

DOI: 10.19783/j.cnki.pspc.241176

基于声光融合成像特征解析的电力设备局部放电 精细识别方法研究

马富齐^{1,2}, 穆睿昕¹, 贾嵘¹, 王波², 赵宇航¹, 马恒瑞²

(1. 西安理工大学电气工程学院, 陕西 西安 710054; 2. 武汉大学电气与自动化学院, 湖北 武汉 430072)

摘要: 局部放电是表征电力设备绝缘状态的重要指标, 研究局部放电辨识对保障电力设备及电网安全运行意义重大。然而局部放电信号微弱, 不同类型局部放电特征差异小, 现有基于单数据源的局部放电监测方法信息利用率低、辨识精度有限。为此, 提出了一种基于声光融合成像特征解析的电力设备局部放电精细识别方法。首先, 对采集到的放电音频和声像图进行滑动特征提取, 构成声光融合特征矩阵。其次, 将特征矩阵嵌入多元时间序列, 利用门控双轴编码模型并行地从时间轴方向和特征轴方向进行信息抽取、权重分配及特征重组。最后, 计算重组特征向量属于各个类别的概率, 实现局部放电高精度辨识。结果表明, 所提方法能够实现对多种放电类型的精确识别, 其准确率可达98.32%, 相较基于单数据源特征的局部放电辨识表现出更好的检测效果。

关键词: 局部放电; 声光融合成像; 多元特征解析; 时间序列; 模式识别

Refined identification method for partial discharge in power equipment based on acoustic-optical fusion imaging feature analysis

MA Fuqi^{1,2}, MU Ruixin¹, JIA Rong¹, WANG Bo², ZHAO Yuhang¹, MA Hengrui²

(1. School of Electrical Engineering, Xi'an University of Technology, Xi'an 710054, China;

2. School of Electrical and Automation, Wuhan University, Wuhan 430072, China)

Abstract: Partial discharge is an important indicator for assessing the insulation condition of power equipment, and accurate identification of partial discharge types is essential for ensuring the safe operation of both power equipment and power grid. However, due to weak partial discharge signals and the similar characteristics of difference types of partial discharges, existing partial discharge monitoring methods based on single data source suffer from low information utilization and limited identification accuracy. To address these challenges, a refined identification method for partial discharge in power equipment based on acoustic-optical fusion imaging feature analysis is proposed. First, sliding feature extraction is performed on the collected discharge audio and acoustic images to form a feature matrix of acoustic-optical fusion. The feature matrix is then embedded into a multivariate time series, and a gate controlled dual-axis encoding model is used to extract information, allocate weights, and recognize features in parallel along both the time and feature dimensions. Finally, the probability of the recognized feature vector belonging to each discharge category is calculated to achieve high-precision identification. Results show that the proposed method can achieve accurate identification of multiple types of discharge with an accuracy of up to 98.32%, outperforming identification methods based on single-source features.

This work is supported by the National Science Basic Research Program of Shaanxi Province (No. 2024JC-YBQN-0433).

Key words: partial discharge; acoustic-optical fusion imaging; multivariate feature analysis; time series; pattern recognition

0 引言

局部放电是表征电力设备绝缘状态的重要指标。

基金项目: 陕西省自然科学基金基础研究计划(2024JC-YBQN-0433); 国家科技部高端外国专家引进计划(G2023041010L)

它是导致电力设备发生绝缘击穿故障乃至爆炸燃烧事故的重要诱因, 可能会造成巨大的经济损失甚至人员伤亡^[1-2]。如2019年11月22日, 山东某变电站发生了一起因变压器高压套管局部放电引发的爆炸燃烧事故, 造成1人死亡, 2人重伤^[3]; 2021年3月14日, 内蒙古某风场发生了一起因定子接触器

弧光放电引起的内部短路着火事故,造成机舱烧损,预估损失 445 万元^[4]。因此,对电力设备进行局部放电在线监测,可以及时发现早期的安全隐患,这对于评估电力设备的绝缘状态以及保障电网的安全运行具有重要意义。

局部放电检测方法通常分为电气测量法和非电气测量法。其中电气测量法通过测量局部放电产生的脉冲电流或高频电磁波来反映其特征。但在某些场景下,如对大功率电力设备进行检测时,电气测量法容易受到电磁干扰,从而导致测量结果不准确。非电气测量法主要包括红外热像法、紫外图像法、声信号法等^[5-6]。其中声信号检测法由于其响应的敏感性、非侵入性、广泛适用性、实时性等优点,逐渐被用于局部放电检测及类型识别^[7-9]。声信号法根据采集方式可以分为接触式和非接触式^[10]。前者需要将传感器安装在设备的内部或外部,通过提取振动信号的特征进行局部放电识别,但振动传感器安装位置难以选择,影响检测精度^[11]。后者通过麦克风设备采集放电音频,如文献[12]通过提取变压器声信号在各频段的能量分布作为特征量,实现了对不同放电类型、机械故障和变压器本体噪声的识别。文献[13]基于声谱图提取放电声信号的短时频率、能量分布等特征量,构建了多特征数据集,实现了电力设备不同放电缺陷的诊断识别。文献[14]采集了电晕放电、瞬态辉光、火花放电和辉光放电 4 种放电模式下的声音信号,并提取了各模式下的短时傅里叶变换(short-time Fourier transform, STFT)特征对放电类型进行识别。但在实际电力设备运行场景中,

往往存在现场环境噪声和设备噪声等干扰因素,利用单通道麦克风采集声信号的过程中易受噪声干扰,导致故障状态识别不准确^[15-16]。为此文献[17]将 16 个麦克风按照特定拓扑结构排列,提取多通道声信号特征对 4 种局部放电类型进行了识别,取得了较好的识别效果。

由于电力设备局部放电信号微弱,且不同类型的局部放电之间特征差异小、区辨力特征难以捕捉,基于单传感来源数据的传统局部放电监测方法对于来自不同传感手段的信息利用率低,其局部放电辨识精度有待提高。为此,本文以声学相机感知的多元数据为基础,提出了一种基于声光融合成像特征解析的电力设备局部放电精细识别方法。该方法利用局部放电的时间序列特性构造了多元时间序列,且基于多头注意力机制的门控双轴编码模型并行地从时间轴方向和特征轴方向进行信息抽取及重组,最终通过计算特征向量属于各类别的概率进行局部放电类型判断,从而实现特征高度相似的不同局部放电类型的精细辨识,以提高电力设备在线监测水平。

1 基于声光融合成像特征解析的电力设备局部放电精细识别方法框架

针对传统监测方法对局部放电不同传感手段的信息利用率低、缺陷类型识别率不高的问题,本文在差异化表征高度相似的局部放电的音频特征和声像图特征基础上,构建了基于声光融合成像特征解析的局部放电精细识别方法,该方法的具体框架如图 1 所示。

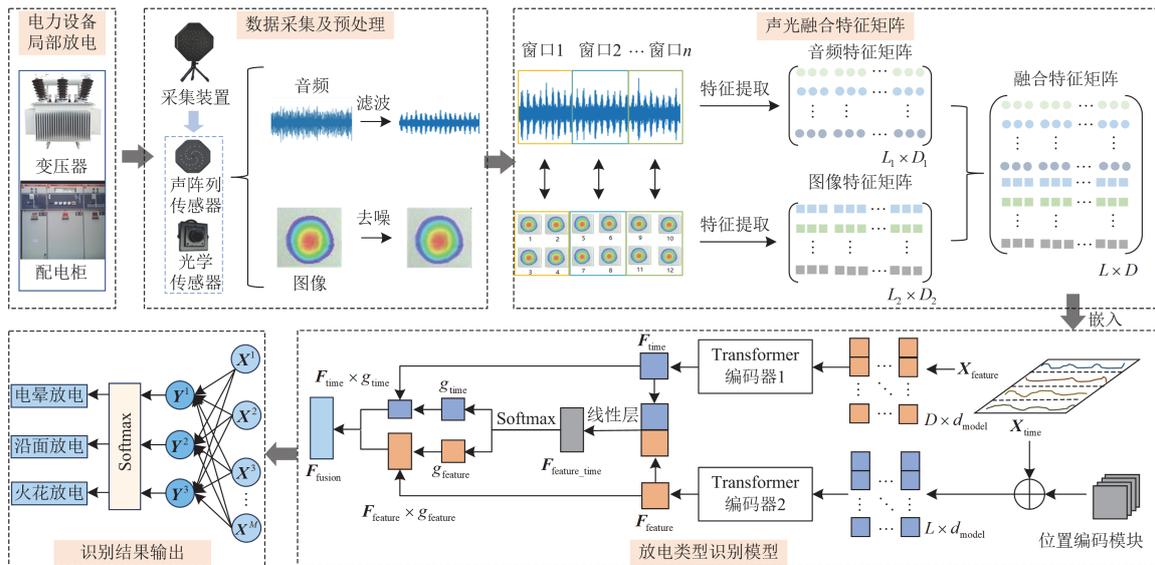


图 1 基于声光融合成像特征解析的电力设备局部放电分类方法框架图

Fig. 1 Partial discharge classification method for power equipment based on acoustic-optical fusion imaging feature analysis

图中: n 为窗口数; L_1 、 D_1 分别为音频特征矩阵的行、列; L_2 、 D_2 分别为图像特征矩阵的行、列; L 、 D 分别为融合特征矩阵的行、列; \mathbf{X}_{time} 为时间维度的嵌入向量; $\mathbf{X}_{\text{feature}}$ 为特征维度的嵌入向量; d_{model} 为嵌入维度; \mathbf{F}_{time} 为时间轴方向的多头注意力输出; $\mathbf{F}_{\text{feature}}$ 为特征轴方向的多头注意力输出; $\mathbf{F}_{\text{feature_time}}$ 为线性投影层映射后的多头注意力输出; \mathbf{g}_{time} 为时间轴方向的权重; $\mathbf{g}_{\text{feature}}$ 为特征轴方向的权重; $\mathbf{F}_{\text{fusion}}$ 为分配权重后的重组特征; \mathbf{X}^1 、 \mathbf{X}^2 、 \mathbf{X}^3 、 \mathbf{X}^M 为所有序列样本; \mathbf{Y}^1 、 \mathbf{Y}^2 、 \mathbf{Y}^3 为相应的类别。

如图 1 所示, 对于变压器、配电柜等电力设备, 本文以声学相机作为数据采集手段, 感知放电声信号及声像图数据, 然后利用小波去噪及中值滤波方法分别进行预处理, 再利用滑动窗格对音频采样点进行划分, 从音频和图像两个维度分别提取音频统计特征和图像特征构成单数据源特征矩阵, 拼接构成声光融合特征矩阵。之后将特征矩阵的行嵌入多元时间序列的时间轴方向, 特征矩阵的列嵌入多元时间序列的特征轴方向, 并行地输入到双轴编码器分别学习两个方向上的放电信息, 得到两个维度上的特征后通过门控结构分配权重, 连接得到重组特征。最后将每个重组特征映射到相应的类型, 实现了局部放电高精度辨识。

2 声光融合特征提取方法

本文首先通过声学相机对放电声信号及声像图进行采集, 型号为 DES-S64TPT, 包括光学传感器和声阵列传感器两部分。光学传感器采集光学照片, 声阵列由 64 个数字 MEMS 麦克风构成螺旋形阵列结构, 可采集 20~96 kHz 的超高带宽信号, 根据奈奎斯特定理, 采样频率设置为 192 kHz。将声阵列采集到的多通道声信号通过波束形成算法生成声压级的空间分布, 以伪彩图的方式进行表征, 并与光学照片叠加得到声像图。后续从音频和图像两个角度分别进行预处理及特征提取。

2.1 音频特征提取

2.1.1 音频预处理

由于实验室采集到的放电声信号往往掺杂着环境噪声, 因此本文采用小波分解去噪以提高信号质量, 主要分为小波分解、阈值量化以及信号重构 3 个步骤^[18]。

1) 小波分解。首先选择合适的小波基函数对原始信号进行小波分解, 常用的小波基函数有 Haar 小波、DbN 小波(Daubechies, 紧支集正交小波)、SymN 小波(Symlet, 近似对称的紧支集正交小波)等^[19]。

为了定量分析不同小波基函数的有效性, 引入均方误差(mean squared error, MSE)和信噪比(signal to noise ratio, SNR)作为评价指标。SNR 以信号功率和噪声功率的比值衡量了信号的改善程度, SNR 越大, 降噪效果越好, 但过高的 SNR 可能表示过度降噪, 导致信号失真以及细节丢失。因此, 加入 MSE 评估降噪信号和纯净信号之间的误差大小, MSE 越小, 表示降噪后的信号所含噪声越少。其计算公式为

$$E_{\text{MSE}} = \frac{1}{T} \sum_{i=1}^T [y(i) - s(i)]^2 \quad (1)$$

$$R_{\text{SNR}} = 10 \lg \frac{\sum_{i=1}^T s^2(i)}{\sum_{i=1}^T [y(i) - s(i)]^2} \quad (2)$$

式中: $s(i)$ 为纯净信号; $y(i)$ 为去噪后的信号; T 为信号长度。

对原始声信号而言, 在选定小波基后, 需对其进行五次迭代分解, 分解过程中保留每次分解后的高频系数, 仅对低频系数进行逐级迭代分解, 经五次分解后得到原始信号的高频系数 HF1—HF5 及低频系数 LF5。小波分解示意图如图 2 所示。

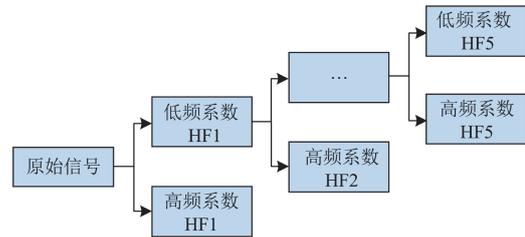


图 2 小波分解示意图

Fig. 2 Schematic diagram of wavelet decomposition

2) 阈值量化。由于信号的噪声主要集中于信号的高频分量, 且有效信号对应的系数大, 而噪声对应的系数小, 因此本文使用硬阈值处理方法, 将阈值以下的小波系数置零, 即将小于阈值部分的系数作为干扰噪声去除。考虑到放电声信号是连续一维时域信号, 本文选取全局统一阈值 ν 对高频系数 HF1—HF5 进行处理, 其计算公式为

$$\nu = \sigma \sqrt{2 \ln T} \quad (3)$$

式中: σ 是首层分解系数绝对值的中间值与高斯噪声标准方差的调节系数之比。

3) 信号重构。将经过阈值处理后的高频系数 HF1'—HF5' 与低频系数 LF5 进行小波逆变换, 重构得到去除干扰的一维时域信号, 去噪效果如图 3 所示。

2.1.2 音频特征提取及筛选

本文提取的音频特征包括 12 个时域特征和 13

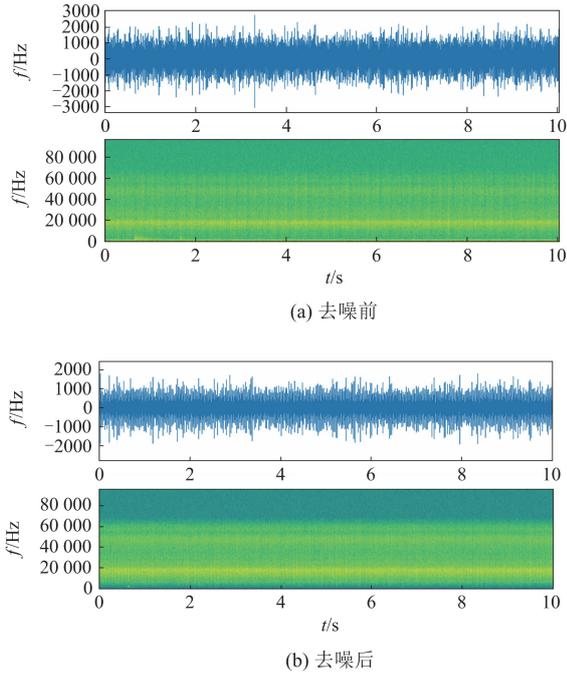


图3 小波去噪效果对比

Fig. 3 Comparison of wavelet denoising effects

个频域特征^[20-21]。在提取大量音频特征参数后，由于数据之间存在相关性且数量较多，存在过拟合的风险，可能导致识别精度降低^[22]。因此，本文通过计算音频时频域特征的最大互信息系数进行特征筛选，找到特征与目标变量之间的最大相关性，去除与目标变量关联较弱的特征，提高模型的性能和效率。其计算公式为

$$I(x; y) = \int p(x, y) \log_2 \frac{p(x, y)}{p(x)p(y)} dx dy \quad (4)$$

$$\text{mic}(x; y) = \max_{a \times b < B} \frac{I(x; y)}{\log_2 \min(a, b)} \quad (5)$$

式中： x 、 y 为两个随机变量； $I(x; y)$ 为 x 、 y 之间的互信息； $p(x)$ 、 $p(y)$ 分别为 x 、 y 的边缘分布概率； $p(x, y)$ 为 x 、 y 的联合分布概率； a 、 b 分别为 x 、 y 方向上划分的网格数； $\text{mic}(x; y)$ 为 x 、 y 间的最大信息系数； B 为划分的网格数。根据经验， B 取数据总量的0.6次方效果较好。

2.2 声像图特征提取

2.2.1 图像预处理

光线不足、强光、阴影等环境因素会影响声像图的质量。为此，本文首先对图像进行去噪以便于提取颜色特征。常用的滤波去噪方法有中值滤波和均值滤波，其基本思想是用像素点邻域灰度值的中值或均值来代替该像素点的灰度值，从而达到去除噪音的目的^[23]。为衡量两种滤波方法的性能，本文

选取均方误差 MSE、峰值信噪比(peak signal-to-noise ratio, PSNR)、结构相似性(structural similarity, SSIM)3个指标验证滤波效果。其中 MSE 与 PSNR 是通过计算滤波前后图像之间像素误差的全局大小来衡量图像质量的好坏，SSIM 是考虑人眼局部视觉因素引入的指标。设无噪声真值图和滤波后的图像分别为 I_0 和 I_p ，大小均为 $m \times n$ ，上述指标的计算公式为

$$M_{\text{MSE}} = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{m-1} [I_0(i, j) - I_p(i, j)]^2 \quad (6)$$

$$P_{\text{PSNR}} = 10 \lg \left(\frac{\text{MAX}_I^2}{M_{\text{MSE}}} \right) \quad (7)$$

$$S_{\text{SSIM}}(x, y) = \frac{(2\mu_x \mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (8)$$

式中： MAX_I 为像素最大值； μ_x 和 μ_y 分别为 x 和 y 的平均值； σ_x 和 σ_y 分别为 x 和 y 的标准差； σ_{xy} 为 x 和 y 的协方差； C_1 、 C_2 为常数。

2.2.2 图像特征提取

声像图大多呈类似圆形的不规则形状，需要将人眼观察到的形状特征提取出来。此外，对于不同放电类型的声像图，其形状特征、颜色分布、纹理规律及图像本身具有的统计特性都具有细微差别。因此本文从以上4个维度进行特征提取，指标如下。

1) 形状特征提取。由于实验室环境下拍摄到的声像图背景复杂，因此本文首先使用边缘分割算法提取声像图的基本几何特征，如图4所示。

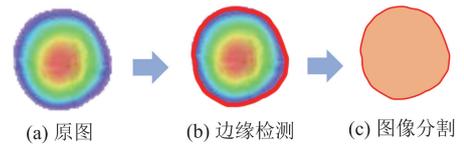


图4 基于边缘分割算法的形状特征提取

Fig. 4 Shape feature extraction based on edge segmentation algorithm

通过计算声像图圆形度对其形状特征进行描述，公式为

$$f_1 = \frac{4\pi S}{L^2} \quad (9)$$

式中： S 为提取的声像图面积； L 为周长。

2) 颜色特征提取。颜色矩是一种常用于描述图像颜色分布的特征，本文直接在红绿蓝颜色空间(red green blue color space, RGB)进行计算。由于颜色主要信息分布在低阶矩，因此选择一阶矩、二阶

矩和三阶矩作为特征描述声像图中的颜色分布。

一阶矩定义了每个颜色分量的平均值 μ_i 为

$$\mu_i = \frac{1}{N} \sum_{j=1}^N P_{ij} \quad (10)$$

二阶矩反映待测区域颜色方差, 即不均匀性 δ_i 为

$$\delta_i = \left[\frac{1}{N} \sum_{j=1}^N (P_{ij} - \mu_i)^2 \right]^{\frac{1}{2}} \quad (11)$$

三阶矩定义了颜色分量的偏斜度, 即颜色的不对称性 ζ_i 为

$$\zeta_i = \left[\frac{1}{N} \sum_{j=1}^N (P_{ij} - \mu_i)^3 \right]^{\frac{1}{3}} \quad (12)$$

式中: i 代表 R、G、B 三个颜色通道; j 表示像素值; P_{ij} 表示图像中第 i 个颜色通道在第 j 个像素上的颜色值; N 表示像素数量。

3) 纹理特征提取。图像的纹理常用灰度共生矩阵进行分析和描述。灰度共生矩阵通过计算图像空间中像素之间的灰度相关性, 来反映图像关于方向、相邻间隔和幅度的变化信息^[24]。由于灰度共生矩阵的维度较大, 一般不直接用于区分纹理的特征, 而是基于它提取一些统计量作为描述图像纹理信息变化的特征值。如图 5 所示, 本文提取了角二阶矩能量、对比度、熵、逆差矩等参数作为纹理特征指标^[25]。

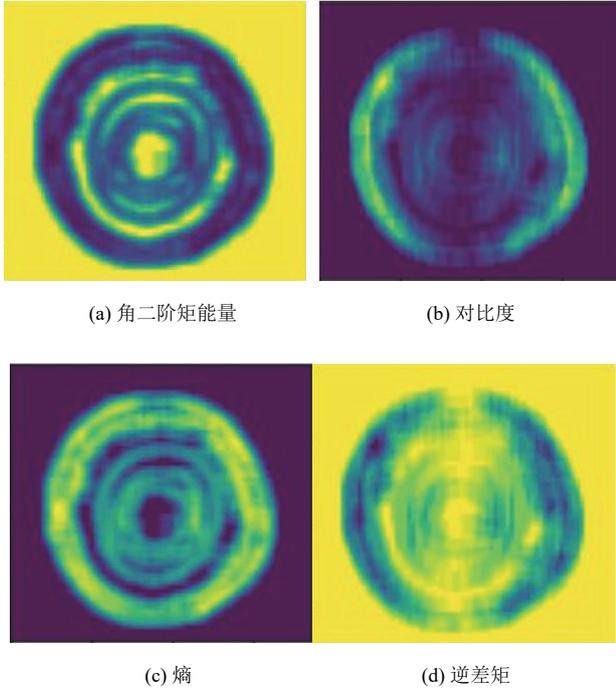


图 5 纹理特征提取效果

Fig. 5 Extraction effect of texture feature

角二阶矩能量(angular second moment, ASM)用于描述图像纹理的细致程度, 矩阵元素差别越大, 纹理越粗, 其值越大。具体的计算公式为

$$A_{ASM} = \sum_i \sum_j P(i, j)^2 \quad (13)$$

对比度(contrast, CON)表征了图像纹理深浅程度, 沟纹越深, 效果越清晰, 表示为 C_{CON} 。其计算公式为

$$C_{CON} = \sum_i \sum_j (i - j)^2 P(i, j) \quad (14)$$

熵(entropy, ENT)度量了图像灰度分布的复杂程度。其计算公式为

$$E_{ENT} = - \sum_i \sum_j P(i, j) \log(P(i, j)) \quad (15)$$

逆差矩(inverse difference moment, IDM)代表了图像纹理的局部一致性, 图像越均匀, 其值越大。其计算公式为

$$M_{IDM} = \sum_i \sum_j \frac{P(i, j)}{1 + (i - j)^2} \quad (16)$$

式中: $P(i, j)$ 表示灰度级为 i 的像素与灰度级为 j 的像素共同出现的概率。

4) 统计特征提取。统计特征基于图像自身的统计特性, 反映了图像中所含信息的丰富程度以及空间活跃程度。包括以下几个指标: 标准差(standard deviation, STD)、空间频率(spatial frequency, SF)、平均梯度(average gradient, AG)。其计算公式为

$$D_{STD} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (17)$$

$$F_{RF} = \sqrt{\frac{1}{N} \sum_{i=1}^{N-1} (F(i, j) - F(i, j+1))^2} \quad (18)$$

$$F_{CF} = \sqrt{\frac{1}{N} \sum_{i=1}^{N-1} (F(i, j) - F(i+1, j))^2} \quad (19)$$

$$F_{SF} = \sqrt{F_{RF}^2 + F_{CF}^2} \quad (20)$$

$$G_{AG} = \frac{1}{N} \sum_{i=1}^N \sqrt{\left[\left(\frac{\partial f}{\partial x} \right)^2 + \left(\frac{\partial f}{\partial y} \right)^2 \right]} \quad (21)$$

式中: x_i 为第 i 个像素的灰度值; μ 为图像的平均灰度值; F 为图像在 (i, j) 位置的像素值; F_{RF} 为横轴的信号频率; F_{CF} 为纵轴的信号频率; $\frac{\partial f}{\partial x}$ 、 $\frac{\partial f}{\partial y}$ 分别表示水平、垂直方向的梯度。

3 基于多头注意力机制的门控双轴编码模型

3.1 多元时间序列

局部放电信号是一种典型的时间序列数据^[26-27],

且每一时刻均具有多个维度的特征。本文基于局部放电的时间序列特性构建了融合特征的多元时间序列，将信息抽取分为时间轴方向和特征轴方向，深度挖掘两个维度上的特征^[28]，如图 6 所示。

多元时间序列数据集 X 可表示为

$$X = \{X^1, X^2, X^3, \dots, X^i, \dots, X^M\} \quad (22)$$

式中： M 为样本的个数。

数据集 X 中的样本 X^i 可表示为

$$X^i = (x_1^i, x_2^i, \dots, x_t^i, \dots, x_L^i) \quad (23)$$

式中： $X^i \in \mathbf{R}^{L \times D}$ ； x_t^i 表示第 i 个样本在 t 时间的状态， $x_t^i \in \mathbf{R}^D$ 。

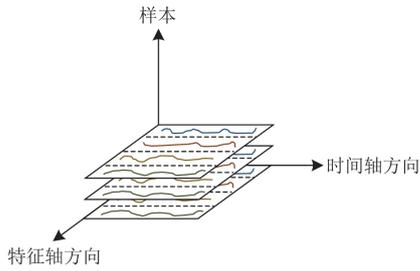


图 6 多元时间序列示意图

Fig. 6 Schematic diagram of multivariate time series

3.2 模型架构

Vaswani 等人提出的 Transformer 网络由编码器和解码器组成。其中的自注意力机制能够考虑时间序列全局信息，有效捕获时间序列中数据相互依赖的特征，在处理序列数据上具有一定的优越性^[29]。本文基于 Transformer 结构设计了一个门控双轴编码模型，该模型并行地从局部放电多元时间序列的时间轴方向和特征轴方向上分别学习放电信息，再通过门控机制按照一定的权重值进行重组，最终用于局部放电类型辨识。模型整体框架如图 7 所示，分为嵌入层、编码层和分类层 3 个部分。

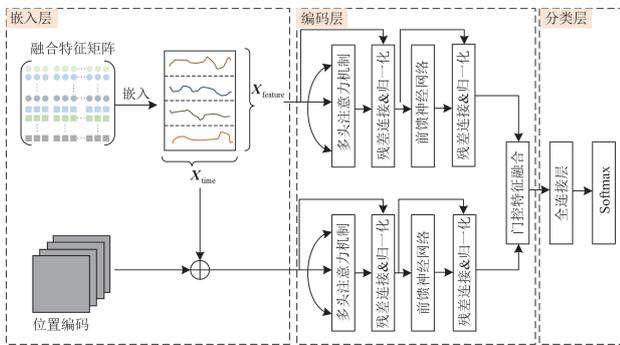


图 7 门控双轴编码模型

Fig. 7 Gated dual channel encoding model

3.2.1 嵌入层

嵌入层使用一个线性层将输入的时间序列映射为 d_{model} 维向量。对于时间维度，输入的 $X^i \in \mathbf{R}^{L \times D}$ 通过权重矩阵 $W_t \in \mathbf{R}^{d_{\text{model}} \times D}$ 变换得到 $X_{\text{time}} \in \mathbf{R}^{L \times d_{\text{model}}}$ ，其公式为

$$X_{\text{time}} = X^i W_t^T \quad (24)$$

对于特征维度，输入的 $X^i \in \mathbf{R}^{L \times D}$ 首先转置得到 $(X^i)^T \in \mathbf{R}^{D \times L}$ ，再通过权重矩阵 $W_c \in \mathbf{R}^{d_{\text{model}} \times L}$ 变换得到 $X_{\text{feature}} \in \mathbf{R}^{D \times d_{\text{model}}}$ ，其公式为

$$X_{\text{feature}} = (X^i)^T W_c^T \quad (25)$$

式中： X^i 为输入的特征矩阵， $X^i \in \mathbf{R}^{L \times D}$ ； W_c 和 W_t 是权重矩阵， $W_c \in \mathbf{R}^{d_{\text{model}} \times L}$ ， $W_t \in \mathbf{R}^{d_{\text{model}} \times D}$ 。

由于自注意力机制本身不具备学习序列位置信息的能力，因此对时间维度添加正余弦位置编码 (positional encoding, PE)，使门控双轴编码模型能够感知输入数据的位置信息^[30]，公式如下。

$$P_{\text{PE}}(k, 2i) = \sin\left(\frac{k}{10000^{\frac{2i}{d_{\text{model}}}}}\right) \quad (26)$$

$$P_{\text{PE}}(k, 2i+1) = \cos\left(\frac{k}{10000^{\frac{2i}{d_{\text{model}}}}}\right) \quad (27)$$

式中： k 为时序位置； i 为该位置下的维度值， $0 \leq i < d_{\text{model}}/2$ 。位置编码后，生成的位置编码向量 $P_{\text{PE}}(k)$ 与嵌入向量 X_{time} 相加，得到时间维度新的输入向量 X' 。

3.2.2 编码层

为充分利用特征维度与时间维度上的信息，使用两个并行的编码器子层分别抽取特征轴方向和时间轴方向上的信息。两个子层都包含多头注意力层与前馈神经网络层，分别在每个子层后接残差连接与归一化层，以降低梯度消失或者梯度爆炸的风险，加速模型收敛过程，提高训练的稳定性^[31]。

多头注意力机制利用多个自注意力机制捕捉序列数据不同层次及尺度上的信息^[32]。注意力矩阵计算方式为

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (28)$$

式中： Q 、 K 、 V 是通过输入进行不同的线性变换之后得到的； d_k 为缩放系数，防止 QK^T 点积值过大，从而缓解了梯度不稳定问题。

多头注意力的输出是由每个自注意力层的输出拼接之后再行线性变换得到的，如图 8 所示。

其计算过程为

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h)W^o \quad (29)$$

其中

$$\text{head}_i = \text{Attention}(QW_i^q, KW_i^k, VW_i^v) \quad (30)$$

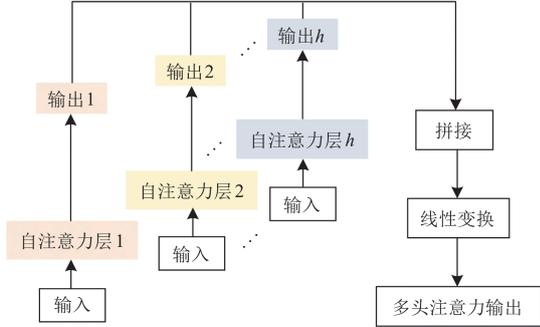


图 8 多头注意力计算过程

Fig. 8 Multi head attention calculation process

将特征轴方向和时间轴方向的多头注意力输出 F_{feature} 和 F_{time} 用门控结构进行连接, 并通过线性投影层映射得到 $F_{\text{feature_time}}$, 输入 Softmax 函数得到权重 g_{feature} 和 g_{time} , 最后将权重值分配给 F_{feature} 和 F_{time} 得到重组特征 F_{fusion} 。其中 W 是训练模型的参数; b 是偏差。计算公式为

$$F_{\text{feature_time}} = W \times \text{Concat}(F_{\text{feature}}, F_{\text{time}}) + b \quad (31)$$

$$g_{\text{feature}}, g_{\text{time}} = \text{Softmax}(F_{\text{feature_time}}) \quad (32)$$

$$F_{\text{fusion}} = \text{Concat}(F_{\text{feature}} \cdot g_{\text{feature}}, F_{\text{time}} \cdot g_{\text{time}}) \quad (33)$$

3.2.3 分类层

将编码层输出的重组特征 F_{fusion} 依次通过全连接层和 Softmax 层, 计算特征向量属于各个类别的概率, 实现将每个序列样本 X^i 映射到相应的分类 Y^i , 完成局部放电的分类。

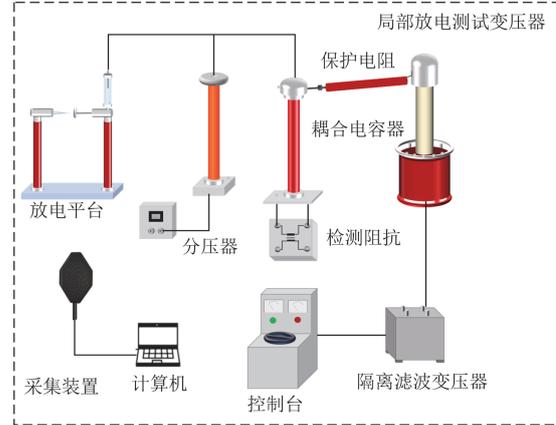
4 实验结果与分析

4.1 局部放电实验平台搭建

局部放电实验平台接线与实物分别如图 9(a)和图 9(b)所示。其中控制台型号为 TC-10 kVA, 容量为 10 kVA, 输入电压为 220 V, 输出可调电压范围为 0~250 V, 后连接额定容量为 25 kVA 的隔离滤波变压器以避免谐波对实验造成影响。局部放电测试变压器的型号为 YDQ-10/100, 容量为 10 kVA。为限制试品击穿时的短路电流, 防止对其他设备造成损坏, 串联了一个 10 kΩ 的保护电阻。分压器用于将输入放电平台的电压升高到实验所需的千伏级电压, 并通过控制台调节电压大小。采集装置与放电

平台间隔一定距离采集信号, 进行后续分析。

为模拟电力设备运行时产生的局部放电信号, 本文设计了 3 种典型局部放电缺陷模型, 分别为电晕放电、沿面放电和火花放电。不同的放电类型对电力设备绝缘性能造成的损害程度有所差异, 因此有必要对局部放电的类型进行识别。



(a) 局部放电实验平台接线示意图



(b) 局部放电实验平台接线实物图

图 9 局部放电实验平台

Fig. 9 Partial discharge experimental platform

1) 电晕放电

针板模型形成的极不均匀电场在尖端电极附近易产生高场强, 可用于模拟变压器内部的电晕放电。本文设计的电晕放电模型如图 10(a)所示, 针尖的曲率半径为 50 μm, 圆形平板电极直径为 100 mm, 针尖距平板电极的距离为 3~30 mm。

2) 沿面放电

本文设计的沿面放电模型如图 10(b)所示。高压端连接针电极, 针尖的曲率半径为 50 μm。将厚度为 1 mm 的环氧树脂片放置在板电极上, 针尖紧压在环氧树脂上。当向针电极施加高电压时, 针尖处将产生放电, 并沿着环氧树脂表面到板电极。

3) 火花放电

由于电力设备往往存在电压过高、电气绝缘破损或电弧故障等问题，因此设备内部容易发生火花放电。本文采用球隙电极模型来模拟火花放电，放电模型如图 10(c)所示，采用一对直径为 5 cm 的铜制球形电极组成，球电极间距取 3~30 mm。

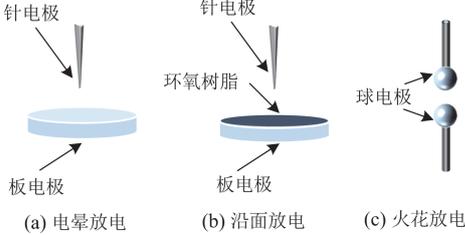


图 10 局部放电缺陷模型

Fig. 10 Partial discharge defect models

4.2 数据采集

本文通过声学相机对局部放电信号同时进行音频和声像图采集。音频采样频率为 192 000 Hz，图像帧率为 25 帧。

1) 采用声学相机对 4.1 节模拟的 3 种局部放电进行数据采集。3 种放电类型共重复 2000 次实验，控制每次实验放电时长为 2 s 对应一个样本，共得到 2000 个样本作为数据集。数据集描述如表 1 所示。为了提高模型的泛化性能，每次实验需要对施加电压、采集距离、采集角度、电极间距进行调整，此时每个样本中包含的放电脉冲形态、数量均有所差异，有效模拟了局部放电随机性和复杂性的特点，表征了不同的放电类型及放电程度。

表 1 数据集描述

Table 1 Dataset description

类别	训练集	测试集	总计
电晕放电	490	210	700
火花放电	370	155	525
沿面放电	545	230	775
总计	1405	595	2000

2) 表 2 对比了 3 种常用的小波基函数 Haar、Db2、Sym2 的去噪效果，并计算 MSE 和 SNR 作为评价指标。可以看出 Sym2 的 MSE 最小、SNR 最大，降噪效果优于 Haar 和 Db2。这是因为 Haar 小波在时域上是不连续的，所以作为基本小波性能较差。Sym 函数是对 Db 函数的一种改进，具有更好的对称性，一定程度上能够减少对信号进行分析和重构时的相位失真。因此本文选定 Sym2 小波基作为母小波。

表 2 小波基对比

Table 2 Comparison of wavelet bases

评价指标	Haar	Db2	Sym2
MSE	0.067	0.018	0.016
SNR/dB	18.70	24.37	25.48

3) 音频特征筛选结果如图 11 所示。选择互信息值为 0.4 以上的特征量，从而去除相关性较低的特征量。筛选后的时频域指标如下：最大值、最小值、平均值、中位数、峰峰值、整流平均值、方差、标准差、峭度、偏度、均方根、波形因子、方根幅值、脉冲因子、峰值因子、裕度因子、重心频率、均方根频率、均方频率、频率标准差。

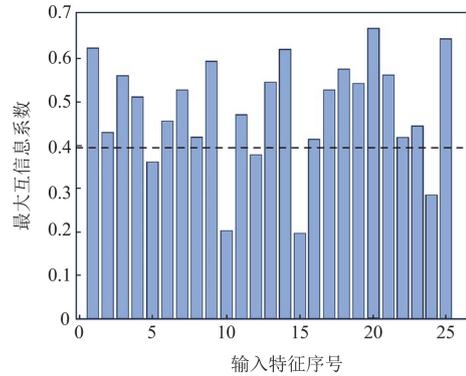


图 11 音频特征筛选结果

Fig. 11 Audio feature selection results

4) 分别使用均值滤波和中值滤波对声像图进行处理，设置滤波核大小均为 3，结果如表 3 所示。MSE 的值越小，PSNR 值越大，SSIM 值越接近 1，表明滤波后的图像质量越好。可以看出相比于均值滤波，中值滤波方法更适合处理声像图数据，能够在抑制图像噪声的同时保留原始图像的细节信息，不会造成边缘模糊。

表 3 滤波效果对比

Table 3 Comparison of filtering effects

评价指标	均值滤波	中值滤波
MSE	450.17	121.76
PSNR/dB	21.60	27.28
SSIM	0.7026	0.8906

5) 利用滑动窗格对音频采样点进行划分，窗长和步长均设置为 7680 采样点。对每个窗进行音频特征提取得到一组一维音频特征向量，同时对一帧图片进行图像特征提取得到一组一维图像特征向量，将所有特征向量进行拼接即为一组一维声光融合特征向量。按时间顺序依次对每组特征向量排列，得到声光融合特征矩阵，一个特征矩阵即为一个样本，对应一次放电时长为 2 s 的实验。特征矩阵的

行表示时间轴方向, 即对于同一个特征, 在不同时刻的取值; 特征矩阵的列表示特征轴方向, 即在同一时刻下, 不同特征量的取值。因此对于每个样本, 其维数均为 $n \times 50$, n 取决于特征量的维数。单个样本内视角如图 12 所示。

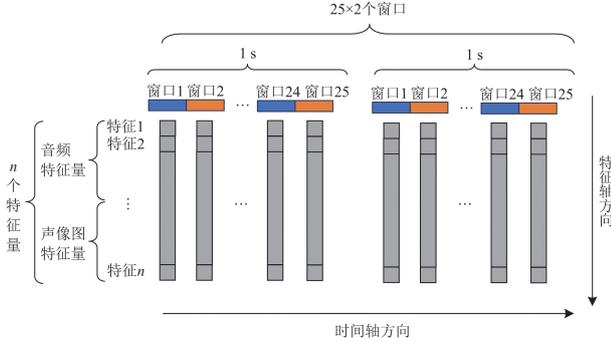


图 12 单个样本内视角

Fig. 12 Perspective within a single sample

6) 为了消除数据特征之间量纲对结果的影响, 本文对上述特征进行归一化处理得到归一化值, 使各种特征处于同一数量级^[33]。本文归一化区间为 $[0,1]$, 归一化公式为

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (34)$$

式中: X 和 X_n 分别为原始和归一化后的特征值信息量; X_{\max} 和 X_{\min} 分别为原始特征值信息量中各类信息量的最大值和最小值。

4.3 实验环境及训练参数

本文使用的服务器类型为 DELL Precision T5820 GPU 服务器, 处理器为 i9-10980XE、18 核、3.0 GHz 的 CPU, 2×RTX3090、48GB 的 GPU, 内存 128 GB, 系统为 Linux Ubuntu20.04。

本文模型训练的超参数设置如表 4 所示。

表 4 超参数描述及设置

Table 4 Description and setting of hyperparameters

超参	值	描述
d_model	512	输入维度
d_hidden	1024	隐藏层维度
d_input	50	时间序列长度
d_feature	20、14、34	时间序列维度
d_output	3	分类类别数
q,v	8	多头注意力线性层映射维度
h	8	注意力头数
N	8	编码器数量
dropout	0.2	随机失活
epoch	100	训练迭代次数
Batch_size	3	批次大小
LR	$\times 10^{-4}$	学习率
optimizer	Adam	优化器

4.4 结果分析

为验证所提方法的有效性, 本文基于第 3 节提出的门控双轴编码模型进行训练和测试, 选用单数据源特征与所提声光融合特征进行比较。为便于描述, 将上述特征量构成的数据集分别命名为 A、B、C, 随机选取 70% 作为训练集, 30% 作为测试集。其中 A 的每个样本只包含 20 维音频特征量, 构成 20×50 特征量矩阵; B 的每个样本只包含 14 维图像特征量, 构成 14×50 特征量矩阵; C 的每个样本包含 20 维音频特征量和 14 维图像特征量, 构成 34×50 特征量矩阵。

为了验证通过不同传感手段获取的信息对局部放电分类性能的影响, 分别从可视化和评价指标两个角度对结果进行分析。

4.4.1 可视化分析

图 13 给出了分别使用 A、B、C 训练模型得到的混淆矩阵和 t-SNE 聚类图。标签 0 为电晕放电, 1 为火花放电, 2 为沿面放电。从图 13(a)、13(c)、13(e) 可以看出, 混淆矩阵展示了模型对各个故障类别的诊断精确度和敏感度。与单数据源特征作为输入相比, 以声光融合特征 C 为输入的模式在测试集上的

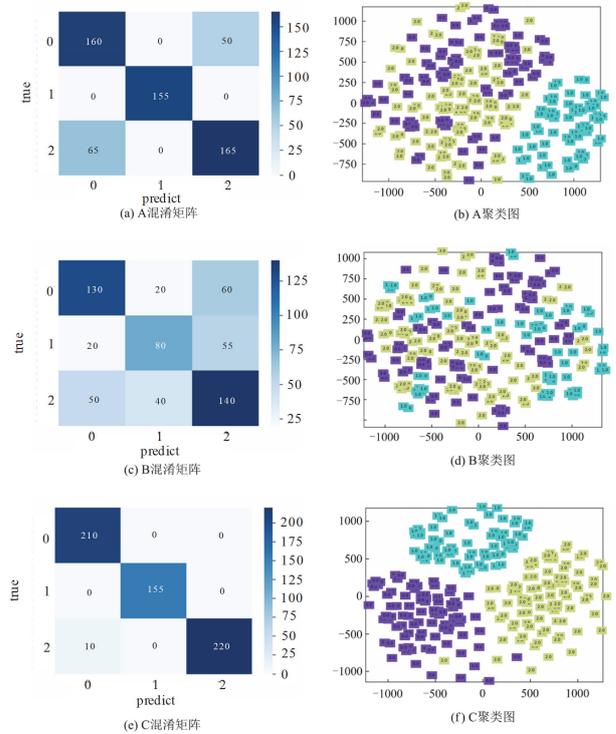


图 13 混淆矩阵和 t-SNE 聚类图对比

Fig. 13 Comparison of confusion matrix and t-SNE cluster diagram

准确率分别提升了 17.65%和 39.5%，且对电晕放电和沿面放电的识别准确率可达 100%和 95.65%。而以 A 和 B 为输入的模型电晕放电的精度仅分别为 76.19%和 61.9%，沿面放电的精度仅分别为 71.74%和 60.87%。由此可见，声光融合特征在很大程度上解决了电晕放电和沿面放电的混淆问题。

从图 13(b)、13(d)、13(f)可以看出，以声光融合特征 C 作为输入能够使不同故障类型的样本分布更为分离，同一故障类型的样本分布更为紧密，有效减少不同类别间的样本混叠现象，分类边界更清晰，验证了本文提出的基于声光融合特征能实现对不同放电模式的良好判别。

4.4.2 评价指标分析

表 5 和表 6 对分类效果进行量化描述。由表 5 可见，对于每种放电类型，声光融合特征 C 相较于 A 和 B，在精确率、召回率、F1 值几个指标上均取得更好的结果，从而具有更好的分类精度。表 6 首先基于平均精确率、平均召回率、平均 F1 值、加权 F1 值、准确率对数据集整体进行分析，可见本文提出的声光融合特征在以上指标均为 98%以上。其次计算了 t-SNE 聚类后的轮廓系数。轮廓系数是用于描述聚类有效性的指标，其值越接近 1，类间距离越大，类内距离越小，聚类效果越好。可以看出，声光融合特征的轮廓系数大于未融合特征，分离效果更好。

表 5 不同放电类型的检测结果对比

Table 5 Comparison of detection results for different discharge types

放电类别	样本数	精确率/%			召回率/%			F1 值/%		
		A	B	C	A	B	C	A	B	C
电晕放电	210	71.11	65	95.45	76.19	61.90	100	73.56	63.41	97.67
火花放电	155	100	57.14	100	100	51.61	100	100	54.23	100
沿面放电	230	76.74	54.90	100	71.74	60.87	95.65	74.16	57.73	97.78

表 6 不同输入特征的检测结果对比

Table 6 Comparison of detection results for different input features

数据集	平均精确率/%	平均召回率/%	平均 F1 值/%	加权 F1 值/%	准确率/%	轮廓系数
A	82.62	82.64	82.57	80.68	80.67	0.11
B	59.01	58.13	58.46	58.82	58.82	0.03
C	98.48	98.55	98.48	98.32	98.32	0.61

5 结论

本文聚焦于传统单传感的局部放电监测方法来自不同传感手段的信息利用率低、对缺陷类型识别率不高的问题，提出了一种基于声光融合成像特征解析的电力设备局部放电精细识别方法。实验结果表明，通过引入局部放电的声像图特征，不仅提高了特征聚类的轮廓系数，使得不同放电类型的样本分布边界更加清晰，而且实现了声场与可见光场下不同特征之间的互补，提高了放电类型的识别精度。

参考文献

[1] 桂媛, 及洪泉, 辛锋, 等. 考虑温湿度影响的空气绝缘开关柜局部放电分解组分仿真与实验研究[J]. 高压电器, 2025, 61(1): 30-40.
 GUI Yuan, JI Hongquan, XIN Feng, et al. Simulation and experimental study on partial discharge decomposition components of air-insulated switchgear cabinet considering the influence of temperature and humidity[J]. High Voltage Apparatus, 2025, 61(1): 30-40.

[2] 张伟, 方舟, 黄钟, 等. 基于等效距离的 GIS 局部放电特高频定位方法[J]. 高压电器, 2024, 60(8): 92-98.
 ZHANG Wei, FANG Zhou, HUANG Zhong, et al. UHF location method of GIS partial discharge based on equivalent distance[J]. High Voltage Apparatus, 2024, 60(8): 92-98.

[3] 国家能源局. 2020 年三季度事故分析报告[EB/OL] (2020-12-30). https://www.nea.gov.cn/2020-12/30/c_139629076.htm.

[4] 国家能源局. 2021 年一季度事故分析报告[EB/OL] (2021-8-10). https://www.nea.gov.cn/2021-08/10/c_1310119210.htm.

[5] CHELMIAH E T, MADIGAN C D, KAVANAGH D F. An acoustic sensor array approach for localizing partial discharges in electric machines[J]. Mechanical Systems and Signal Processing, 2024, 214.

[6] FAIZOL Z, ZUBIR F, SAMAN N M, et al. Detection method of partial discharge on transformer and gas-insulated switchgear: a review[J]. Applied Sciences, 2023, 13(17).

- [7] ZHOU Lijun, CAI Junyi, HU Junjie, et al. A correction-iteration method for partial discharge localization in transformer based on acoustic measurement[J]. IEEE Transactions on Power Delivery, 2020, 36(3): 1571-1581.
- [8] RAMY H, KHALED B S, AYMAN H E. 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] 曾潮旭, 徐会凯, 杨淳岚, 等. 开关柜典型局部放电类型超声波信号特征量研究[J]. 高压电器, 2025, 61(2): 1-9, 16.
ZENG Chaoxu, XU Huikai, YANG Chunlan, et al. Study on characteristic quantities of ultrasonic signals of typical partial discharge types in switchgear cabinet[J]. High Voltage Apparatus, 2025, 61(2): 1-9, 16.
- [10] 王鹏, 刘玉婷, 邹阳, 等. TEV 和超声波检测法在开关柜局部放电检测中的应用评述[J]. 高压电器, 2020, 56(10): 75-83.
WANG Peng, LIU Yuting, ZOU Yang, et al. Application of TEV and ultrasonic detection methods in partial discharge detection of switchgear[J]. High Voltage Apparatus, 2020, 56(10): 75-83.
- [11] 李晨, 于强, 王林峰, 等. 基于振动声学的电力变压器绕组在线监测及特征参量提取[J]. 电工技术, 2021(6): 76-77, 80.
LI Chen, YU Qiang, WANG Linfeng, et al. On-line monitoring and features extraction of power transformer windings based on vibrational acoustics[J]. Electrical Technology, 2021(6): 76-77, 80.
- [12] 吴国鑫, 詹花茂, 李敏. 声纹的变压器放电与机械故障诊断研究[J]. 应用声学, 2021, 40(4): 602-610.
WU Guoxin, ZHAN Huamao, LI Min. Research on transformer discharge and mechanical fault diagnosis based on voiceprint[J]. Applied Acoustics, 2021, 40(4): 602-610.
- [13] 汪志成, 王泽旺, 朱梦帆, 等. 基于卷积神经网络的局部放电声音识别研究[J]. 电子测量技术, 2023, 46(20): 148-155.
WANG Zhicheng, WANG Zewang, ZHU Mengfan, et al. Study on sound recognition of partial discharge based on convolutional neural network[J]. Electronic Measurement Technology, 2023, 46(20): 148-155.
- [14] XIONG Zilan, WANG Yuqi, LI Mengqi. Classification of DC discharge modes based on acoustic signal[J]. Physica Scripta, 2022, 98(1).
- [15] HADRIEN P, ÉRIC B, ALEXANDRE G. Beam learning: an end-to-end deep learning approach for the angular localization of sound sources using raw multichannel acoustic pressure data[J]. The Journal of the Acoustical Society of America, 2021, 149(6): 4248-4263.
- [16] YAN Jiaming, CHEN Caihui, WU Zhipeng. An acoustic localization sensor based on MEMS microphone array for partial discharge[J]. Sensors, 2023, 23(3).
- [17] 王红霞, 王波, 张嘉鑫, 等. 基于声阵列时空关联特征融合的不平衡局部放电类型识别方法[J]. 高电压技术, 2024, 50(5): 1913-1922.
WANG Hongxia, WANG Bo, ZHANG Jiabin, et al. Pattern recognition of partial discharge using imbalanced acoustic array data based on spatial correlation and temporal correlation feature fusion method[J]. High Voltage Engineering, 2024, 50(5): 1913-1922.
- [18] 高淑萍, 姜元月, 宋国兵, 等. 混合三端直流输电线路故障测距方法研究[J]. 电力系统保护与控制, 2021, 49(15): 76-83.
GAO Shuping, JIANG Yuanyue, SONG Guobing, et al. Research on a fault location method for a hybrid three-terminal DC transmission line[J]. Power System Protection and Control, 2021, 49(15): 76-83.
- [19] 王桐, 史雯, 石浩瀚, 等. 基于平稳小波变换的光伏直流串联电弧故障检测[J]. 电力系统保护与控制, 2024, 52(12): 82-93.
WANG Tong, SHI Wen, SHI Haoyuan, et al. Photovoltaic DC series arc fault detection based on stationary wavelet transform[J]. Power System Protection and Control, 2024, 52(12): 82-93.
- [20] 刘素贞, 陈云龙, 张闯, 等. 融合多维超声时频域特征的锂离子电池荷电状态估计[J]. 电工技术学报, 2023, 38(17): 4539-4550, 4563.
LIU Suzhen, CHEN Yunlong, ZHANG Chuang, et al. State of charge estimation of lithium-ion batteries fused with multidimensional ultrasonic time-frequency domain features[J]. Transactions of China Electrotechnical Society, 2023, 38(17): 4539-4550, 4563.
- [21] 秦心筱, 张昌华, 徐子豪, 等. 基于卷积神经网络的电力系统低频振荡主导模态特征定性辨识[J]. 电力系统保护与控制, 2021, 49(10): 51-58.
QIN Xinxiao, ZHANG Changhua, XU Zihao, et al. Research on qualitative identification of a low frequency oscillations dominant mode in power system based on a convolutional neural network[J]. Power System Protection and Control, 2021, 49(10): 51-58.
- [22] 廖才波, 杨金鑫, 胡雄, 等. 基于油中溶解气体特征量筛选的变压器故障诊断方法[J]. 电力工程技术, 2024, 43(1): 192-200.
LIAO Caibo, YANG Jinxin, HU Xiong, et al. Fault diagnosis method for transformers based on feature

- selection of dissolved gas in oil[J]. Electric Power Engineering Technology, 2024, 43(1): 192-200.
- [23] 周封, 任贵新. 基于颜色空间变量的输电线图像分类及特征提取[J]. 电力系统保护与控制, 2018, 46(5): 89-98.
ZHOU Feng, REN Guixin. Image classification and feature extraction of transmission line based on color space variable[J]. Power System Protection and Control, 2018, 46(5): 89-98.
- [24] 司文荣, 傅晨钊, 徐鹏, 等. 基于声学成像及图像处理的变压器铁心松动检测研究[J]. 高压电器, 2021, 57(11): 180-186.
SI Wenrong, FU Chenzhao, XU Peng, et al. Research on loose detection of transformer core based on acoustic imaging and image processing[J]. High Voltage Apparatus, 2021, 57(11): 180-186.
- [25] 郭凤仪, 邓勇, 王智勇, 等. 基于灰度-梯度共生矩阵的串联故障电弧特征[J]. 电工技术学报, 2018, 33(1): 71-81.
GUO Fengyi, DENG Yong, WANG Zhiyong, et al. Series arc fault characteristics based on gray level-gradient co-occurrence matrix[J]. Transactions of China Electrotechnical Society, 2018, 33(1): 71-81.
- [26] SUN Kang, LI Rui, ZHAO Lijun, et al. Feature extraction based on time-series topological analysis for the partial discharge pattern recognition of high-voltage power cables[J]. Measurement, 2023, 217.
- [27] PABLO D, ROGER S, JORGE A, et al. Analysis of partial discharges in electrical tree growth under very low frequency (VLF) excitation through pulse sequence and nonlinear time series analysis[J]. IEEE Access, 2020, 8: 163673-163684.
- [28] LIU Minghao, REN Shengqi, MA Siyuan, et al. Gated transformer networks for multivariate time series classification[J]. arxiv Preprint arxiv: 2103. 14438, 2021.
- [29] ASHISH V, NOAM S, NIKI P, et al. Attention is all your need[C]// Proceedings of the 31st International Conference on Neural Information Processing System, 2017: 1-21.
- [30] 刘斌, 吉春霖, 曹丽君, 等. 基于自适应噪声完全集合经验模态分解与 Bi LSTM-Transformer 的锂离子电池剩余使用寿命预测[J]. 电力系统保护与控制, 2024, 52(15): 167-177.
LIU Bin, JI Chunlin, CAO Lijun, et al. Prediction of remaining service life of lithium-ion batteries based on complete ensemble empirical mode decomposition with adaptive noise and BiLSTM-Transformer[J]. Power System Protection and Control, 2024, 52(15): 167-177.
- [31] 金亮, 尹振豪, 刘璐, 等. 基于残差 U-Net 和自注意力 Transformer 编码器的磁场预测方法[J]. 电工技术学报, 2024, 39(10): 2937-2952.
JIN Liang, YIN Zhenhao, LIU Lu, et al. Magnetic field prediction method based on residual U-Net and self-attention Transformer encoder[J]. Transactions of China Electrotechnical Society, 2024, 39(10): 2937-2952.
- [32] 陈豪钰, 李振华, 张绍哲, 等. 基于 MHA-CNN-SLSTM 和误差补偿的短期互感器误差预测[J]. 电力系统保护与控制, 2024, 52(24): 74-84.
CHEN Haoyu, LI Zhenhua, ZHANG Shaozhe, et al. Short-term transformer error prediction based on MHA-CNN-SLSTM and error compensation[J]. Power System Protection and Control, 2024, 52(24): 74-84.
- [33] 周海成, 石恒初, 曾令森, 等. 基于关系超图增强 Transformer 的智能站二次设备故障诊断研究[J]. 电力系统保护与控制, 2024, 52(12): 123-132.
ZHOU Haicheng, SHI Hengchu, ZENG Lingsen, et al. Fault diagnosis of an intelligent substation secondary device based on a relational hypergraph-enhanced Transformer[J]. Power System Protection and Control, 2024, 52(12): 123-132.

收稿日期: 2024-09-02; 修回日期: 2025-02-08

作者简介:

马富齐(1994—), 男, 博士研究生, 研究方向为防灾减灾与安全、电力安全影像解译和边缘智能; E-mail: xautmfq@xaut.edu.cn

穆睿昕(2000—), 女, 通信作者, 硕士研究生, 研究方向为电力设备多模态融合及故障诊断。E-mail: 2221921147@stu.xaut.edu.cn

(编辑 石晋美)