

DOI:10.19651/j.cnki.emt.2209404

# 基于 Iradon-CNN 的变压器局部放电状态识别方法<sup>\*</sup>

朱霄珣 林佳伟 刘宝平 李震涛 高晓霞  
(华北电力大学动力工程系 保定 071003)

**摘要:**为解决变压器局部放电故障所带来的安全隐患,提出了一种基于 Iradon CNN 的变压器局部放电信号图像识别方法。针对三种故障进行了局部放电实验,首先通过共振稀疏分解对局部放电信号进行分解,获取低共振分量,然后将其转换成 Iradon 图像,最后利用 CNN 自适应地提取 Iradon 图像的特征信息。结果表明,该方法能够准确提取信号特征,具有强大的数据处理和识别功能,并为变压器局部放电状态的识别提供了丰富的信息,提高了学习效果和识别精度。

**关键词:**局部放电;状态识别;深度学习;卷积神经网络;Iradon 变换

中图分类号: TP183; TM835; TM41 文献标识码: A 国家标准学科分类代码: 510.4030

## Transformer partial discharge state identification method based on Iradon-CNN

Zhu Xiaoxun Lin Jiawei Liu Baoping Li Zhentao Gao Xiaoxia  
(Department of Power Engineering, North China Electric Power University, Baoding 071003, China)

**Abstract:** In order to solve the potential safety hazards caused by transformer partial discharge fault, an image recognition method of transformer partial discharge signal based on Iradon CNN was proposed. Partial discharge experiments were carried out for three kinds of faults. First, the partial discharge signal was decomposed by resonance sparse decomposition to obtain low resonance components, which were then converted into Iradon images. Finally, CNN was used to adaptively extract the feature information of Iradon images. The results show that, this method can accurately extract signal features, has powerful data processing and identification functions, and provides rich information for the identification of partial discharge states of transformers, and improves the learning effect and identification accuracy.

**Keywords:** partial discharge; state recognition; deep learning; convolutional neural networks; Iradon transform

## 0 引言

电网正常运行期间,确保变压器安全平稳运行是电网正常运行的关键<sup>[1]</sup>。长时间处于高压环境下,变压器内部元件将发生老化和损坏,从而影响其功能。变压器的局部放电行为是其绝缘劣化的具体特征之一。如果能准确识别局部放电故障的类型和程度,就能及时掌握变压器的运行状况。

故障信号的有效特征提取是准确识别的前提。肖酒等<sup>[2]</sup>对 GIS 设备局部放电展开研究,发现改进变分模态分解与阈值算法相结合的方法对局部放电信号具有的较好的去噪效果。Ghorat 等<sup>[3]</sup>基于双树复小波变换(DTCWT)对局部放电信号进行去噪处理,大大降低了小波变换中的平

移灵敏度,提高了方向选择性。然而,这种方法不能实现图像的智能融合和自动融合,不能满足在线故障诊断的需要。刘鑫等<sup>[4]</sup>提出一种基于联合近似对角化的分离算法,实现了对多个局部放电信号的有效分离。Mor 等<sup>[5]</sup>使用小波分析对噪声环境中的局部放电状态进行分析,将噪声和外部干扰从放电信号中分离出来。但由于放电信号中包含的模态分量非常复杂<sup>[6]</sup>,信息维数较高,很难人工提取和定位信号的状态特征,存在一定的主观性。此外,信号处理方式的局限性使得难以适应不同类型信号的特征提取。

同时,为了实现智能故障诊断,机器学习的方法被越来越多地应用于状态识别。这种方法通常首先通过信号处理手段提取故障特征信息,然后基于机器学习模型进行识别,即“特征提取+模型识别”模式。针对变压器状态识别准确

收稿日期:2022-03-25

\*基金项目:中央高校基本科研业务费(2020MS145)项目资助

率低的问题,王雨虹等<sup>[7]</sup>提出了多策略改进麻雀算法及BILSTM,在保证识别精度的前提下提高了模型的收敛速度。程江洲等<sup>[8]</sup>利用 T-MobileNet-L 模型,在保证精确度的前提下,利用少量数据输入量训练实现对图像特征的大量提取。然而,机器学习的方法依然面临两个严重的问题。首先,由于机器学习模型的学习深度不足,难以实现复杂的映射关系,即无法建立从状态特征到状态类别的精确映射关系。其次,特征提取的质量决定了机器学习模型的识别精度,无法实现高质量的特征提取制约了模型识别精度的提高。

深度学习方法的出现很好地解决了传统机器学习的问题。一方面,学习深度的增加可以实现更复杂的映射关系。另一方面,自适应特征提取过程在特征提取和构造的灵敏度和鲁棒性中占有重要地位。它可以从海量数据中自动学习特征信息,极大地弥补了基于信号处理的特征提取方法的不足,为局部放电状态识别带来了新的机遇。CNN 的本质是通过多个特征过滤器逐层进行卷积和池化运算,可以提取输入数据的特征<sup>[9-10]</sup>,进而逐步提取隐藏在数据中的特征。综上所述,CNN 通过卷积模拟特征差异,通过权重共享和池化来减少网络参数的数量,最终通过神经网络完成分类任务<sup>[11]</sup>。

Ganguly 等<sup>[12]</sup>提出了一种新的卷积神经网络(CNN)拓扑结构,该拓扑结构利用小波核提取放电信号的特征,以提高高压电力设备中单个或多个放电状态的检测和识别精度,同时,无需使用单独的算法对采集的局部放电信号进行特征提取和分类。Peng 等<sup>[13]</sup>提出了一种基于 CNN 局部放电学习模型的深度学习方法,在高压实验室对 5 个人工缺陷进行局部放电测试,并通过调整自适应卷积核的大小和网络层数来提高识别精度。Zhang 等<sup>[14]</sup>提出了一种基于小数据集 CNN 的绝缘故障识别方法,通过相空间重构对单位工频周期的局部放电信号进行等效变换,并提取几何、分形、熵和时域特征,增加特征数据量,最后构造组合特征导入 CNN 完成放电识别。陈雨馨等<sup>[15]</sup>提出了一种基于特征融合与几何短语池化的图像分类方法,此方法对低层特征图像具有较高的识别精度。

在研究中发现,学习对象所携带的状态差异信息的完整性和冗余性不同于其他类型的信息,这极大地影响了模型的准确性和网络的复杂性。将图像识别和准确的特征提取相结合,可以提高故障诊断的准确性。

针对以上问题,本文提出了基于 Iradon-CNN 的局部放电故障图像诊断方法。该方法通过图像特征优化学习对象的特征信息,建立 CNN 模型对其特征信息进行深度学习和识别。首先,对于复杂的局部放电信号,采用共振稀疏分解方法提取信号的低共振分量,增强其细节特征。然后提出了一种基于 Iradon 变换的特征图像诊断方法,以提高识别对象的特征表达能力,并将一维信号的特征转化为图像形式;在此基础上,研究了 CNN 模型结构,最终建立了

基于 CNN 的变压器局部放电特征学习和状态识别模型。研究结果证明,本文提出的方法将有助于提升状态特性的可识别性及设备故障的精确诊断,对于局部放电状态识别准确率达到 96.34%。

## 1 基于 Iradon 变换的冲击特征

局部放电信号包含复杂的冲击信号和噪声,如果直接利用 CNN 进行识别则其准确性无法得到保障。因此,能否准确提取复杂信号的差异化特征是识别的关键。本节提出了一种基于 Iradon 变换的特征提取方法,可以将一维数据信号转化为图像特征,改善不同状态下信号之间的特征差异。同时,为了提高特征提取的精度,本部分提出了基于 Iradon 变换的冲击特征提取方法,并对原始信号和处理后的信号特征图像进行了比较。

### 1.1 概述 Radon 和 Iradon

Radon 变换如图 1 所示。函数  $f$  定义在  $xOy$  平面上的区域  $D$  中。对于  $xOy$  平面上的任意直线  $L$ ,都可以由一对参数  $(\alpha, s)$  唯一确定。其中,  $\alpha$  是  $x$  轴的正方向到直线  $L$  的法向量的夹角,  $\alpha \in (0, \pi)$ ,  $s$  是坐标轴原点到直线  $L$  的距离<sup>[16-17]</sup>。如果直线  $L$  与函数  $f$  的域  $D$  相交,则函数  $f$  在直线  $L$  上的值被积分为 Radon 变换的值,直线  $L$  为:

$$Rf(L) = \int_L f(s) |ds| \quad (1)$$

直线  $L$  的参数方程可以表示为:

$$Rf(\alpha, s) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \delta(s - x \cos \alpha - y \sin \alpha) dx dy \quad (2)$$

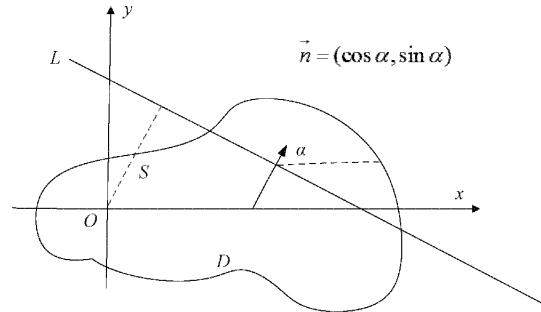


图 1 Radon 变换原理

投影函数  $g(\alpha, s)$  的一维傅里叶变换等于投影线上计算的图像的二维傅里叶变换。因此,  $g$  的一维傅里叶变换由下式给出<sup>[18]</sup>:

$$p(\alpha, w) = \int e^{-j\omega t} g(\alpha, s) ds \quad (3)$$

将  $g(\alpha, s)$  代入上式,得到:

$$p(\alpha, w) = \iint f(x, y) e^{-j\omega t} \delta(x \cos \alpha + y \sin \alpha - s) dx dy \quad (4)$$

$$f(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(k_x, k_y) e^{j2\pi(k_x x + k_y y)} dk_x dk_y \quad (5)$$

$$\begin{cases} k_x = v \cos \alpha \\ k_y = v \sin \alpha \end{cases}$$

由二维傅里叶逆变换得：

$$f(x, y) = \frac{1}{4\pi^2} \iint p(\alpha, \omega) e^{j\omega(x \cos \alpha + y \sin \alpha)} |w| dw d\alpha \quad (6)$$

其中， $|w|$  是变量变为极坐标的雅可比矩阵的行列式。 $q(\alpha, \omega) = p(\alpha, \omega) |w|$  是角度为  $\alpha$  的滤波反投影。理论上，Iradon 变换将产生原始图像<sup>[18]</sup>。

因此，Iradon 变换就是平面上的任何余弦形式都可以通过该变换聚集到  $xOy$  平面上的一个点。局部正弦基在时频两域都保持较好的局部化特性，所以它可以基于不同频率的数据，在时域中调整采样步长，以便可以使用各种数据来重建图像。

利用滤波函数重建反投影图像。使用 Ram-lak 滤波函数，其离散形式  $h_{R-L}(nd)$  为：

$$h_{R-L}(nd) = \begin{cases} \frac{1}{4d^2}, & n = 0 \\ 0, & n = \text{偶数} \\ -\frac{1}{n^2 \pi^2 d^2}, & n = \text{奇数} \end{cases} \quad (7)$$

为了验证变压器局部放电状态识别是否有效，本文构造了 4 个添加了信噪比为 30 dB 的噪声信号的仿真信号用于模拟不同的放电状态。变压器局部放电信号的频率一般保持在一个较高的范围内，为使模拟信号尽可能接近放电信号，设置  $f$  为 10 kHz，采样频率为 30 kHz。模拟信号如下所示，模拟信号的 Iradon 图如图 2 所示。

$$x_A = \sin(2\pi \times 50t) \quad (8)$$

$$x_B = 2\sin(2\pi \times 50t) + \sin(2\pi \times 100t) \quad (9)$$

$$x_C = 3\sin(2\pi \times 50t) + 2\sin(2\pi \times 100t) + \sin(2\pi \times 150t) + s(t) \quad (10)$$

$$x_D = 3\sin(2\pi \times 50t) + 2\sin(2\pi \times 100t) + 3\sin(2\pi \times 150t) + 20e^{-50t} \times \cos(100\pi t) \quad (11)$$

$$s(t) = \sum_{m=1}^M B_m \exp[-\beta(t - mT_p)] \times \cos[2\pi f_r \times (t - mT_p)] u(t - mT_p) \quad (12)$$

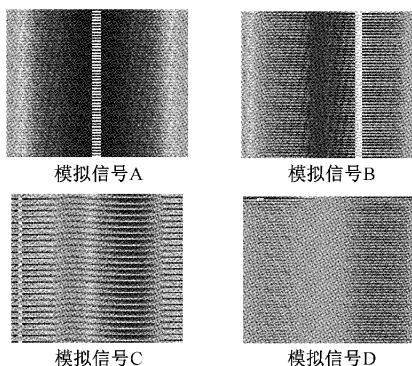


图 2 模拟信号 Iradon 图

从模拟信号 Iradon 图可以看出，不同输入信号的 Iradon 图之间差异很大。模拟信号 A 是完全对称的图。模拟信号 B 完全不对称，特征色彩丰富；模拟信号 C 看起来对称，左右颜色不同；在模拟信号 D 中，整个特征图显示为蓝色。因此，Iradon 变换可以对信号中的特征实现更准确地提取。

### 1.2 冲击特征的 Iradon 变换提取

从以上研究可以看出，变压器局部放电信号十分复杂，其包含冲击分量、噪声和非周期成分等。为此，通过共振稀疏分解的方式分解原始信号，提取所需特征成分。

共振稀疏分解最早由 Selesnick 提出，它是将采集到的原始信号分解为两部分，当  $Q=3$  时获得连续振荡信号，这部分信号含有较多的噪声和较大的干扰；当  $Q=1$  时获得瞬态冲击信号，其范围更广、特征更加明显<sup>[19]</sup>。分解过程如图 3 所示。

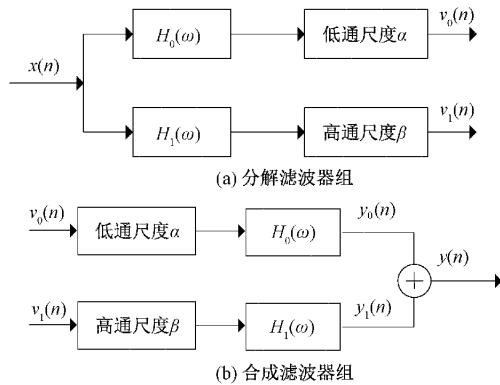


图 3 双通道滤波器组

在图 3 中， $H_0(\omega)$  和  $H_1(\omega)$  分别代表低、高通滤波器。 $\alpha$  和  $\beta$  为低、高通比例因子， $r$  为冗余度； $v_0(n), v_1(n)$  是子带信号。

$$\alpha = 1 - \beta/r \quad (13)$$

$$Q = \frac{2 - \beta}{\beta} \quad (14)$$

$$L_{\max} \leqslant \frac{\log(\beta N / 8)}{\log(1/\alpha)} \quad (15)$$

### 2 基于神经网络的局部放电信号图像识别

通过 Iradon 变换，可以对不同放电状态进行区分和识别，进而实现故障诊断。然而，人工识别图像特征基于大量的专业经验，而且对于图像中的微小差异难以做到精准的把握。因此，本文将深度学习应用于图像识别，提出了一种基于 Iradon-CNN 的局部放电信号识别方法，建立了智能局部放电故障诊断模型，如图 4 所示。

该模型主要包括以下几个部分：

- 1) 局部放电特征提取：对原始信号进行共振稀疏分解，提取相关的低共振分量状态特征。
- 2) 图像特征提取：使用 Iradon 分析方法计算每个状态

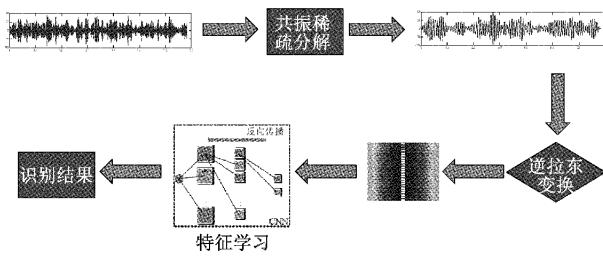


图 4 故障诊断模型结构

信号的信息,获得 Iradon 图像,使得信号之间的差异更加突出。

3) 深度特征学习和识别: 构建基于 Iradon-CNN 模型, 对网络各层参数进行优化。并以 Iradon 图像作为 CNN 模型的输入, 识别局部放电信号的状态, 实现深度特征学习。

在上述过程中,CNN 的结构将影响局部放电信号的特征学习效果, 进而影响识别精度。本文在 CNN 的基础上进行了优化和改进, 最终确定了本文 CNN 的最优结构和参数。详情如表 1 所示。

表 1 CNN 模型参数设置

层	卷积核/滤波器(高×宽/步)	特征图
输入层		128×128
卷积层 1	5×5/1	124×124×6
池化层 2	2×2/2	62×62×6
卷积层 3	5×5/1	58×58×16
池化层 4	2×2/2	29×29×16
全连接层		16
输出层		3

### 3 实验研究

根据变压器工作环境建立如图 5 所示的局部放电实验系统, 其由模拟系统、检测系统及数据采集系统 3 部分组成。当实验开始时, 接地线上会产生脉冲电流, 使用电流传感器和 UHF 传感器对其进行测量, 使用局部放电分析仪(TWPD-2E)对实验数据进行采样并分类存储。

共设置 3 个局部放电模型, 包括图 6(a) 电晕放电、图 6(b) 气隙放电、图 6(c) 悬浮微粒放电, 如图 6 所示。

对 3 个局部放电模型各进行 200 次测试, 共采集脉冲电流和原始放电数据共 600 组, 样本长度 2 048。数据集如表二所示, 3 种放电类型依次编码为 0、1、2。

#### 3.1 实际信号的干扰

信号的特征图可以反映不同的故障状态。同时, 从上面可以看出, Iradon 变换可以将不同信号的特征以图像的形式进行区分, 从而反映变压器不同放电故障之间的差异。因此, 本文研究了基于 Iradon 变换的故障特征提取方法。

首先, 将未经任何处理的原始信号进行 Iradon 变换。如图 7 所示。

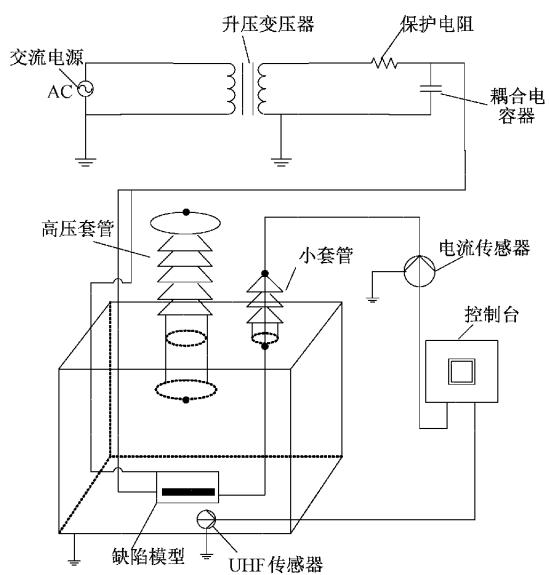


图 5 局部放电实验系统

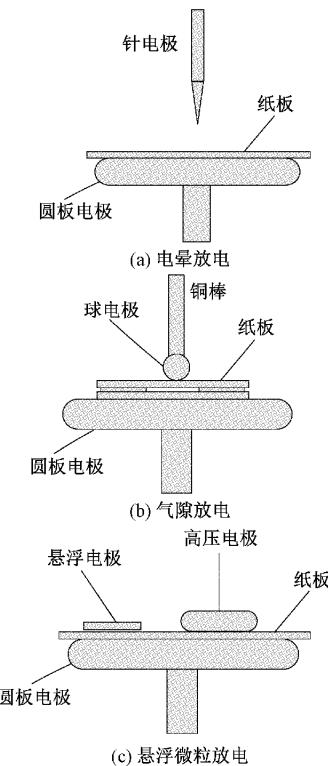


图 6 局部放电模型

表 2 局部放电信号的实验样本

编码	样本类型	实验电压/ kV	样本个数 (train/test)
0	电晕放电	10	100/100
1	气隙放电	10	100/100
2	悬浮微粒放电	10	100/100

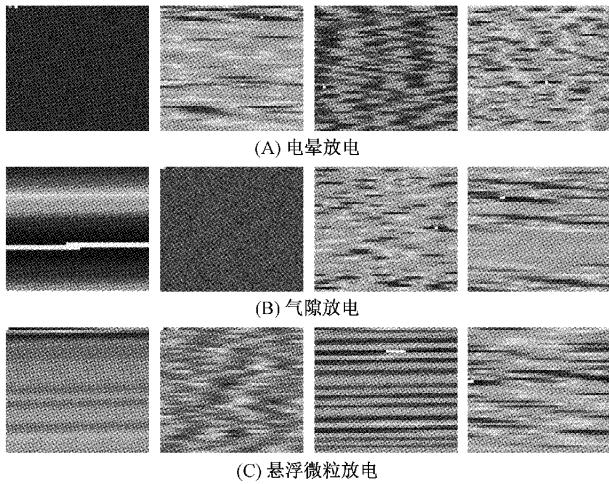


图 7 原始信号 Iradon 图

由图 7 可以看出,对于原始信号直接生成的 Iradon 图,同一故障的特征相对不同,不同故障的特征差异相对较小,各状态的特征模式杂乱无章,无明显规律。因此,需要对原始信号进行预处理,准确提取信号中所需的特征分量。

图 8、9 和 10 展示出了 3 个状态信号通过共振稀疏分解获得的高和低共振信号分量。

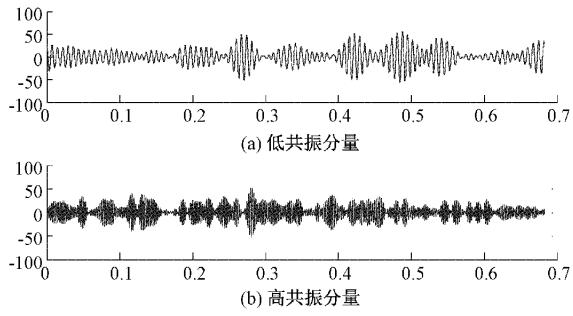


图 8 电晕放电

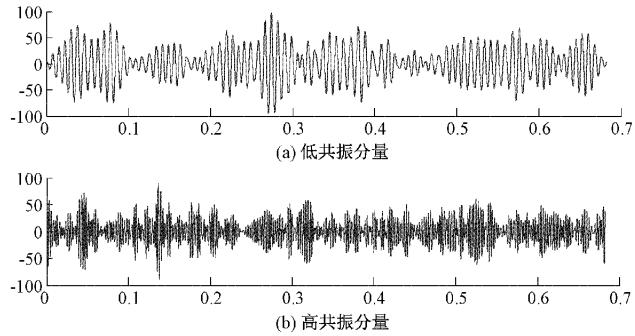


图 9 气隙放电

### 3.2 信号处理后的 Iradon 图

通过分析可以得出,瞬态冲击信号往往是故障信号的一个重要特征。同时,根据上文的结论,Iradon 图可以通过图像提取不同信号的特征,进而反映变压器不同运行状态之间的差异,因此本部分将研究基于 Iradon 的特征提取。

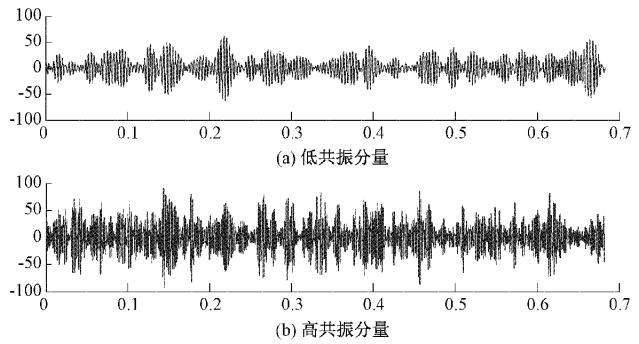


图 10 悬浮微粒放电

对 3 种故障的局部放电信号进行低共振分解,在每种故障的低共振分量中随机选取 4 个样本,对选取的 12 个样本进行 Iradon 特征分析。结果如图 11 所示。

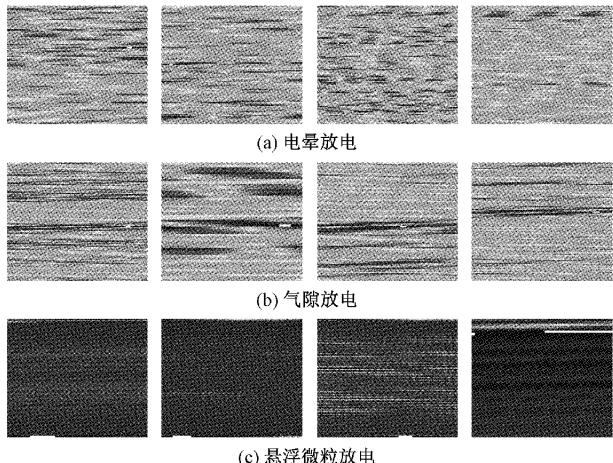


图 11 低共振分量 Iradon 图

对比图 7 和 11 可以看出,当低共振信号经历 Iradon 变换时,3 种故障状态的复原图像特征明显:电晕放电的 Iradon 变换图多为橙、黄、蓝相交,无特定形状,图像不具有连续性。气隙放电 Iradon 变换图为规则条状图案,覆盖整个界面具有较好的连续性;悬浮微粒放电图像更加整洁,显示出穿过界面的规则蓝色条纹。结合 3 种状态的图像特征,可以得出不同状态的信号在 Iradon 变换复原特征图上具有不同的特征。Iradon 变换可以清楚地显示不同状态下差异,进而进行区分。

### 3.3 基于 CNN 的局部放电故障诊断

为验证该模型是否可行,将低共振分量经 Iradon 变换后生成的图像制作成数据集。基于上述模型进行实验,通过训练集训练优化该卷积神经网络的参数值,最后利用测试集对模型性能进行测试。

首先,识别 300 组原始信号测试样本。本文模型的识别率达到 72.34%,如表 3 所示,其中电晕放电、气隙放电、悬浮微粒放电的识别率分别为 78%、74% 和 65%。

将 300 组低共振分量信号作为测试样本。该模型的识别率达到 96.34%。如表 4 所示,电晕放电、气隙放电和悬

表 3 局部放电信号的实验样本

	状态 & 类别		
	电晕放电	气隙放电	悬浮微粒放电
电晕放电	78	17	5
气隙放电	20	74	6
悬浮微粒放电	20	15	65

浮微粒放电的识别率分别为 95%、97% 和 97%。与表 3 相比, 表 4 的准确率更高。

表 4 局部放电信号低共振分量实验样本

	状态 & 类别		
	电晕放电	气隙放电	悬浮微粒放电
电晕放电	95	2	3
气隙放电	1	97	2
悬浮微粒放电	0	3	97

为使不同放电状态特征更直观地显示出来, 将经过低共振处理的全连接层特征映射为特征向量, 其包括了输入图像的全部特征信息。由图 12 可以看出, 在不同放电状态下的特征图区别鲜明。

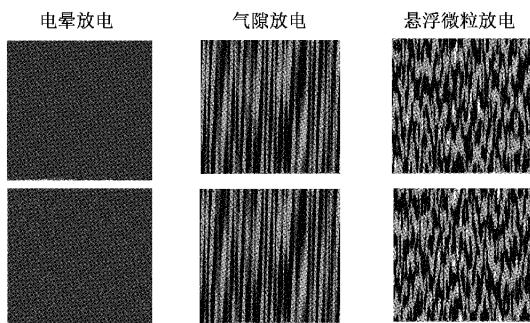


图 12 深度学习框架下不同故障状态的特征

由图 12 可以看出, 各种故障的特征差异明显。电晕放电特征图呈现蓝色区域, 仅有轻微的线性波动; 气隙放电特征图呈现蓝色和黑色重叠条, 条纹纵向跨度较大, 更具有连续性; 悬浮微粒放电特征图是一个波动较大的曲线特征, 且图片特征不具有连续性。这一结果表明, 融合特征对变压器局部放电故障的诊断有很大作用。

为了进一步论证据单一特征和融合特征的可区分性, 本文对放电状态数据点采用 T-SNE 相似性建模, 实现样本特征高维数据的可视化降维<sup>[20]</sup>。在 T-SNE 图中, 点簇的混合程度代表不同特征样本的分类。

由图 13 可以看出, 在原始信号通过全连接层输出的 T-SNE 图中, 这 3 种状态无序分布, 区间不明显, 聚类情况差, 类别间可区分度低。经过 Radon 变换后的原始信号, 3 种状态的分布有一定规律, 但仍有重叠部分。信号再次经过低共振分解后, 3 种状态的区分度非常高, 区域分离明显。

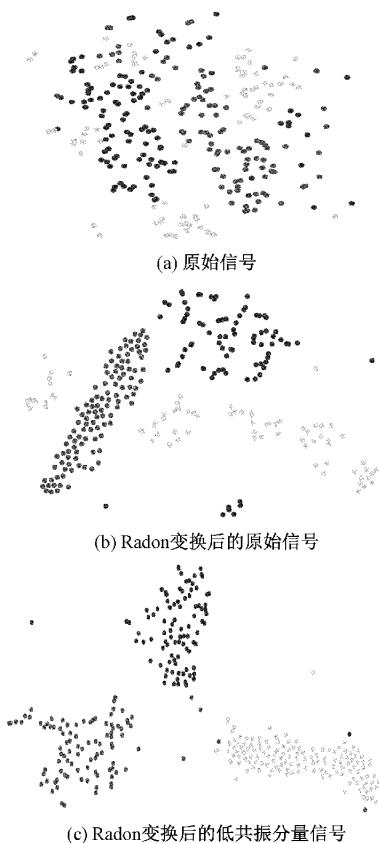


图 13 全连接层输出的 T-SNE 图

由图 14 可以看出, 随着迭代次数的增加, 模型的精度不断提高, 并在迭代 200 次左右达到峰值, 且保持平稳。

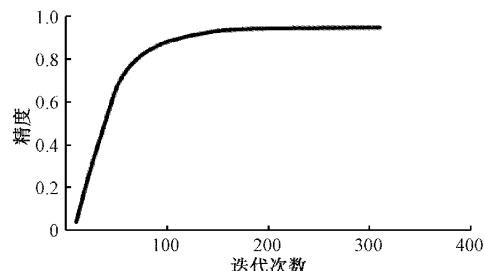


图 14 CNN 实验精度曲线

#### 4 结 论

针对变压器局部放电信号构成复杂、信号非线性等特点, 提出了一种基于 Iradon-CNN 的状态识别方法。该方法由以下 3 部分组成。首先, 对原始信号进行共振稀疏分解, 获取低共振分量。然后, 利用 Radon 变换对局部放电信号进行特征分析, 得到特征 Iradon 图像。最后, 基于 CNN 深度学习实现智能局部放电状态识别。至此, 建立了基于 Iradon-CNN 的变压器局部放电状态识别模型。通过相关实验研究, 得出以下结论:

基于 Iradon-CNN 的变压器局部放电状态识别方法实

现了对局部放电故障的快速、准确和智能识别。模型精度达到 96.34%，使局部放电信号特征学习的效果和状态识别精度都得到有效的提升。

Iradon 分析可以将局部放电信号映射成一种可视化的表达形式，确保了特征信息的完整性。更清晰、直观、完整地显示局部放电信号的特征，使不同状态特征之间的可区分性得到有效提升。

优化后的 CNN 模型能够自适应识别 Iradon 图特征，并实现准确的分类，实现高效精准的变压器局部放电状态识别。

## 参考文献

- [1] MOR A R, HEREDIA L C C, MUÑOZ F A. New clustering techniques based on current peak value, charge and energy calculations for separation of partial discharge sources [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2017, 24(1):340-348.
- [2] 肖洒,陈波,沈道贤,等.改进 VMD 和阈值算法在局部放电去噪中的应用[J].电子测量与仪器学报,2021,35(11):206-214.
- [3] GHORAT M, GHAREHPETIAN G B, LATIFI H, et al. A new partial discharge signal denoising algorithm based on adaptive dual-tree complex wavelet transform [J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(10): 2262-2272.
- [4] 刘鑫,朱宁宁,郑祥.基于联合近似对角化的多源局部放电混合信号分离方法研究[J].电子测量技术,2021,44(17):101-104.
- [5] MOR A R, MUÑOZ F A, WU J, et al. Automatic partial discharge recognition using the cross wavelet transform in high voltage cable joint measuring systems using two opposite polarity sensors [J]. International Journal of Electrical Power & Energy Systems, 2020, 117, DOI: 10. 1016/j. ijepes. 2019. 105695.
- [6] ZHU M X, WANG Y B, LIU Q, et al. Localization of multiple partial discharge sources in air-insulated substation using probability-based algorithm [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2017, 24(1): 157-166.
- [7] 王雨虹,王志中,付华,等.多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研究[J].仪器仪表学报,2022,43(3):87-97.
- [8] 程江洲,温静怡,鲍刚,等.基于 T-MobileNet-L 模型的 GIS 局部放电模式识别研究[J].电子测量技术,2021,44(20):22-28.
- [9] 张鹏,杨涛,刘亚楠,等.基于 CNN-LSTM 的 QAR 数据特征提取与预测[J].计算机应用研究,2019,36(10):2958-2961.
- [10] 王昕.迁移学习和卷积神经网络电力设备图像识别方法[J].中国测试,2020(5):108-113.
- [11] 朱霄珣,罗学智,叶行飞,等.基于深度特征学习的汽轮机转子状态识别方法[J].中国电机工程学报,2021,41(2):432-442.
- [12] GANGULY B, CHAUDHURY S, BISWAS S, et al. Wavelet kernel based convolutional neural network for localization of partial discharge sources within a power apparatus [J]. IEEE Transactions on Industrial Informatics, 2020, 17(3): 1831-1841.
- [13] PENG X, YANG F, WANG G, 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.
- [14] ZHANG A, HE J, LIN Y, et al. Recognition of partial discharge of cable accessories based on convolutional neural network with small data set [J]. COMPEL International Journal of Computations and Mathematics in Electrical, 2020, 39(2): 431-446.
- [15] 陈雨馨,王富平,程国建.基于特征融合与几何短语池化的现勘图像分类[J].国外电子测量技术,2022,40(1):8-13.
- [16] 王雨千,周峰,王世强.弹道目标微多普勒特性基于逆 Radon 变换的稀疏表示[J].火力与指挥控制,2017,42(9):55-59.
- [17] CULHA O, TANIK Y. Low complexity keystone transform and radon fourier transform utilizing chirp-Z transform [J]. IEEE Access, 2020, DOI: 10. 1109/ ACCESS. 2020. 3000998.
- [18] 许珊珊,谭兵.滤波反投影图像重建算法的研究[J].内江科技,2018,39(4):109-110,131.
- [19] 王瑜,刘钢,王玉鑫.基于点对称图像的变压器局部放电信号故障诊断[J].中国测试,2020,46(11):120-125.
- [20] WEN L, LI X, GAO L, et al. A new convolutional neural network-based data-driven fault diagnosis method [J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5990-5998.

## 作者简介

朱霄珣,博士后,讲师,硕士生导师,主要研究方向为电站设备状态监测与故障诊断和智慧运行。

E-mail:zhuxiaoxun@ncepu.edu.cn

林佳伟,硕士研究生,主要研究方向为风力发电机传动系统状态检测与故障诊断。

E-mail:linjiawei@ncepu.edu.cn