

DOI:10.12158/j.2096-3203.2022.05.021

基于 CNN+D-S 证据理论的多维信息源局部放电故障识别

王磊¹, 张磊², 牛荣泽¹, 孙芊¹, 李丰君¹, 张周胜²

(1. 国网河南省电力公司电力科学研究院, 河南 郑州 450052;

2. 上海电力大学电气工程学院, 上海 200090)

摘要:基于多维信息源融合的局部放电故障识别方法对提高故障识别的准确性和容错性具有重要意义。文中以开关柜中的典型局部放电类型为识别对象,设置4种典型的局部放电模型(电晕放电、沿面放电、悬浮放电和气隙放电),利用超声波(Ultra)法、甚-特高频(V-UHF)法以及脉冲电流法(PCM)采集不同放电类型产生的局放信号。首先利用深度卷积神经网络(CNN)算法对不同传感器测量数据进行训练,之后利用 Dempster-Shafer(D-S)证据理论对多维信息源识别结果进行融合,并作出最终决策。结果表明,相比于基于单一信息源的故障识别模式,基于多维信息源的故障识别模式准确率更高,且当多维信息源中某一信息源出现误判时仍能正确识别放电类型,对信息源的容错性更好,识别效果良好。

关键词:局部放电;故障识别;深度卷积神经网络(CNN);Dempster-Shafer(D-S)证据理论;多维信息源;信息融合
中图分类号:TM591 **文献标志码:**A **文章编号:**2096-3203(2022)05-0172-08

0 引言

局部放电故障是电气设备的主要故障之一,严重威胁电气设备的运行安全性和稳定性^[1-4]。因此,有效监测并准确识别局部放电故障十分重要,在故障发生之前及时预警并采取必要措施能够降低故障发生的概率^[5-6]。

目前常用的电气设备局部放电故障检测方法有脉冲电流法(pulse current method,PCM)、甚-特高频(very-ultrahigh frequency,V-UHF)法、暂态地电波(transient earth voltage,TEV)法以及超声波(ultra-sonic,Ultra)法等^[7-9]。PCM灵敏度高,但准确度和分辨率等受硬件参数的影响较大;V-UHF法具有检测频带宽,灵敏度高,抗干扰能力强等优点,用于检测开关柜内局部放电时常安装于开关柜压力释放通道的上方,但其对沿面放电的检测灵敏度较低;TEV法通过电容传感器在电气设备金属外壳上采集局部放电信息,对轻微的局部放电现象灵敏度较低;Ultra法抗环境噪声能力强,检测时不影响电气设备的运行,且能够直接利用超声信号对局放源进行物理定位,但只能定性地判断局部放电信号的有无,因此主要作为局部放电检测的辅助手段。综上所述,单一的检测手段很难实现局部放电故障的有效检测^[10]。因此文中针对开关柜采用在线PCM、

V-UHF法、Ultra法进行多维信息源融合的局部放电故障识别,其中在线PCM已开发出装置,具有带电显示功能和局放测量功能,现场换掉开关柜原来的带电显示器即可,成本低,可实现在线监测。V-UHF法和Ultra法目前已广泛应用于开关柜的带电检测,技术成熟,并不需要每面开关柜安装。且基于上述测量的多维信息源融合方法能够可靠判断局部放电的有无,定位局放源的位置,识别缺陷类型,因此,具有较好的经济性和实用性。

目前,国内外学者针对单一信息源下局部放电故障识别算法进行了大量研究,包括支持向量机(support vector machine,SVM)^[11]、卷积神经网络(convolutional neural networks,CNN)^[12]、反向传播(back propagation,BP)神经网络以及主成分分析法等^[13-14],并取得了令人满意的结果。在对多维信息源下局部放电故障诊断方法的研究中,研究者大都采用基于浅层分类器的融合算法,如基于SVM的多信息融合方法^[15]、基于BP神经网络的多信息融合方法等^[16],这类算法大都需要依据专家经验人工提取故障特征,且特征参量的选取严重影响整个识别模型的准确率。因此,开展基于深度学习分类器的多信息源局部放电故障诊断能够极大地避免人工选取特征参量所带来的误差,而目前对这方面的研究较少。

文中以开关柜中4种典型的局部放电故障类型为识别对象,采用PCM、V-UHF法及Ultra法联合检测,并通过CNN算法对各信息源的检测数据进行训练识别,之后利用Dempster-Shafer(D-S)证据理论对

收稿日期:2022-05-23;修回日期:2022-07-29

基金项目:国家电网有限公司科技项目“面向配电网的多维监测与运行辅助决策关键技术研究”(5400-202024-116A-0-0-00)

多维信息源的 CNN 识别结果进行融合,构建基于多维检测数据的局部放电故障识别模式,并与基于单一信息源的故障识别结果进行对比。

1 局部放电实验平台布置

文中针对开关柜中 4 种典型的局部放电故障,搭建多维传感器联合检测下的局部放电测量平台,如图 1 所示。该平台主要由交流电源、包含不同放电模型的试验腔体(腔体内介质为空气)、脉冲电流局部放电检测仪、甚-特高频传感器以及超声传感器组成。实验中缺陷模型处于空气介质下,相比于 SF₆ 介质内的局部放电,空气介质下各类缺陷起始放电电压更低,放电剧烈程度较小。前期采用特高频传感器对各类缺陷模型进行测量时测量效果较差,因此选用甚-特高频传感器 PDVUHF-02 进行测量,其检测带宽为 100 MHz~1 GHz,通带内平均等效高度为 11.5 mm,传感器与放电试验腔体之间的距离约为 10 cm。超声测量选用 PDTG-100 多功能局部放电巡检仪,其分辨率为 1 dB,中心频率为 40 kHz,与放电试验腔体之间的距离为 70 cm。脉冲电流测量选用 JFD-2010 局部放电检测仪,其检测灵敏度为 0.01 pC,采样速率为 20 M/s。

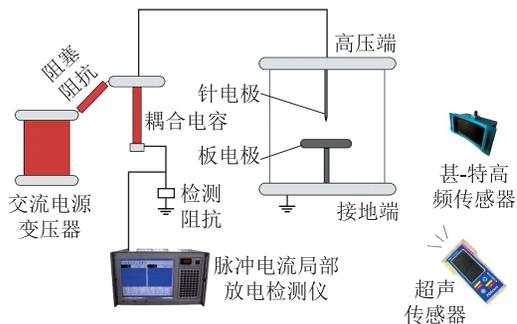


图 1 基于多维传感器联合检测的局部放电测量系统

Fig.1 Partial discharge measurement system based on multi-dimensional sensor

4 种类型的局部放电故障模型如图 2 所示,模型主要用于模拟高压开关柜内的缺陷,其内部介质为空气介质,外部试验腔体非完全密闭,这些与实际开关柜内的局部放电测量环境相似。

模型具体设置如下:(1)电晕放电。铜制针电极棒半径为 1.5 mm,针半径为 0.25 mm,铝制板电极半径为 40 mm,表面进行抛光处理,针-板间隙距离为 30 mm。(2)悬浮放电。上、下铜制针电极棒半径为 1.5 mm,针半径为 0.25 mm,利用环氧树脂环将下针电极固定在空中,上、下针电极针尖距离为 3 mm。(3)沿面放电。铝制球电极球半径为 15 mm,铝制板电极半径为 40 mm,中间环氧树脂圆形薄片

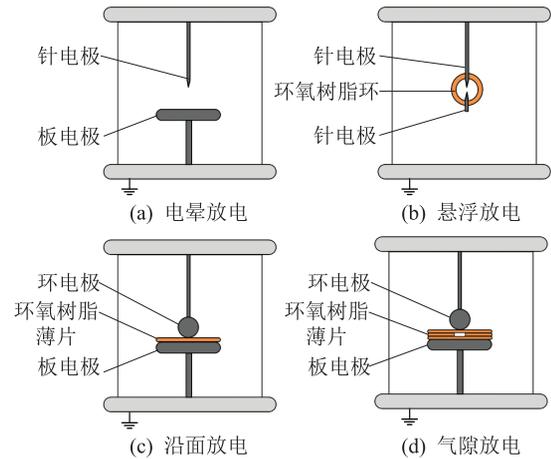


图 2 不同局部放电类型的模型

Fig.2 Models of different partial discharge types

半径为 45 mm,厚度为 2 mm,球电极底端与环氧树脂薄片上表面紧密接触。(4)气隙放电。铝制球电极球半径为 15 mm,铝制板电极半径为 40 mm。中间硅胶片为 3 层薄片叠加到一起,薄片半径均为 45 mm,薄片厚度均为 0.5 mm,且中间层在圆心位置镂空处理,镂空半径为 5 mm,3 层薄片紧密粘贴到一起,只留下中间层镂空位置存在气隙。

2 多维信息源局部放电故障识别模式

目前,SVM 这类浅层学习算法在局部放电故障识别中已经得到较多运用^[17],但 SVM 识别准确度强烈依赖于人工提取的特征参数,而深度学习算法(如 CNN)在架构和计算层次上更加复杂,可以自动完成特征提取和预测^[18]。文中针对 3 种传感器采集的不同局部放电类型图谱,分别建立 CNN 模型进行训练,待其训练完成后保存训练模型,CNN 模型的输出为 4 种放电类型的概率;利用 D-S 证据理论对 3 种传感器的 CNN 模型输出结果进行融合。

2.1 CNN 模型

CNN 是深度学习算法的代表之一,在图像分类上具有独特的优越性^[19-21]。CNN 能够自动提取图像特征,不需要在训练前人工提取图像特征参数。其自动图像特征提取主要依赖于卷积层与池化层的操作,首先将输入图像转化为以像素点值组成的图像矩阵,图像矩阵在经过卷积核的卷积操作后得到另一个矩阵(特征映射)。CNN 通过卷积核在图像上的不断滑动运算和池化层进行特征选择,降低特征数量,最终实现图像特征的自动提取^[22]。文中采用的 CNN 包括 1 个输入层、3 个卷积层、3 个池化层、1 个全连接层和 1 个输出层,具体网络结构如图 3 所示。

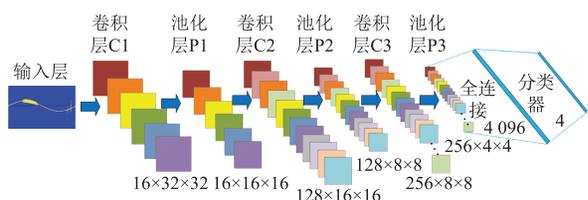


图3 CNN网络结构

Fig.3 The structure of CNN

卷积层对上层特征 $X_{i,m-1}$ 与卷积核 $K_{ij,m}$ 进行卷积计算,实现图像特征的充分提取。文中卷积核大小为 3×3 方阵,激活函数 $f(X)$ 为 ReLU 函数^[23]。具体计算公式如下:

$$X_{j,m} = f\left(\sum X_{i,m-1} \otimes K_{ij,m} + b_{j,m}\right) \quad (1)$$

式中: $X_{i,m-1}$ 为第 $m-1$ 层的第 i 个特征图谱, $i=1, 2, \dots, p$; $X_{j,m}$ 为第 m 层的第 j 个特征图谱, $j=1, 2, \dots, q$; $b_{j,m}$ 为第 m 层的第 j 个偏置量;卷积核 $K_{ij,m}$ 为第 m 层的神经元 i 的第 j 个对应权值。

池化层的作用是对卷积层得到的特征图谱进行降维,以降低网络的训练参数。池化层的具体计算公式如下:

$$X_{j,m} = \beta_{j,m} \text{down}(X_{j,m-1}) + b_{j,m} \quad (2)$$

式中: $\beta_{j,m}$ 为第 m 层的第 j 个可训练参数; $\text{down}(\cdot)$ 为下采样函数。常用的下采样方法包括均值采样 (mean-pooling)、最大采样 (max-pooling) 以及随机采样 (stochastic-pooling) 等。文中采用最大采样作为池化方法,池化核大小为 2×2 方阵,其计算如下^[24]:

$$\text{down}(X_{j,m-1}) = \max(X_{j,m-1}) \quad (3)$$

CNN 的输入为不同放电类型的图谱,图谱的尺寸统一为 32×32 。训练后,CNN 的输出为 4 种放电类型的概率,其中概率最大的放电类型为 CNN 的最终决策结果。

2.2 D-S 证据理论

D-S 证据理论是建立在辨识框架 Θ 基础上的推理模型,最早应用于专家系统中,能处理不确定信息,目前在电气设备故障信息融合领域已得到广泛应用^[10,15]。其基本思想如下^[15]:

(1) 建立辨识框架 Θ 。 Θ 为该辨识问题下所有可能的输出结果组成的集合, Θ 为一个非空的有限集合, $\Theta = \{\theta_1, \theta_2, \dots, \theta_N\}$, 其中, θ 为辨识框架内可能发生的事件 (或称之为元素), 各元素两两互斥。辨识框架全部子集的集合, 记作幂集 2^Θ , 其中 $2^\Theta = \{\emptyset, \{\theta_1\}, \{\theta_2\}, \dots, \{\theta_N\}, \{\theta_1 \cup \theta_2\}, \dots, \Theta\}$ 。

(2) 基本概率分配 (basic probability assignment, BPA)。对 Θ 中每个子集按照特定的概率分配函数 (mass 函数) 分配概率。其中分配函数 m 是

一个从 $2^\Theta \rightarrow [0, 1]$ 的映射, 即对于任意一个子集 A , 其必须满足 2 个条件:

$$m(\emptyset) = 0 \quad (4)$$

$$\sum_{A \subseteq \Theta} m(A) = 1 \quad (5)$$

(3) D-S 证据合成。利用得到的各证据的 mass 函数进行融合计算, 输出各类证据的共同辨识结论。具体融合规则可参考文献 [15]。

针对文中 3 种传感器数据, 采用 D-S 证据理论将 3 种类型数据进行融合。融合过程如图 4 所示, 首先针对 PCM、V-UHF 和 Ultra 图谱建立 3 个 CNN 初始模型, 并利用各自的图谱数据对 CNN 初始模型进行训练和参数优化; 然后对优化好的训练模型依据 D-S 证据理论建立融合模式: CNN 模型的识别结果利用基本概率分配函数分配相应概率; 最后通过各信息源的 BPA 计算综合概率并作出最终样本类型判别。图 4 中, A_1 为电晕放电; A_2 为悬浮放电; A_3 为沿面放电; A_4 为气隙放电。

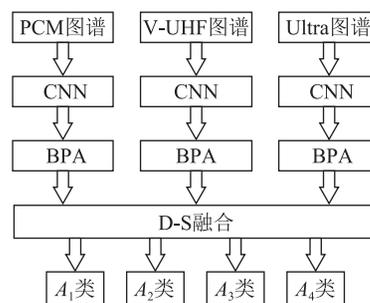


图4 基于 D-S 证据理论信息融合的框架

Fig.4 The framework of information fusion based on D-S evidence theory

文中的辨识问题为判断局部放电故障类型, 其可能的输出结果为包含电晕放电、悬浮放电等在内的 4 种放电形式以及不确定性共 5 个事件。这 5 个事件组成的集合即为该辨识问题下的识别框架 Θ :

$$\Theta = \{A_1, A_2, A_3, A_4, \theta'\} \quad (6)$$

式中: θ' 为不确定性。识别框架内对不同传感器数据识别结果的 BPA 计算方法为:

$$m_i(A_j) = \alpha_i u_{ij} \quad i = 1, 2, 3; j = 1, 2, 3, 4 \quad (7)$$

$$m_i(\theta') = 1 - \alpha_i \quad (8)$$

式中: $m_i(A_j)$ 为第 i 个信息源对第 A_j 类识别结果的概率分配函数; α_i 为第 i 类信息源的可靠性系数, 文中用第 i 类信息源单独在 CNN 下的测试准确率代替其可靠性系数; u_{ij} 为第 i 个信息源对于输出为 j 类缺陷的隶属度; $m_i(\theta')$ 为第 i 个信息源不确定性的 BPA 值。对于 4 种放电类型及其不确定性, 有:

$$\sum_{j=1}^4 m_i(A_j) + m_i(\theta') = 1 \quad (9)$$

根据 D-S 证据理论的合成规则,将 3 种信息源的 BPA 进行合成,并得出基于 3 种信息源的共同辨识结论。其中,具体融合规则为^[15]:

$$(m_1 \oplus m_2 \oplus m_3)(A) = \frac{1}{K} \sum_{A_1 \cap A_2 \cap A_3 = A} m_1(A_1) m_2(A_2) m_3(A_3) \quad (10)$$

其中:

$$K = \sum_{A_1 \cap A_2 \cap A_3 \neq \emptyset} m_1(A_1) m_2(A_2) m_3(A_3) \quad (11)$$

3 多维信息源测量及模式识别结果

3.1 局部放电测量图谱

通过图 1 所示实验平台,文中共采集了各 422 组 Ultra 图谱、PCM 图谱以及 V-UHF 图谱,各包括 100 组电晕放电、112 组悬浮放电、110 组沿面放电和 100 组气隙放电图谱。对于同一缺陷下测量的数据集,其放电图谱虽然在整体相位分布特征上具有一定的相似性,但具体来看,同一缺陷下的图谱在脉冲幅值、脉冲数量以及放电脉冲聚集簇的形状上各有不同。同时,为避免训练过程中数据集过少而造成的过拟合,文中通过改变图像亮度、图像模糊处理以及加入随机噪声等将数据集扩大 10 倍,即 Ultra、PCM 以及 V-UHF 图谱各扩充至 4 220 组。这使得同一缺陷下的样本在保留该缺陷样本的本征特征(相位分布特征)以外,同时呈现出样本其他特征(脉冲幅值、脉冲数量等特征)的多样性,以适应同一缺陷下对样本多样性的要求。文中采用的图像数据扩充方法不会改变不同类型放电图谱的放电脉冲分布特征,并且能够在测试结果上提高模型的分类准确率,避免训练过程中的过拟合。

图 5 为不同检测方法对电晕放电模型检测得到的图谱。其中图 5(a)为 PCM 检测到的图谱,可以看出,幅值较大的脉冲都分布在工频相位的负半周上,正半周上分布着许多幅值较小的脉冲;图 5(b)为 Ultra 法检测到的局部放电相位分辨(phase resolved partial discharge, PRPD)图谱,可以看出图谱具有典型的相位分布,工频相位负半周上放电点的数量和幅值都要比正半周上的高,同时在工频相位 270°附近放电点数量和幅值最大,幅值最大为 22 dB;图 5(c)为 V-UHF 法检测到的 PRPD 图谱,该图谱与 Ultra 图谱展示了相同的相位分布特性,放电多集中于工频相位的负半周,且在工频相位 270°附近放电点数量和幅值达到最大,幅值最大为 -37 dBm。因此,上述 3 种检测方式检测到的图谱都显示了典型的电晕放电特性。

图 6 为不同检测方法对沿面放电模型检测得到

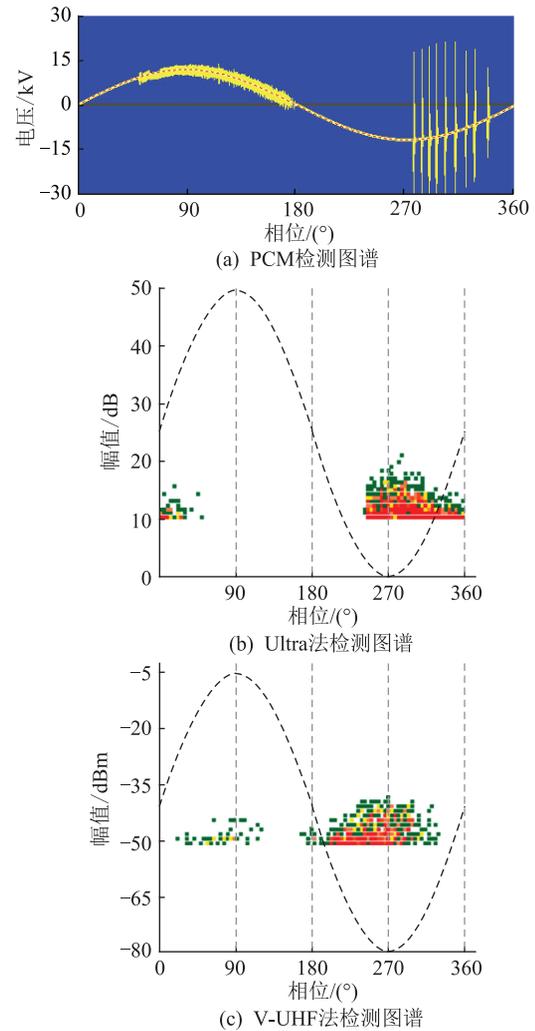
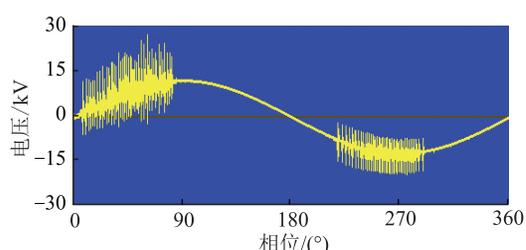


图 5 不同检测方法检测的电晕放电图谱

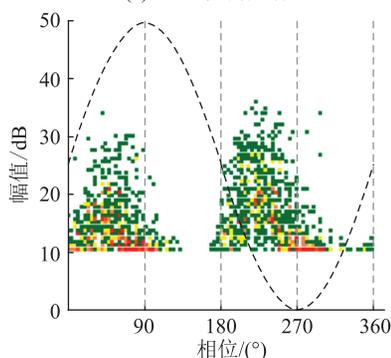
Fig.5 Corona discharge patterns detected by different detection methods

的图谱。其中图 6(a)为 PCM 检测到的图谱,可以看出,正负半周上放电脉冲幅值并不存在明显差别,放电脉冲数量与幅值在正负半周上近似相同,且主要分布在一、三象限;图 6(b)为 Ultra 法检测到的 PRPD 图谱,可以看出放电点大多分布在工频相位的一、三象限,正负半周上的放电点数量与幅值基本相同,最大幅值都在 35 dB 左右;图 6(c)为 V-UHF 法检测到的 PRPD 图谱,其放电点的分布相位与 PCM 和 Ultra 图谱展现了相同的特性,大都分布在一、三象限,在幅值上正半周最大幅值(-19 dBm)略高于负半周最大幅值(-25 dBm)。

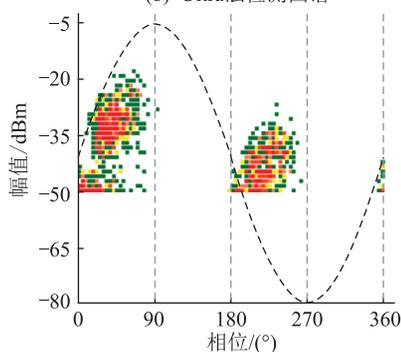
图 7 为不同检测方法对悬浮放电模型检测得到的图谱。其中图 7(a)为 PCM 检测到的图谱,可以看出,正负半周上放电脉冲幅值并不存在明显差别,放电脉冲数量与幅值在正负半周上近似相同,且放电脉冲主要分布在二、四象限;图 7(b)为 Ultra 法检测到的 PRPD 图谱,可以看出放电点大多分布



(a) PCM检测图谱



(b) Ultra法检测图谱



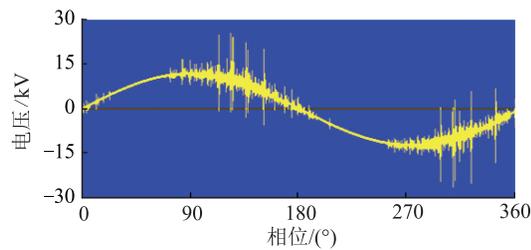
(c) V-UHF法检测图谱

图6 不同检测方法检测的沿面放电图谱

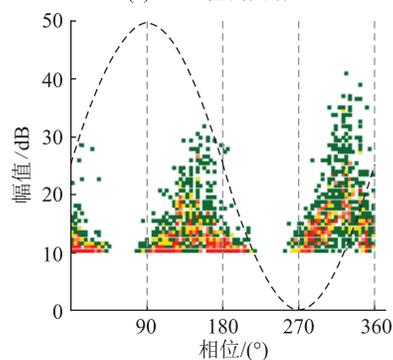
Fig.6 Suspended discharge patterns detected by different detection methods

在工频相位的二、四象限,放电幅值最大值达到了43 dB左右;图7(c)为V-UHF法检测到的PRPD图谱,其放电点的分布相位与PCM以及Ultra图谱展现了相同的特性,大都分布在二、四象限,放电点幅值分布更加集中,大部分放电点幅值分布在-40 dBm附近,最大幅值为-32 dBm。

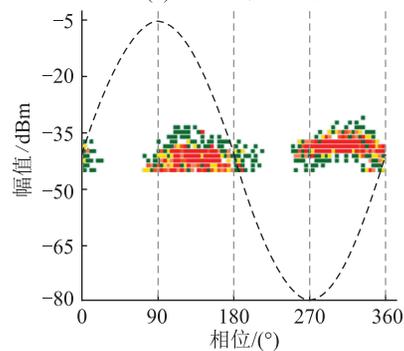
图8为不同检测方法对气隙放电模型检测得到的图谱。其中图8(a)为PCM检测到的图谱,可以看出,正负半周上放电脉冲幅值和数量基本相同,放电脉冲基本分布在相位90°和270°左右;图8(b)为Ultra法检测到的PRPD图谱,可以看出放电点相位分布与PCM展现了相同的特征,基本分布在相位90°和270°左右;图8(c)为V-UHF法检测到的PRPD图谱,其放电点的分布相位与PCM以及Ultra图谱展现了相同的特性,放电点数量与幅值正负半周基本相同,放电点幅值最大为-28 dBm。



(a) PCM检测图谱



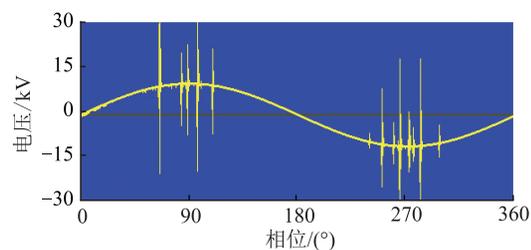
(b) Ultra法检测图谱



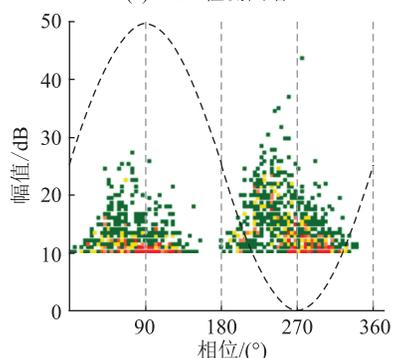
(c) V-UHF法检测图谱

图7 不同检测方法检测的悬浮放电图谱

Fig.7 Floating discharge patterns detected by different detection methods



(a) PCM检测图谱



(b) Ultra法检测图谱

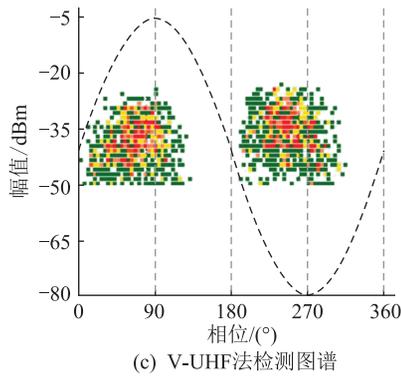


图8 不同检测方法检测的气隙放电图谱

Fig.8 Air-gap discharge patterns detected by different detection methods

3.2 多维信息源识别模式的容错性

经过 D-S 证据理论对 3 种信息源数据融合后,该模型对不同缺陷样本的识别效果差异较小,因此,文中选取电晕放电样本为代表说明所构建模型对 4 种缺陷识别的有效性和容错性。通过融合模式,分别对 PCM、Ultra 以及 V-UHF 已经训练好的 CNN 模型进行计算并输出 BPA。最后对 3 种信息源的 BPA 依据 D-S 合成规则计算融合后的概率,所选取的电晕放电样本在 3 种信息源的 BPA 以及融合后的概率计算结果如表 1 所示。

表 1 3 种信息源 BPA 及 D-S 融合的概率计算结果
Table 1 Probability calculation results of BPA and D-S fusion of three information sources

BPA	PCM	Ultra	V-UHF	D-S 融合
$m(A_1)$	0.541 1	0.344 1	0.571 6	0.822 5
$m(A_2)$	0.132 2	0.236 6	0.115 3	0.088 6
$m(A_3)$	0.071 1	0.108 2	0.096 8	0.039 3
$m(A_4)$	0.112 0	0.078 6	0.051 9	0.033 8
$m(\theta)$	0.143 6	0.232 5	0.164 4	0.015 8

由表 1 可知,3 种信息源的识别结果是一致的, $m(A_1)$ 被诊断为存在局放的概率是最大的,其中 PCM、Ultra 以及 V-UHF 模式下 $m(A_1)$ 的概率分别为 0.544 1、0.344 1 和 0.571 6,均在识别类型中占据概率最大,此时 3 种信息源输出结果是一致的,通过 D-S 融合后 A_1 类的概率达到了 0.822 5,进一步扩大了被判为 A_1 类的概率,判别结果与实际相符,融合结果提高了识别的可靠性。

为进一步验证文中所构建的多维信息源融合模式的容错性,选取 3 种传感器测量到的一组电晕放电数据,其中 PCM 和 V-UHF 法在这组数据下判断正确,而 Ultra 法的判别结果出现错误。此时 3 种信息源以及 D-S 融合后的 BPA 结果如表 2 所示。

由表 2 可知,PCM 以及 V-UHF 法中被判为 A_1

表 2 3 种信息源判别结果不一致时概率计算结果
Table 2 Probability calculation results when the judgment results of the three information sources are inconsistent

BPA	PCM	Ultra	V-UHF	D-S 融合
$m(A_1)$	0.547 3	0.188 0	0.486 8	0.675 5
$m(A_2)$	0.075 4	0.179 6	0.089 9	0.064 2
$m(A_3)$	0.041 6	0.150 5	0.042 4	0.033 8
$m(A_4)$	0.192 1	0.249 4	0.216 5	0.206 4
$m(\theta)$	0.143 6	0.232 5	0.164 4	0.020 1

类的概率最大,分别为 0.547 3 和 0.486 8。而 Ultra 法的识别结果与 PCM 和 V-UHF 法出现了分歧, Ultra 模式下 A_4 类型的概率最大,为 0.249 4, A_1 类的概率仅为 0.188 0。通过 D-S 融合后, A_1 类的概率最大,为 0.675 5, A_4 类的概率为 0.206 4。由此可知,当某个信息源在识别中出现误判时,通过 D-S 融合仍能排除干扰,作出正确判断,具有一定的容错性。

4 识别效果比较与分析

文中将测量并扩充后得到的 4 220 组数据按照 8:2 分为训练集和测试集,按照 CNN 算法模型,分别对 Ultra、V-UHF 以及 PCM 图谱进行训练和测试。在对单一信息源数据的识别中, CNN 对 4 种缺陷的识别效果各不相同,这主要是由于单一传感器本身对 4 种缺陷放电的测量效果存在差异。但经过 D-S 证据理论对 3 种信息源数据进行融合后,其对 4 种缺陷的识别效果差异不大。因此,文中主要对单一信息源与多维信息源数据融合后的识别效果进行了对比,具体训练和测试结果见表 3。

表 3 识别效果对比
Table 3 Comparison of recognition accuracy %

数据类型	训练准确率	测试准确率
Ultra	92.14	76.75
V-UHF	93.25	83.56
PCM	96.87	85.64
Ultra+V-UHF+PCM (D-S 融合)		93.13

从测试结果可以看出,在单一的识别模式中, PCM 测试准确率最高,能达到 85.64%, V-UHF 法测试准确率为 83.56%, Ultra 法测试准确率最低,仅有 76.75%,相比于 PCM 准确率下降了 8.89%,因此可以发现 Ultra 法在模式识别中表现最差,不能很好地区分所设置的 4 种放电类型。同时,单一数据源的模式识别中测试准确率普遍低于 90%,而文中采用的基于 Ultra、V-UHF 以及 PCM 三者图谱的 D-S 融合识别方法的测试准确率达到 93.13%,是测试准确率最高的方法。相比于单一信息源下 Ultra 法,

V-UHF法,PCM 的测试准确率分别提高了 16.38%, 9.57%和 7.49%。

5 结论

(1) 基于单一信息源对电晕放电、沿面放电、悬浮放电以及气隙放电进行识别,PCM 识别效果最好,测试准确率能达到 85.64%,Ultra 法识别效果最差,测试准确率仅有 76.75%。

(2) 在多维信息源下,当各信息源的识别结果一致时,通过 D-S 融合能进一步扩大正确放电类型的概率;当多维信息源中某一信息源的识别结果出现误判时,通过 D-S 融合能够排除错误信息源的干扰,准确识别放电类型,提高识别模式的容错性。

(3) 文中采用的 CNN+D-S 证据理论的三维信息源融合识别方法比单一信息源模式识别的测试准确率高,测试准确率达到 93.13%,识别效果良好。

参考文献:

- [1] 何金,田涛,宋晓博,等. 基于特高频法的开关柜局部放电识别方法研究[J]. 高压电器,2020,56(11):90-95,101.
HE Jin, TIAN Tao, SONG Xiaobo, et al. Research on partial discharge identification method of switchgear based on UHF method[J]. High Voltage Apparatus, 2020, 56(11): 90-95, 101.
- [2] SHAHSAVARIAN T, PAN Y, ZHANG Z S, et al. A review of knowledge-based defect identification via PRPD patterns in high voltage apparatus[J]. IEEE Access, 9: 77705-77728.
- [3] 李玉杰,田阳普,赵科,等. 基于自编码网络的局部放电信号特征提取与识别[J]. 电力工程技术, 2021, 40(3): 148-152.
LI Yujie, TIAN Yangpu, ZHAO Ke, et al. Feature extraction and recognition of partial discharge signal based on self-encoding network[J]. Electric Power Engineering Technology, 2021, 40(3): 148-152.
- [4] 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.
- [5] 徐卫东,聂一雄,周文文,等. 固体绝缘开关柜局部放电模式识别优化算法[J]. 高压电器, 2019, 55(5): 100-107.
XU Weidong, NIE Yixiong, ZHOU Wenwen, et al. Optimization algorithm for partial discharge pattern recognition of solid insulated switchgear [J]. High Voltage Apparatus, 2019, 55(5): 100-107.
- [6] 田妍,刘宇舜,熊俊,等. 基于时频分布图像纹理特征的局部放电特高频信号的特征参数提取方法[J]. 高压电器, 2017, 53(7): 30-37, 44.
TIAN Yan, LIU Yushun, XIONG Jun, et al. Feature parameters extraction method of partial discharge UHF signal based on textural features in time-frequency representation image[J]. High Voltage Apparatus, 2017, 53(7): 30-37, 44.
- [7] 关少平,韩肖清,王佳莉,等. 基于联合检测的环网柜局部放电方法研究[J]. 电测与仪表, 2020, 57(13): 126-129, 136.
GUAN Shaoping, HAN Xiaoqing, WANG Jiali, et al. Research on partial discharge of ring network cabinet based on combined detection method [J]. Electrical Measurement & Instrumentation, 2020, 57(13): 126-129, 136.
- [8] 黎宏飞,高宗宝,江建明,等. 开关柜典型缺陷模型的 TEV 和超声波法局部放电特征研究[J]. 绝缘材料, 2018, 51(5): 81-86.
LI Hongfei, GAO Zongbao, JIANG Jianming, et al. Study on partial discharge characteristics of typical defect model of switch cabinet by TEV and ultrasonic method[J]. Insulating Materials, 2018, 51(5): 81-86.
- [9] 张炜,俸波,邬蓉蓉. 局部放电脉冲信号特征向量的提取方法[J]. 绝缘材料, 2018, 51(7): 77-82.
ZHANG Wei, FENG Bo, WU Rongrong. Extraction method of characteristic vectors of partial discharge pulse signal[J]. Insulating Materials, 2018, 51(7): 77-82.
- [10] 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.
- [11] 弓艳朋,刘有为,吴立远. 采用分形和支持向量机的气体绝缘组合电器局部放电类型识别[J]. 电网技术, 2011, 35(3): 135-139.
GONG Yanpeng, LIU Youwei, WU Liyuan. Identification of partial discharge in gas insulated switchgears with fractal theory and support vector machine [J]. Power System Technology, 2011, 35(3): 135-139.
- [12] 王菲菲,阮爱民,魏刚,等. 基于卷积神经网络的开关柜局部放电故障识别[J]. 电气技术, 2019, 20(4): 76-81.
WANG Feifei, RUAN Aimin, WEI Gang, et al. Partial discharge fault identification of switchgear based on convolutional neural network [J]. Electrical Engineering, 2019, 20(4): 76-81.
- [13] 陈敬德,高兆丽,罗林根,等. 基于 BP 神经网络的特高频局部放电定位误差校正[J]. 高电压技术, 2018, 44(6): 2040-2047.
CHEN Jingde, GAO Zhaoli, LUO Lingen, et al. Error correction of UHF partial discharge location method based on BP network [J]. High Voltage Engineering, 2018, 44(6): 2040-2047.
- [14] 张秦棣,宋辉,姜勇,等. 基于 OS-ELM 的变压器局部放电模式识别[J]. 高电压技术, 2018, 44(4): 1122-1130.
ZHANG Qinqi, SONG Hui, JIANG Yong, et al. Partial discharge pattern recognition of transformer based on OS-ELM [J]. High Voltage Engineering, 2018, 44(4): 1122-1130.
- [15] 王瑜. 基于支持向量机和多信息融合的局部放电故障诊断研究[D]. 北京:华北电力大学, 2015.
WANG Yu. Study on partial discharge fault diagnosis based on support vector machine and information fusion [D]. Beijing: North China Electric Power University, 2015.

- [16] 龙官微,穆海宝,张大宇,等. 基于多特征融合神经网络的串联电弧故障识别技术[J]. 高电压技术,2021,47(2):463-471.
LONG Guanwei, MU Haibao, ZHANG Daning, et al. Series arc fault detection technology based on multi-feature fusion neural network[J]. High Voltage Engineering, 2021, 47(2):463-471.
- [17] 陈继明,许辰航,李鹏,等. 基于时频分析与分形理论的 GIS 局部放电模式识别特征提取方法[J]. 高电压技术,2021,47(1):287-295.
CHEN Jiming, XU Chenhang, LI Peng, et al. Feature extraction method for partial discharge pattern in GIS based on time-frequency analysis and fractal theory[J]. High Voltage Engineering, 2021, 47(1):287-295.
- [18] 黄新波,胡潇文,朱永灿,等. 基于卷积神经网络算法的高压断路器故障诊断[J]. 电力自动化设备,2018,38(5):136-140,147.
HUANG Xinbo, HU Xiaowen, ZHU Yongcan, et al. Fault diagnosis of high-voltage circuit breaker based on convolution neural network[J]. Electric Power Automation Equipment, 2018, 38(5):136-140,147.
- [19] 万晓琪,宋辉,罗林根,等. 卷积神经网络在局部放电图像模式识别中的应用[J]. 电网技术,2019,43(6):2219-2226.
WAN Xiaoyi, SONG Hui, LUO Linggen, et al. Application of convolutional neural networks in pattern recognition of partial discharge image[J]. Power System Technology, 2019, 43(6):2219-2226.
- [20] UCKOL H I, ILHAN S, OZDEMIR A. Partial discharge pattern classification based on deep learning for defect identification in MV cable terminations[C]//2020 IEEE International Conference on High Voltage Engineering and Application. Beijing, China. IEEE;1-4.
- [21] 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.
- [22] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems-Volume 1. New York: ACM, 2012:1097-1105.
- [23] SHANG W L, SOHN K, ALMEIDA D, et al. Understanding and improving convolutional neural networks via concatenated rectified linear units[C]//Proceedings of the 33rd International Conference on International Conference on Machine Learning-Volume 48. New York: ACM, 2016:2217-2225.
- [24] YUE K Y, XU F X, YU J N. Shallow and wide fractional max-pooling network for image classification[J]. Neural Computing and Applications, 2019, 31(2):409-419.

作者简介:



王磊

王磊(1978),男,硕士,高级工程师,从事配电网安全经济运行技术相关工作;

张磊(1996),男,博士在读,研究方向为电力设备状态检测、局部放电故障识别、气体放电(E-mail:743802269@qq.com);

牛荣泽(1989),男,硕士,工程师,从事配电网运行分析工作。

Partial discharge fault identification of multi-dimensional information sources based on CNN+D-S evidence theory

WANG Lei¹, ZHANG Lei², NIU Rongze¹, SUN Qian¹, LI Fengjun¹, ZHANG Zhousheng²

(1. State Grid He'nan Electric Power Research Institute, Zhengzhou 450052, China;

2. School of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: The partial discharge fault identification method based on the fusion of multi-dimensional information sources can greatly improve the accuracy and fault tolerance in the fault identification of power equipment. In this paper, four typical partial discharge models, namely corona discharge, suspended discharge, floating discharge and air-gap discharge are prepared. The partial discharge signals generated by different discharge models are collected by ultrasonic (Ultra), very-ultra high frequency (V-UHF) and pulse current method (PCM) sensors. Firstly, the deep convolutional neural network (CNN) algorithm is used to train the measurement data of different sensors, and then the Dempster-Shafer (D-S) evidence theory is used to perform fusion calculation on the recognition results of multi-dimensional information sources. Finally, according to the fusion calculation results, the identification conclusion is made. The results show that the fault identification model based on multi-dimensional information sources constructed in this paper has higher accuracy than that based on single information source. When a misjudgment occurs in one of the multi-dimensional information sources, the model can still correctly identify the type of discharge, which indicates that the model has better fault tolerance for the information sources and the recognition effect is good.

Keywords: partial discharge; fault identification; convolutional neural network (CNN); Dempster-Shafer (D-S) evidence theory; multi-dimensional information sources; information fusion

(编辑 方晶)