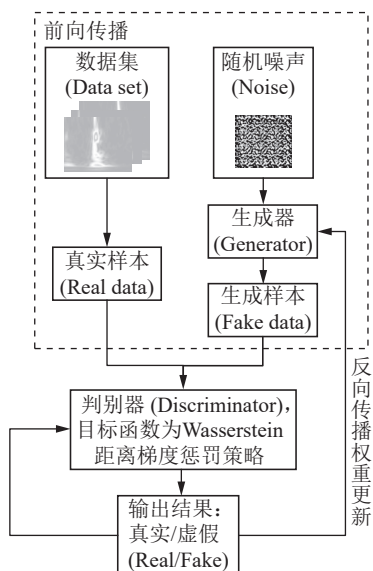


图 6 WGAN-GP 基本框架

Fig.6 Basic framework of WGAN-GP

WGAN 在 GAN 基础上引入 Wasserstein 距离作为度量 2 个分布相似性的方法,替换 GAN 的目标函数。该距离与 JS 散度相比的优越性在于即使 2 个分布之间没有重叠,依然可以反映 2 个分布远近程度,增强训练稳定性。Wasserstein 距离计算如下:

$$W(P_{\text{data}}, P_G) = \inf_{r \sim \prod(P_{\text{data}}, P_G)} E \left(\sqrt{\sum_{i=1}^n (u_i - v_i)^2} \right) \quad (5)$$

式中: P_{data} 为真实样本分布; P_G 为生成样本分布; $\prod(P_{\text{data}}, P_G)$ 为 P_{data} 和 P_G 的联合概率分布的集合; E 为求取数学期望; r 为从分布中采样得到真实样本 u 和生成样本 v 的分布; u_i, v_i 分别为第 i 个真实样本和生成样本; n 为样本数量。

引入 Wasserstein 距离能改善 GAN 网络训练不稳定、生成器生成样本缺乏多样性等问题。但为正确计算该距离,须保证判别器输出变化不能太快,其梯度范数不能超过 1。为此 WGAN-GP 引入利普希茨(Lipschitz)连续条件限制函数最大局部变动幅度,并以梯度惩罚项的形式加入到判别器损失函数中,将判别器相对于原始输入梯度的 L2 范数约束在 1 附近,取代 WGAN 中的权重修剪策略,该网络生成器损失函数 L_G 与判别器损失函数 L_D 计算分别见式(6)、式(7)。

$$L_G = -E(D(G(z))) \quad (6)$$

式中: $G(z)$ 为生成器的输出,表示由噪声向量 z 生成的样本; $D(\cdot)$ 为判别器输出; P_z 为噪声向量 z 的分布。

$$L_D = E_{z \sim P_z} (D(G(z))) - E_{u \sim P_{\text{data}}} (D(u)) + \lambda E_{\hat{u} \sim P_{\hat{u}}} \left((\|\nabla_{\hat{u}} D(\hat{u})\|_2 - 1)^2 \right) \quad (7)$$

式中: λ 为梯度惩罚系数; $\hat{u}$ 为真实样本与生成样本之间的线性差值; $P_{\hat{u}}$ 为线性差值的分布; $\|\nabla_{\hat{u}} D(\hat{u})\|_2$ 为原始输入梯度的 L2 范数。

梯度惩罚策略的优势在于将判别器梯度更新始终维持在可控范围内,有效提升网络训练速度。综上,文中模型使用 WGAN-GP 网络生成超声脉冲二维时频谱图,解决样本总量不足以及样本类间数量不均衡的问题。

2.2 诊断模型

变压器局放模式识别通常使用图像分类算法学习局放图谱特征与类型标签之间的关系,设计分类器实现对局放图谱的单标签分类。当图谱中出现多个局放特征时,该分类器仅会输出最显著局放特征所属类别标签,导致其余局放漏检。为解决该问题,引入可对多特征进行标记与识别的单阶段目标检测算法 YOLOv8。该算法主要由主干网络、颈部网络、检测头部模块组成^[28-29],其网络结构如图 7 所示。




图 7 YOLOv8 网络结构

Fig.7 Network structure of YOLOv8

YOLOv8 使用 Darknet-53 网络作为主干,并将

原 C3 模块替换为 C2f 模块, 进一步提升特征提取能力, 主干网络作为主要特征提取器, 负责从输入图谱中获取对象信息; 颈部网络则对提取特征进行整合与加工, 用于处理不同尺度的特征信息, 提升检测性能; 检测头部模块则应用解耦头结构, 负责将最终特征转换为包含目标位置和类别信息的目标检测输出。

由频域分析可知, 相比于尖端缺陷与悬浮缺陷, 气隙缺陷超声脉冲主要频率分布范围较窄, 导致其可视化映射特征面积较小, 呈现小目标局放特征, 增大了该类型局放检测难度, 部分图谱的局放识别出现漏检现象。图 8 为模型改进前后对比, 图 8(a) 中, 图谱左下部分气隙缺陷未成功检测, 模型遗漏对此处局放的标记, 该类情况降低了整体检测准确率。




图 8 模型改进前后对比

Fig.8 Comparison between before and after model improvement

引入注意力机制对特征权重进行优化, 提升诊断模型关键特征辨识能力^[30]。在诊断模型特征提取部分即主干网络加入全局注意力机制(global attention mechanism, GAM)模块, GAM 综合了通道注意力机制与空间注意力机制的处理方法。首先在通道注意力子模块中对初始特征图使用一个多层感知器放大跨维通道-空间依赖性, 其输出特征图作为空间注意力子模块的输入, 通过 2 个卷积层进行空间信息融合, 最终实现对图谱中局放特征的加权处理, 选择性强调其中的重要信息, 有效避免漏检。加入 GAM 后检测效果如图 8(b) 所示, 在检测出悬浮缺陷的基础上, 对气隙缺陷特征也实现准确标记与识别。GAM 原理如图 9 所示。

3 多源局放脉冲模式识别方法验证

3.1 诊断模型训练

使用 WGAN-GP 生成模型对单源局放时频谱图样本库进行样本扩充, 借助已有样本数据对




图 9 GAM 原理

Fig.9 GAM principle

WGAN-GP 生成模型进行训练。模型部分参数设置如下: 潜在维度作为生成模型中潜在空间的维度, 其值设为 100, 用于生成随机噪声向量; 隐藏层维度为模型内部用于处理和转换数据的隐藏层的维度, 其值设为 256; 批次大小设为 16; 总训练轮数设为 200, 使模型在训练集上迭代 200 次; 生成器学习率设为 0.003; 判别器学习率设为 0.002。

在生成器训练初始阶段, 生成的图像整体为无序的随机噪声信号, 未呈现任何局放脉冲时频信息; 持续训练至 50 次时, 生成图谱开始显现局放谱图中频率分量聚集区域的边缘特征, 但仍然存在大量噪声点, 且内部细节尚不明显; 训练至 200 次时, 所生成的图谱已呈现出与真实样本相似的时频域特征, 且均有较丰富的多样性, 可辅助后续模式识别算法进行充分的训练, 符合试验预期要求。部分生成样本图谱如图 10 所示。训练完成后, 保存最后一次训练的生成器模型权重文件, 用于单源局放样本扩充。




图 10 部分生成样本

Fig.10 Some of the generated results

为保证生成样本数据集质量, 使用 t -分布随机邻域嵌入算法(t -distributed stochastic neighbor embedding, t -SNE)对真实样本与生成样本进行降维分析^[31], 结果如图 11 所示。其中特征 1、2 为降维过程中产生的融合特征, 无物理量纲。由图 11 可知, 大部分生成样本分布区间与真实样本分布基本重合, 证明该处生成样本与真实样本具有高相似性,

少部分生成样本偏离真实样本分布,说明该处生成样本质量较差,须对该处样本进行删除以保证整体数据集质量。





图 11 生成样本与真实样本相似性对比及须删去样本标记结果

Fig.11 Comparison of similarity between generated and real samples and marking results of samples to be censored


文中选用空间聚类算法(density-based spatial clustering of applications with noise, DBSCAN)对偏离真实样本分布的低质量生成样本进行标记删除。该算法基于数据点密度进行类型划分,具体分为核心点、边界点、噪声点,其中噪声点即为需要删除的目标数据。实施过程中,将真实样本数据全部作为核心点,循环遍历核心点并检查其 ε -邻域,判断生成样本是否属于真实样本邻域,超出邻域范围即视为需要删除的生成样本。

筛选完成后,最终尖端局放谱图达到 1 000 张,悬浮局放谱图达到 990 张,气隙缺陷谱图达到 1 020 张。按 8 : 2 对样本库进行分配,80% 的样本作为 YOLOv8 目标检测算法的训练集,20% 作为验证集,所有多源局放时频谱图均作为该模型测试集。将训练集数据投入改进的 YOLOv8 网络中进行迭代训练,迭代次数设为 150。图 12 为训练过程中两类损失函数变化曲线,其中边界框损失为模型标记区域与实际局放出现区域的差距,可表征模型对于局放特征出现位置标记的精准程度;类别损失为模型识别结果的概率分布与实际标签分布之间的差异,可表征模型对于类别分类的准确程度。随着迭代次数的增加,两类损失均出现明显的下降,在 100 次迭代后趋于平缓,边界框损失最终下降至 0.46,类别损失最终下降至 0.32,验证了模型对时频谱图中局放特征学习的有效性。

诊断模型训练完成以后,使用测试集样本验证识别效果,如图 13 所示。该网络可对单源与多源局放二维时频谱图中出现的特征区域进行标记,并



(a) 验证集边界框损失



(b) 验证集类别损失

图 12 损失函数

Fig.12 Loss function

在标注框上方以标签形式输出该图谱所属局放类型,实现对多种局放特征的模式识别。对于实际变压器运行中可能出现的多处同类型局放和多处不同类型局放,模型均可进行准确的识别与标记。

3.2 诊断模型性能分析

使用各类别精确率和召回率均值对诊断模型性能进行评估^[32],计算方法如下:

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (8)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (9)$$

式中: P 为精确率; R 为召回率; N_{TP} 为正样本被正确识别的数量; N_{FP} 为误报的负样本数量; N_{FN} 为漏检的正样本数量。

图 14、图 15 为训练过程中精确率与召回率两类评价指标变化曲线。训练初期,精确率与召回率均有迅速提升,但存在较大波动,其中召回率波动尤为剧烈,说明在模型训练初期,漏检问题较为严重;随模型训练次数的增加,两指标逐渐提升且趋于稳定,并维持在较高数值,最终精确率达到 96.5%,召回率达到 94.7%,表征各类型局放均可被有效标记与识别。

在此基础上,使用训练过程中平均检测精度 mAP50-95 指标变化对加入 GAM 前后模型性能进行综合评估,该指标是精确率和召回率之间的平衡,并在不同的 IoU 阈值下(从 0.5 到 0.95,步长




图 13 多源局放识别结果

Fig.13 Multi-source partial discharge identification results




图 14 精确率

Fig.14 Accuracy rate

0.05)计算,使用该指标可更全面地了解模型在不同 IoU 要求下的性能。如图 16 所示,初始阶段,GAM 使模型性能指标相对原模型较快达到 56%,但也伴随着较大幅度震荡,随迭代次数增加,指标趋势上稳定上升;在迭代次数达到 75 次时,改进后模型相对原模型性能上有较明显提高,并一直维持到训练结束,最终加入 GAM 后模型指标达到 88%,相对原




图 15 召回率

Fig.15 Recall rate

模型最终结果 85.4%,提升了 2.6 个百分点。




图 16 平均检测精度

Fig.16 Average detection accuracy

选取多种在故障诊断领域具有良好效果的目标检测算法对该数据集进行检测分析,结果如表 3 所示。其中,YOLOv6 与 YOLOv7 在平均检测精度指标 mAP50-95 上相差较小,分别为 83.60% 与 84.00%,YOLOv8 则为 85.40%,在该数据集上效果优于 YOLOv6 与 YOLOv7;在最优基准算法 YOLOv8 上加入多种注意力机制,多头注意力机制(multi-headed self-attention, MHSA)将算法性能提升至 86.36%,但低于引入 GAM 的测试结果。

表 3 识别算法性能对比
Table 3 Comparison of recognition algorithm performance

诊断模型	mAP50-95/%
YOLOv6	83.60
YOLOv7	84.00
YOLOv8	85.40
YOLOv8+MHSA	86.36
YOLOv8+GAM	88.00

在多源局放测试集上使用改进后模型进行局放识别,绘制混淆矩阵,如图 17 所示,该矩阵表示各类型缺陷识别、误判与漏检的比例,颜色越深代表该项比例越接近 100%。其中,尖端缺陷 97% 被准确识别,悬浮缺陷 98% 被准确识别,气隙缺陷 92% 被准确识别,平均识别准确率达到 95.67%,较

原始算法最终结果 93.79%, 提升 2%, 满足局放识别准确率要求。




图 17 混淆矩阵
Fig.17 Confusion matrix

变压器实际运行状态下局放超声信号传播到绕组或铁心界面时会发生折射、反射,对于设置在钢板外壁的传感器,钢板亦会影响超声信号时频域特征分布。根据超声波信号固有传播特性,多种传播介质造成的衰减现象集中出现在信号高频部分,致使信号高频分量幅值下降,结果表现为低频分量基本不衰减,高频分量衰减严重,从而导致信号整体频谱变化。为此,使用低通滤波器(low pass filter, LPF)构建衰减模型,对局放信号进行滤波处理,以模拟多介质传播过程折、反射对信号特征的影响。滤波处理结果如图 18 所示,由滤波前后信号频域特性可知,信号低频段分量基本无衰减,高频段分量出现较为严重的衰减,符合现场信号模拟预期。此外,考虑到现场环境下超声监测装置易受噪声干扰,所监测超声信号为局放信号与噪声信号的叠加,故基于滤波信号对现场噪声局放超声信号进行构建,测试该情况下现场噪声干扰对诊断模型的性能影响。

变压器运行过程存在绕组的热噪声、继电保护线路耦合的各种噪声以及电子元器件运行时产生的散粒噪声等^[33-34],此类噪声分布在整个频带上,性质上属于高斯白噪声。为评估该诊断模型在信号频谱变化及噪声情况下的识别精度,仿照当前去噪领域常见的噪声模拟方法,在滤波超声局放脉冲中加入服从 $N(0, 0.2^2)$ 分布的高斯白噪声,重新制作测试数据集。测试结果显示,在上述情况下,模型依然可以准确对超声局放脉冲进行标记与类型识别,统计指标中平均检测精度 mAP50-95 为 82.3%,平均识别准确率为 91.6%,模型性能指标有所下降,但仍满足检测要求,验证了模型具有一定的抗干扰能力与泛化能力。




图 18 局放超声信号时-频域特性

Fig.18 Time-frequency domain characterization of partial discharge ultrasound signals

4 结论

(1) 文中提出基于超声脉冲时频特征的变压器油纸绝缘缺陷多源局放诊断模型。使用脉冲时频图谱作为识别对象,借助 WGAN-GP 算法解决训练用数据集类间样本数量不均衡问题,并使用 t -SNE 算法控制生成样本集质量;以 YOLOv8 目标检测算

法作为主体,在特征提取模块引入 GAM 进行改进,有效提升模型检测性能。在多源局放测试集上应用该诊断模型,计算得平均检测精度(mAP50-95)可达 88%,较原始算法提升 2.6 个百分点;平均识别准确率可达到 95.67%,较原始算法提升 2%。

(2) 实测气隙缺陷脉冲频率分布范围相对于尖端缺陷与悬浮缺陷较窄,其可视化时频特征面积较小,导致准确识别难度大于其他 2 种缺陷。使用单阶段目标检测算法 YOLOv8 构建的诊断模型对该类小目标局放特征存在标记遗漏问题,且该问题是影响模型整体识别准确率的重要原因。文中研究表明在目标检测算法特征提取模块中引入 GAM 可有效提升模型对小目标局放特征的检测能力,降低该类局放漏检率。

参考文献:

- [1] 龚泽威一, 饶桐, 王钢, 等. 基于改进粒子群优化 XGBoost 的变压器故障诊断方法[J]. 高压电器, 2023, 59(8): 61-69.
GONG Zewei, RAO Tong, WANG Gang, et al. Fault diagnosis method of transformer based on improved particle swarm optimization XGBoost[J]. High Voltage Apparatus, 2023, 59(8): 61-69.
- [2] 宋辉, 代杰杰, 李喆, 等. 运行条件下 GIS 局部放电严重程度评估方法[J]. 中国电机工程学报, 2019, 39(4): 1231-1241.
SONG Hui, DAI Jiejie, LI Zhe, et al. An assessment method of partial discharge severity for GIS in service[J]. Proceedings of the CSEE, 2019, 39(4): 1231-1241.
- [3] MA G M, ZHOU H Y, SHI C, et al. Distributed partial discharge detection in a power transformer based on phase-shifted FBG[J]. IEEE Sensors Journal, 2018, 18(7): 2788-2795.
- [4] 孙世明, 岑红星, 白建民, 等. 基于集成 SAO 优化互相关熵极限学习机模型的变压器故障诊断方法[J]. 电测与仪表, 2024, 61(9): 56-64.
SUN Shiming, CEN Hongxing, BAI Jianmin, et al. Transformer fault diagnosis method based on integrated correntropy extreme learning machine model optimized by SAO[J]. Electrical Measurement & Instrumentation, 2024, 61(9): 56-64.
- [5] 谢虎波, 韩世杰, 钱定冬, 等. 基于 EFPI 传感器的变压器套管局放检测[J]. 电瓷避雷器, 2024(4): 140-148.
XIE Hubo, HAN Shijie, QIAN Dingdong, et al. Partial discharge detection of transformer bushing based on EFPI sensor[J]. Insulators and Surge Arresters, 2024(4): 140-148.
- [6] 谢佳, 杨海涛, 丁国成, 等. 变压器高压套管末屏在线监测系统的设计[J]. 电瓷避雷器, 2023(4): 213-220.
XIE Jia, YANG Haitao, DING Guocheng, et al. On-line monitoring system for end shield of high voltage bushing of transformer[J]. Insulators and Surge Arresters, 2023(4): 213-220.
- [7] 唐志国, 唐铭泽, 李金忠, 等. 电气设备局部放电模式识别研究综述[J]. 高电压技术, 2017, 43(7): 2263-2277.
TANG Zhiguo, TANG Mingze, LI Jinzhong, et al. Review on partial discharge pattern recognition of electrical equipment[J]. High Voltage Engineering, 2017, 43(7): 2263-2277.
- [8] 辛晓虎, 罗勇芬, 杜非, 等. 用于油中局部放电定位的超声波接收阵列的定向算法比较[J]. 中国电机工程学报, 2015, 35(20): 5351-5359.
XIN Xiaohu, LUO Yongfen, DU Fei, et al. Comparisons of direction of arrival algorithms applied to ultrasonic arrays for partial discharge location in oil[J]. Proceedings of the CSEE, 2015, 35(20): 5351-5359.
- [9] 孙云亭, 蔡振江, 程曼, 等. 多超声波传感器局部放电源定位方法的研究[J]. 电子测量与仪器学报, 2016, 30(3): 416-422.
SUN Yunting, CAI Zhenjiang, CHENG Man, et al. Research on partial discharge source localization method of multi-ultrasonic-sensor[J]. Journal of Electronic Measurement and Instrumentation, 2016, 30(3): 416-422.
- [10] 相晨萌, 高树国, 刘宏亮, 等. 基于宽频振动传感器的电力设备状态监测方法可行性分析[J]. 高压电器, 2024, 60(4): 83-91.
XIANG Chenmeng, GAO Shuguo, LIU Hongliang, et al. Feasibility analysis of power equipment condition monitoring method based on broadband vibration sensor[J]. High Voltage Apparatus, 2024, 60(4): 83-91.
- [11] 张宇帅, 隋浩冉, 韩世杰, 等. 一种用于高压电气设备局放超声检测的新型 EFPI 传感器[J]. 电测与仪表, 2024, 61(2): 204-209.
ZHANG Yushuai, SUI Haoran, HAN Shijie, et al. A novel type of EFPI sensor for partial discharge ultrasonic testing of high-voltage electrical equipment[J]. Electrical Measurement & Instrumentation, 2024, 61(2): 204-209.
- [12] 刘云鹏, 律方成, 李燕青. 基于 IFS 的局部放电超声信号的数据压缩和模式识别[J]. 电工技术学报, 2003, 18(6): 93-97.
LIU Yunpeng, LÜ Fangcheng, LI Yanqing. Data compression and pattern recognition for partial discharge supersonic signal based on iterated function system[J]. Transactions of China Electrotechnical Society, 2003, 18(6): 93-97.
- [13] 施胜丹, 黄金军, 朱霄珣, 等. 基于声纹 SDP-CNN 的变压器局部放电模式识别[J]. 电力信息与通信技术, 2022, 20(10): 105-112.
SHI Shengdan, HUANG Jinjun, ZHU Xiaoxun, et al. Partial discharge pattern recognition on transformer based on voiceprint SDP-CNN[J]. Electric Power Information and Communication Technology, 2022, 20(10): 105-112.
- [14] 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.
- [15] 李亚楠. 大型水轮发电机局部放电模式识别方法研究[D]. 武汉: 华中科技大学, 2021.

- LI Yanan. Study on partial discharge pattern recognition method of large hydrogenerator[D]. Wuhan: Huazhong University of Science and Technology, 2021.
- [16] 汪可, 李金忠, 张书琦, 等. 基于时频相似度的油纸绝缘多局部放电脉冲群分离与识别策略[J]. 电工技术学报, 2014, 29(12): 251-260.
WANG Ke, LI Jinzhong, ZHANG Shuqi, et al. Pulses separation and recognition strategy for multiple partial discharge sources of oil-paper insulation based on time-frequency similarity[J]. Transactions of China Electrotechnical Society, 2014, 29(12): 251-260.
- [17] 邵先军, 何文林, 徐嘉龙, 等. 利用累积能量函数特征参量优化提取的多源局部放电信号分离技术[J]. 中国电机工程学报, 2017, 37(11): 3348-3358, 3392.
SHAO Xianjun, HE Wenlin, XU Jialong, et al. Separation technique of multiple source PD signals by employing feature optimization extraction of cumulative energy function[J]. Proceedings of the CSEE, 2017, 37(11): 3348-3358, 3392.
- [18] 高敬贝, 周毓颖, 吴季浩, 等. 基于时频相似度的 GIS 多源局部放电信号分离方法[J]. 高压电器, 2018, 54(12): 245-250.
GAO Jinbei, ZHOU Yuying, WU Jihao, et al. Separation method of GIS multi-source partial discharge signal based on time-frequency similarity[J]. High Voltage Apparatus, 2018, 54(12): 245-250.
- [19] 陈钜栋, 江军, 杨小平, 等. 油浸式高压套管局部放电非接触式特高频检测[J]. 电力工程技术, 2021, 40(1): 147-154.
CHEN Judong, JIANG Jun, YANG Xiaoping, et al. Non-contact partial discharge detection of high voltage oil-impregnated-paper bushing based on UHF technology[J]. Electric Power Engineering Technology, 2021, 40(1): 147-154.
- [20] 刘顺成, 向加佳, 陈剑, 等. 局部放电特高频检测校准影响因素研究[J]. 电力工程技术, 2021, 40(3): 128-134.
LIU Shuncheng, XIANG Jiajia, CHEN Jian, et al. Calibration influence factors of UHF partial discharge detector[J]. Electric Power Engineering Technology, 2021, 40(3): 128-134.
- [21] 王伟杰, 雍明超, 何星躲, 等. 变压器局部放电特高频传感器的研究与应用[J]. 高压电器, 2023, 59(8): 84-90.
WANG Weijie, YONG Mingchao, HE Xingduo, et al. Research and application of UHF sensor for partial discharge detection of transformer[J]. High Voltage Apparatus, 2023, 59(8): 84-90.
- [22] 吴灏, 许晓, 彭紫楠, 等. 基于变电站试验现场移动式智慧实验室系统研究[J]. 电测与仪表, 2023, 60(3): 79-85.
WU Hao, XU Xiao, PENG Zinan, et al. Research on mobile intelligent laboratory system based on substation test site[J]. Electrical Measurement & Instrumentation, 2023, 60(3): 79-85.
- [23] 谢庆. 基于空间谱估计的变压器局放超声阵列定位方法研究[D]. 北京: 华北电力大学, 2010.
XIE Qing. Research on the localization method of ultrasonic array for transformer local discharge based on spatial spectrum estimation[D]. Beijing: North China Electric Power University, 2010.
- [24] 孙曙光, 张婷婷, 王景芹, 等. 基于连续小波变换和 MTL-SEResNet 的断路器故障程度评估[J]. 仪器仪表学报, 2022, 43(6): 162-173.
SUN Shuguang, ZHANG Tingting, WANG Jingqin, et al. Fault degree evaluation of circuit breaker based on continuous wavelet transform and MTL-SEResNet[J]. Chinese Journal of Scientific Instrument, 2022, 43(6): 162-173.
- [25] 宋思蒙, 钱勇, 王辉, 等. 基于方向梯度直方图属性空间的局部放电模式识别改进算法[J]. 电工技术学报, 2021, 36(10): 2153-2160.
SONG Simeng, QIAN Yong, WANG Hui, et al. Improved algorithm for partial discharge pattern recognition based on histogram of oriented gradient attribute space[J]. Transactions of China Electrotechnical Society, 2021, 36(10): 2153-2160.
- [26] 朱永利, 张翼, 蔡炜豪, 等. 基于辅助分类-边界平衡生成式对抗网络的局部放电数据增强与多源放电识别[J]. 中国电机工程学报, 2021, 41(14): 5044-5053.
ZHU Yongli, ZHANG Yi, CAI Weihao, et al. Data augmentation and pattern recognition for multi-sources partial discharge based on boundary equilibrium generative adversarial network with auxiliary classifier[J]. Proceedings of the CSEE, 2021, 41(14): 5044-5053.
- [27] 唐贤伦, 杜一铭, 刘雨微, 等. 基于条件深度卷积生成对抗网络的图像识别方法[J]. 自动化学报, 2018, 44(5): 855-864.
TANG Xianlun, DU Yiming, LIU Yuwei, et al. Image recognition with conditional deep convolutional generative adversarial networks[J]. Acta Automatica Sinica, 2018, 44(5): 855-864.
- [28] 陈益方, 张上, 冉秀康, 等. 基于改进 YOLOv8 的 SAR 图像飞机目标检测算法[J]. 电讯技术, 2024, 64(8): 1206-1212.
CHEN Yifang, ZHANG Shang, RAN Xiukang, et al. An aircraft target detection algorithm based on improved YOLOv8 in SAR image[J]. Telecommunication Engineering, 2024, 64(8): 1206-1212.
- [29] 周颖, 颜毓泽, 陈海永, 等. 基于改进 YOLOv8 的光伏电池缺陷检测[J]. 激光与光电子学进展, 2024, 61(8): 0812008.
ZHOU Ying, YAN Yuze, CHEN Haiyong, et al. Defect detection of photovoltaic cells based on improved YOLOv8[J]. Laser & Optoelectronics Progress, 2024, 61(8): 0812008.
- [30] 王宣军, 于虹, 祁兵, 等. 基于注意力机制的混合神经网络电力设备缺陷文本挖掘方法[J]. 电力信息与通信技术, 2023, 21(9): 44-51.
WANG Xuanjun, YU Hong, QI Bing, et al. Hybrid neural network text mining method for power equipment defects based on attention mechanism[J]. Electric Power Information and Communication Technology, 2023, 21(9): 44-51.
- [31] 连子宽, 姚力, 刘晟源, 等. 基于 t-SNE 降维和 BIRCH 聚类的单相用户相位及表箱辨识[J]. 电力系统自动化, 2020, 44(8): 176-184.
LIAN Zikuan, YAO Li, LIU Shengyuan, et al. Phase and meter box identification for single-phase users based on t-SNE di-

- mension reduction and BIRCH clustering[J]. Automation of Electric Power Systems, 2020, 44(8): 176-184.
- [32] 陈鹏, 邵彬, 石英, 等. 融合 BERT、双向长短记忆网络和条件随机场的电力设备缺陷文本实体抽取[J]. 电网技术, 2023, 47(10): 4367-4376.
- CHEN Peng, TAI Bin, SHI Ying, et al. Text entity extraction of power equipment defects based on BERT-BI-LSTM-CRF algorithm[J]. Power System Technology, 2023, 47(10): 4367-4376.
- [33] 余昌佳. 变压器局部放电超声波信号分析与定位研究[D]. 南京: 东南大学, 2019.
- SHE Changjia. Research on the analysis and localization of ultrasonic signals of transformer partial discharge[D]. Nanjing: Southeast University, 2019.
- [34] 唐志国, 李阳. 基于改进无参尺度空间经验小波变换的变压器高频电流局放噪声抑制研究[J]. 高压电器, 2024, 60(1):

144-153.

TANG Zhiguo, LI Yang. Research on partial discharge noise suppression of transformer based on improved parameterless scale space empirical wavelet transform[J]. High Voltage Apparatus, 2024, 60(1): 144-153.

作者简介:



董冰冰

董冰冰(1987), 男, 博士, 副教授, 研究方向为电力设备在线监测与故障诊断、放电理论与试验(E-mail: bndong@126.com);

李秉华(2000), 男, 硕士, 研究方向为电力设备在线监测与故障诊断、放电理论与试验研究;

李建生(1987), 男, 博士, 高级工程师, 通信作者, 从事电力设备状态评估技术相关工作(E-mail: 15190495701@163.com)。

Multi-source partial discharge ultrasonic hybrid pulse identification method for oil-paper insulation defects

DONG Bingbing¹, LI Binghua¹, LI Jiansheng²

(1. School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China;

2. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, China)

Abstract: To address the issue of leakage in traditional pattern recognition classifiers when identifying transformer oil-paper insulation defects within partial discharge ultrasonic mixed pulses, a multi-source partial discharge diagnostic model based on an improved version of YOLOv8 is proposed. Firstly, three typical defective ultrasonic pulse signals from transformers are collected. Each single-source pulse undergoes transformation into a two-dimensional time-frequency spectrogram using continuous wavelet transform (CWT). The signals are converted into grayscale to enhance contrast while preserving relative intensity information for time-frequency features. Subsequently, a data augmentation method based on the Wasserstein generative adversarial network with gradient penalty (WGAN-GP) is employed to expand the sample library. This addresses the imbalance issue among classes in samples used for training ultrasound pulse defect recognition. Additionally, the *t*-distributed stochastic neighbor embedding (*t*-SNE) algorithm is utilized to perform dimensionality reduction on generated samples. This filters out low-quality samples and ensures the overall quality for the augmented dataset. Finally, the global attention mechanism (GAM) is introduced to enhance the target detection algorithm YOLOv8. The proposed multi-source localized impulse diagnostic model for transformer ultrasonic time-frequency mapping is applied to identify the multi-source localized impulse test set. The average identification accuracy of each type of localized impulse reaches 95.67%, validating the effectiveness of the proposed methodology.

Keywords: transformer; oil-paper insulation defects; ultrasonic detection method; multi-source partial discharge; pattern recognition; object detection

(编辑 方晶)