

油浸式变压器内多源局部放电谱图类型识别方法研究

王彦博^{1,2}, 王伟^{1,2}, 王大伟^{1,2}, 邹雅珺^{1,2}, 常丁戈³, 张冠军³

(1. 全球能源互联网集团有限公司, 北京 100031; 2. 全球能源互联网发展合作组织, 北京 100031;
3. 西安交通大学, 陕西 西安 710049)

摘要: 电力变压器内的局部放电现象既是造成绝缘劣化的主要诱因,也是表征绝缘状况的特征量,准确识别局部放电的类型对于变压器绝缘状况诊断具有重要意义。本文提出一种基于Faster-RCNN算法的多源局放谱图类型识别方法,可以从多源谱图中检测到不同类别的局部放电信息簇。结果表明:将该算法运用到35 kV变压器测试获得的局放谱图中,多源放电的平均识别准确率达到72.1%,其中气隙缺陷放电点数量密集,谱图特征也较为明显,其漏检率和错检率相较于其他缺陷较低,具有较好的可分辨性。尖端缺陷由于间断性放电的特点和起始放电电压较高,导致漏检率较高。

关键词: 电力变压器;类型识别;局部放电;RCNN

中图分类号: TM854 DOI:10.16790/j.cnki.1009-9239.im.2023.04.014

Study on object recognition method of multi-source PD diagrams in oil-immersed power transformer

WANG Yanbo^{1,2}, WANG Wei^{1,2}, WANG Dawei^{1,2}, ZOU Yajun^{1,2}, CHANG Dingge³, ZHANG Guanjun³

(1. Global Energy Interconnection Co., Ltd., Beijing 100031, China; 2. Global Energy Interconnection Development and Cooperation Organization, Beijing 100031, China;
3. Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Partial discharge (PD) phenomenon in power transformer is not only the main cause of insulation deterioration, but also the characteristic parameter to characterize the insulation condition. It is of great significance to accurately recognize the type of PD for the diagnosis of transformer insulation condition. A new method for identifying the type of multi-source PD spectrum based on Faster-RCNN algorithm was proposed in this paper, which can detect different types of PD clusters from multi-source spectrum. The results show that the average recognition accuracy of multi-source PD reaches 72.1% when the proposed algorithm was applied to the PD spectrum obtained from 35 kV transformer. Because the air gap defect has dense PD points and obvious characteristics, its missed and false detection rates are lower than other defects, leading to there be good discrimination for the air gap defect. Because the tip defect has the characteristics of intermittent discharge and high initial discharge voltage, its missed detection rate is high.

Key words: power transformer; pattern recognition; partial discharge; RCNN

0 引言

局部放电是指设备绝缘内发生的非贯穿性放电,它是绝缘故障早期的主要表现形式,既是引起绝缘劣化的主要诱因,又是表征绝缘状况的特征量^[1]。通过开展局部放电离线或在线检测,可以在一定程度上发现变压器内部存在的绝缘缺陷,从而进一步准确地诊断设备的绝缘状况^[2-4]。模式识别是指通过对采集的局部放电数据进行分析得到对应的放电类型,是局部放电检测中的重要部分。不同的放电类型对于油浸式变压器的危害程度不同,因此准确地诊断出放电类型对于评估缺陷的危险

程度及变压器的绝缘状态具有重要意义^[5-7]。

当局部放电来源于单一缺陷点时,研究者可通过从脉冲波形或谱图中提取特征,之后再采用模糊分类^[8]、K邻近分类^[9-10]、神经网络^[11-12]、支持向量机^[13-14]、随机森林^[15]等方法进行模式识别。特征提取方法主要包括离散傅里叶变换^[16]、小波分解^[17-18]、功率谱密度直方图^[8]等多种方法。

当变压器内多个位置存在缺陷时,传感器会接收到来自非同源的信号,此时局部放电波形和谱图中会出现多源信号的混合及交叠覆盖现象,如图1所示。与单源局部放电谱图识别方法不同,单源谱图中由于仅存在一类缺陷,可直接使用谱图内的特

征与训练集的特征库进行计算比对,识别出该类缺陷的类型。对于多源局部放电,同一谱图中存在多类局放特征,若直接将谱图中提取的属于异类缺陷的所有特征统一起来进行模式识别,必然导致类型识别结果的不准确。因此多缺陷的共存增加了局部放电信号分析诊断的难度^[1,19-21]。




图1 双源缺陷放电PRPD谱图

Fig.1 PRPD Pattern of double source defect discharge

针对多个局放源同时放电的情况,文献[21-26]都进行了深入研究。首先对多缺陷源的脉冲波形进行分类,之后对单一类别的局放信号波形进行识别以解决多源放电问题。但由于变压器内结构复杂,采集到的波形数据一方面受缺陷放电类型的影响,另一方面经过复杂的传播路径或电路结构波形会发生严重畸变,难以从波形数据中提取出可以有效反映缺陷处放电类型本身的特征量,识别方法难以具有普适性。

采用谱图进行多源识别的难度体现在两个方面:一是当两种信号谱图相互重叠时,谱图中的信号点覆盖在一起,在PRPD谱图中两类信号间难以存在明显的界限,导致算法不能自适应地选择出合适的候选区域用以分别提取特征;二是两类信号存在重叠时,难以从重叠区域中分别提取出两类信号的特征,导致识别结果不准确。因此多源局放识别需要在两类或多类放电信号拥有明显分界的谱图中进行,这样便于算法自适应地选择出合适的候选区域,也可以更好地提取出异类缺陷的局放信号特征。本文介绍了等效时长-特效频率图谱的计算方法,然后介绍了基于深度学习的Faster-RCNN算法基本原理,其次介绍了实验平台与缺陷设计,最后阐述了多源识别应用实例的结果与分析。

1 等效时长-特效频率图谱计算方法

本文采用的等效时长-特效频率图谱,简称为T-F谱图^[19-20],其他的多源分离谱图也同样适用本文

所述方法,在此不再赘述。等效时长、等效频宽作为一种特征提取映射工具,可以将局部放电脉冲波形中的大量信息进行压缩降维,在信号分离和识别中具有重要作用。若一局放波形有 K 个采样点, $s(t_i)$ 代表 t_i 时刻下的局部放电信号,则时间重心 t_0 可定义为式(1)。

$$t_0 = \frac{\sum_{i=0}^K t_i \cdot s(t_i)^2}{\sum_{i=0}^K s(t_i)^2} \quad (1)$$

等效时间长度 T 可定义为式(2)。

$$T^2 = \frac{\sum_{i=0}^K (t_i - t_0)^2 \cdot s(t_i)^2}{\sum_{i=0}^K s(t_i)^2} \quad (2)$$

对局部放电时域脉冲波形进行快速傅里叶变换,可得到频率分量 $X(f_i)$,等效带宽 W 可定义为式(3)。

$$W^2 = \frac{\sum_{i=0}^K f_i \cdot |X(f_i)|^2}{\sum_{i=0}^K |X(f_i)|^2} \quad (3)$$

经过运算,等效时长 T 和等效带宽 W 可以将检测到的局部放电信号紧凑直观地映射到 T - W 平面(或 T^2 - W^2 平面)。理想情况下,对于特性相近的局部放电脉冲信号,在 T - W 平面中会聚类成界限分明的一簇^[18-19]。

2 基于深度学习的Faster-RCNN算法基本原理

传统的Viola-Jones级联分类器的特征量包括类Haar特征和局部二值模式特征^[27],该分类器适合识别结构比例较为固定的目标,而对于结构比例变化较大的目标则效果欠佳。多个放电点聚集而成的谱图,其尺度和结构可随着噪声水平、放电源数量、放电强度的不同而改变,因此该类分类器不能满足多源局部放电谱图类型识别的要求。

2.1 RCNN算法

RCNN(regions with convolutional neural network)^[28-30]算法采用了区域提取技术,首先对每个区域提取卷积神经网络(convolutional neural network, CNN)特征,再用分类器识别该区域内是否包含特定类特征,转化为分类问题。如图2所示,RCNN算法主要包含4个步骤,分别为获取谱图、产生类别独立的候选区域、将每一区域输入CNN网络提取特征向量、使用SVM对特征进行类别判定。

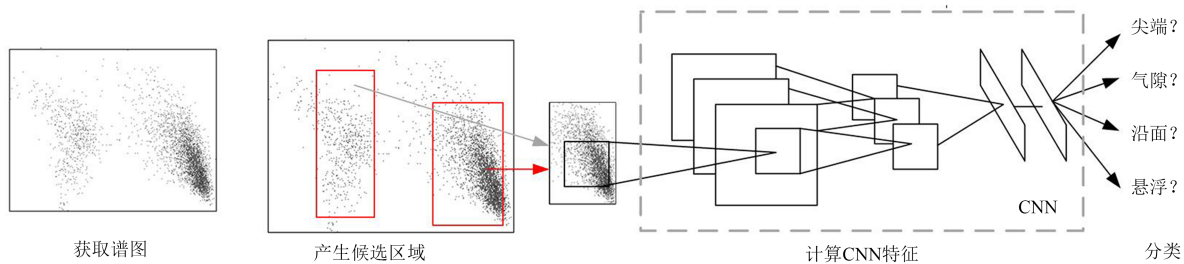


图2 RCNN算法识别步骤

Fig.2 The steps of RCNN algorithm detection

RCNN中产生候选区域的算法为选择性搜索算法^[29](selective search algorithm)。首先通过图像分割方法^[30]分割原始谱图,计算分割后每两个相邻小区域的灰度与纹理相似度,合并所有区域中最相似的两块区域。之后重新计算合并后的区域与其他区域间的相似度,不断循环该过程直到仅剩下一张完整的谱图。同时给小区域更大的权重以保证在图像的各个位置均可以实现多尺度合并,由此根据每次迭代过程产生的区域及合并的区域便可得到图像的分层表示,即产生图2中所示的候选区域。

在候选区域进行固定尺寸的缩放并输入CNN进行特征提取。将原始谱图经过卷积核进行卷积,可得到特征映射矩阵,其中每一个卷积核可从谱图中提取特征,当使用多个卷积核时可得到一系列的特征映射,由此可以得到卷积层。池化可在保留重要信息的同时将卷积层中的特征映射缩小,即保留卷积层中每一个小块内的最大值。当对所有卷积层中特征映射进行池化操作后,便可极大程度减少

计算量。全连接层对提取到的特征进行非线性组合以得到输出,利用现有的高阶特征完成学习目标。

在特征提取之后,将特征输入支持向量机中进行类型识别。为了在原始谱图中显示目标所在的具体位置,需要将CNN对候选区域提取出的特征输入到训练好的边界框回归器中。由此可检测到谱图中是否存在目标类别。

2.2 Fast-RCNN 算法

RCNN算法由于每一幅谱图中所有的候选区域均需要进行卷积运算,存在计算量过大以及训练步骤过多等问题。Fast-RCNN算法在RCNN算法基础上可以实现更快的计算速度和更准确的检测精度。与RCNN算法相比,Fast-RCNN算法最大不同之处在于仅对整体谱图进行卷积特征映射,之后再根据候选区域的位置分别提取不同候选区域的特征。Fast-RCNN算法针对某一候选区域的算法步骤如图3所示。

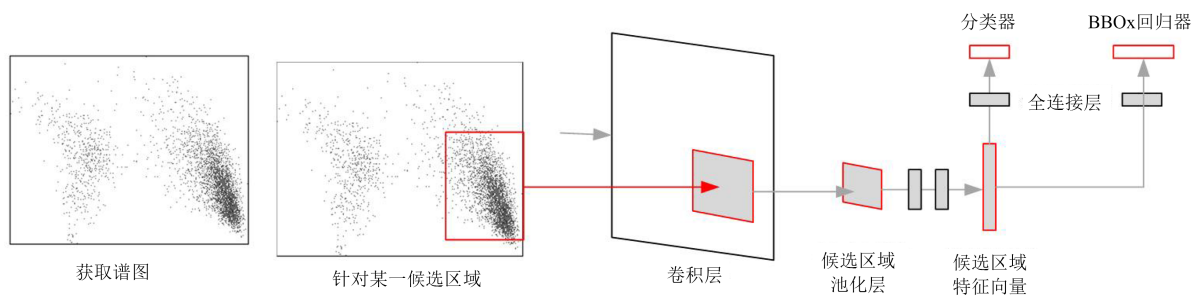


图3 Fast-RCNN算法流程图

Fig.3 Fast-RCNN algorithm flowchart

在获取谱图并搜索出候选区域后,Fast-RCNN算法将整幅谱图进行卷积运算,得到谱图整体的卷积层和池化层。之后针对某一候选区域,从特征映射中选择其相对应的部分,并将候选区域的特征映射分为两部分输入到全连接层中。一部分作为分类器所使用的特征,另一部分提供给边界框回归器用来定位到识别的目标。

2.3 Faster-RCNN 算法

Faster-RCNN 算法与 RCNN 算法相比, Fast-

RCNN算法并未采用选择性搜索算法来从原始谱图中选择候选区域,从而避免了前两种算法在候选区域选择上花费大量的计算时间。Faster-RCNN算法在对整体谱图进行卷积求取特征映射之后再行候选区域的选择,其余过程与Fast-RCNN算法基本类似,如图4所示。候选区域网络是一个全卷积网络,用来选择候选区域,由于候选区域是从特征映射上选取出来的,在边界框回归时需要从原始谱图中寻找精确的边界框。

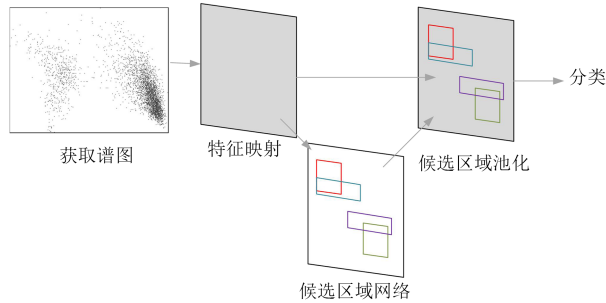


图4 Faster-RCNN 算法流程图

Fig.4 Faster-RCNN algorithm flowchart

3 实验平台与缺陷设计

本文采用的35 kV变压器局部放电实验平台由一台35 kV三相双绕组变压器、可植入式放电缺陷模型以及局放检测系统组成。变压器内可放入多个缺陷模型以对不同位置的多种放电类型进行模拟。高压套管从变压器箱体上部进行安装,套管末屏经检测阻抗接地,通过在接地线上安装高频罗氏线圈实现局部放电检测,如图5所示。高频电流法通过高频罗氏线圈接入放电回路的方式将缺陷模型放电产生的局放脉冲信号进行耦合,并通过局放测试仪进行局放检测。本文采用意大利TechImp公司PDcheck采集高频电流数据,该局放仪可记录局部放电的PRPD谱图以及脉冲信号的时频域波形图,采样率为100 MS/s,带宽为16 kHz~30 MHz。

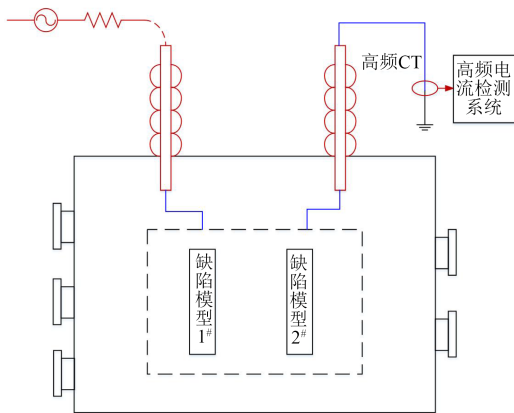


图5 35 kV变压器局放检测系统示意图

Fig.5 Diagram of PD detection system for 35 kV transformer

变压器内部设有两个缺陷模型卡槽,如图6所示。缺陷模型卡槽1#和缺陷模型卡槽2#可同时设置也可单独设置,因此该平台同时具备单一局放模拟以及多源局放模拟的功能。缺陷模型设置在缺陷模型支架上,通过固定弹簧、电极引线连接至高压套管或地电极,更换缺陷模型时仅需将缺陷模型支架整体卡入固定缺陷位置即可,缺陷模型整体实物如图7所示。

本文设计了尖端、悬浮、沿面及气隙4种典型缺

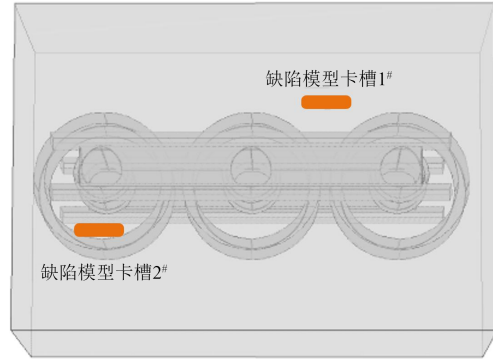


图6 缺陷卡槽位置示意图

Fig.6 Position diagram of defective card slot




图7 缺陷模型整体实物图

Fig.7 Defect model overall physical picture

陷模型。尖端缺陷高压电极采用长度为6 mm的钨针进行模拟,地电极上固定油浸绝缘纸板以避免缺陷在局放起始后快速击穿,通过调节尖端与地电极间的距离可以改变放电起始电压(partial discharge inception voltage, PDIV)和放电强度。由于尖端缺陷与其余缺陷的电极结构及放电形式差异较大,为使多源缺陷PDIV尽量一致,尖端与地电极之间距离不应过大,本文设置尖端缺陷与油浸绝缘纸板的距离约为1 mm,尖端缺陷模型示意图及照片如图8(a)所示。沿面缺陷高压电极为圆柱电极,地电极上固定一层油浸绝缘纸板,圆柱电极与绝缘纸板相接触,其中高压圆柱电极直径不应过大,若高压电极与地电极直径相近,则极容易发生击穿。本文使用直径为5 mm的高压圆柱电极、直径为15 mm的地电极,沿面缺陷模型示意图与照片如图8(b)所示。使用砂纸打磨油浸绝缘纸板,改变油纸表面的粗糙度以调整沿面放电缺陷的PDIV和放电强度。油浸绝缘纸板表面越粗糙,PDIV越低。在两层油浸绝缘纸板间加入一个圆形金属铜片模拟悬浮缺陷,制作过程中需要注意将两层油浸绝缘纸板压实,避免产生气泡。通过调整油浸绝缘纸板的厚度和圆形铜片直径大小来改变PDIV和放电强度,所选铜片直径约为7 mm,悬浮缺陷示意图及照片如图8(c)所示。在油浸绝缘纸板中间裁剪出一圆形区域,用两层厚度较薄的油浸绝缘纸覆盖气泡以模拟气隙缺陷,制作过程中需保证气泡的存在同时避免在中心存在多个气泡,可通过调整绝缘纸板和两侧油浸纸

的厚度来改变PDIV和放电强度,气隙缺陷示意图及照片如图8(d)所示。

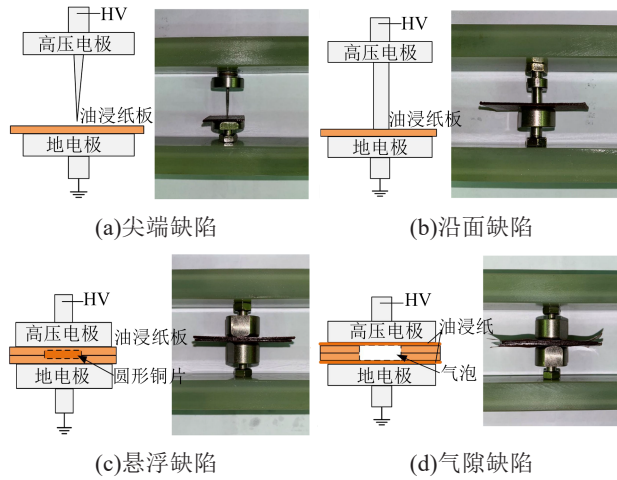


图8 缺陷模型结构

Fig.8 Structures of defect models

4 结果与分析

4.1 T-F谱图训练数据集的构建

在获取到单源局放T-F谱图后,首先需要对该谱图进行相应的预处理,去掉包括坐标、图题、图例等无价值信息。由于彩色谱图中每个像素点的颜色值由RGB 3个分量决定,每个分量有0~255种取值,每个点的颜色变化数量过多,而灰度图像的每个像素点只有0~255种取值,采用灰度图像可减少大量工作量。因此需要将彩色谱图转化为灰度图像。在灰度谱图中存在数量较多的噪声点,这些噪声点会影响后续特征提取,本文采用二值化处理与八邻域法去除噪点。首先将谱图中所有像素点的灰度值设置为0或255,其中接近白色的像素点灰度值设置为255,接近黑色的像素点灰度值设置为0,将谱图整体呈现出明显的黑白效果,突出谱图的轮廓。八邻域法的原理是依次遍历图中所有非白色的像素点并计算其周围8个点中属于非白色点的个数,由于谱图中的噪点大多是孤立点,若数量小于阈值即可判断该点就是噪点,本文阈值设置为6。

训练数据部分典型样本如图9所示。构建数据集时,需要将包含单源放电信号的不同放电阶段、不同放电强度、不同放电点数量的谱图样本包含进去以扩充训练集,本文采用的训练集包括变压器实验平台上获得的4种单源缺陷(尖端、沿面、悬浮、气隙)基于高频电流法采集到的T-F谱图总计400幅。采用MATLAB软件中图像处理和计算机视觉中的Training Image Labeler应用程序对400幅典型样本进行类型标注,标注过程中需要在谱图中框出范围,即手动画出边界框以包含400幅T-F谱图中信号存在的区域。对于不同类型的单源信号,不能直接

选择T-F谱图的边界作为边界框,而应该将预处理遗漏的离散点进行舍弃,仅对包含主要的放电点部分进行边界框的划分,同时边框的选择不可仅包含信号点集中区域,否则将难以涵盖该类信号T-F谱图中全部的特征信息。但由于本文的缺陷设计上4种缺陷类型存在缺陷尺寸以及类型的配合比较单一,必然导致训练样本集的涵盖面较窄、样本种类受限的问题,对于实验结果也有一定的负面影响。

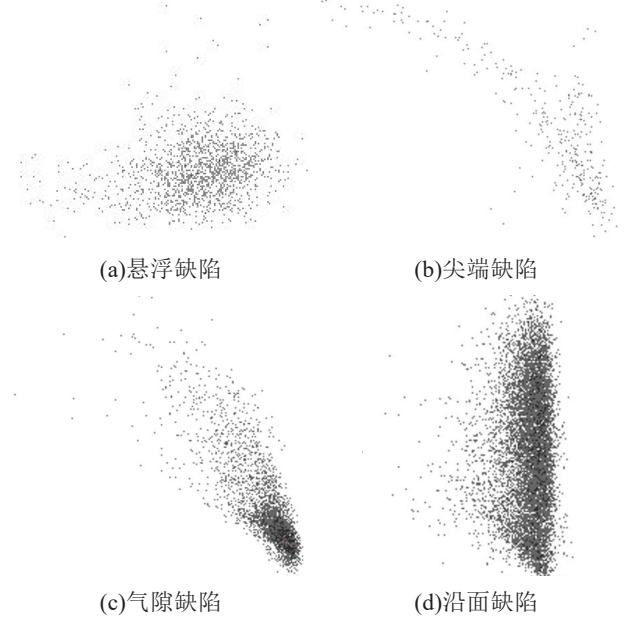


图9 T-F谱图典型训练样本

Fig.9 Training samples of T-F diagram

4.2 多源局放类型识别结果分析

本文使用MATLAB内深度学习、图像处理和计算机视觉模块基于AlexNet网络以实现Faster-RCNN算法。设置学习率参数为0.001,在GPU服务器平台上训练时长为5h。为了检测多源局部放电的识别准确率,本文测试样本为基于高频电流法采集到的共计129幅多源T-F谱图。

使用训练好的分类器逐一对多源谱图进行类型识别,针对多源谱图中可识别到的每一类标签信号,算法结果会输出其对应的边界框位置,包括矩形左上定点的坐标与矩形的长宽值。Faster-RCNN算法特征提取过程中,候选区域是长宽均不等的矩形,而算法会将所有候选区域均转化为长宽一致的矩形,因此无需担心在多源谱图中信号簇会因为坐标尺度变化产生的形变对特征提取的影响。根据边界框回归算法得出的3类多源T-F谱图类型部分识别结果如图10所示,具体识别准确率结果如表1所示,识别结果的平均准确率为72.1%。

将图10中目标识别出的信号区域与图9中单源局部放电谱图样本进行对比发现,不同类信号仍

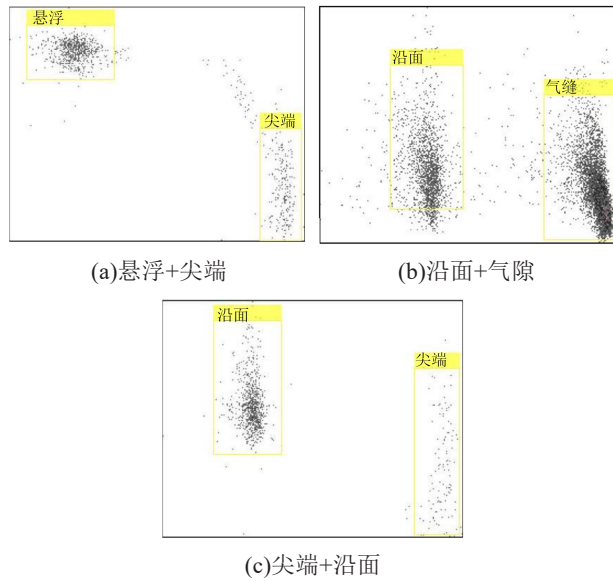


图 10 多源 T-F 谱图类型识别结果示例

Fig.10 Detection results of multi-source T-F diagrams

可保持一致的特征,例如图 10(a)中尖端等效频宽数值较高且分布范围较窄,但等效时长范围较宽,而悬浮缺陷放电等效频宽较低,在谱图中位置靠左,

聚成一簇,与尖端缺陷的“长条形”区别较为明显。这两类放电在 T-F 谱图中的特征与单源放电时特征是相一致的,证明了该种方法的可行性。

从表 1 可以看出,相较于其他 3 种缺陷,尖端缺陷的漏检率较高,在悬浮+尖端多源类型中尖端缺陷的漏检率为 30.2%,在尖端+沿面类型中漏检率为 24.4%,这可能是由于油中尖端放电并不是连续性放电,而呈间断性放电的特性导致的。在使用高频电流法进行数据采集过程中,当设定采样时间或采样脉冲数量一定时,悬浮缺陷或沿面缺陷放电频率明显较高,虽然放电幅值较低,但是在 PRPD 谱图及 T-F 谱图中,大量的脉冲点属于沿面放电或悬浮放电,尖端放电的信号点数量明显偏少,导致在 T-F 谱图中可能由于采样点数量较少而导致尖端放电点未能体现出尖端放电谱图特征。数量点较少可能导致 Faster-RCNN 算法在候选区域选择中无法判断出合适的包含尖端缺陷的特征候选区域,即使选择出合适的候选区域,也无法从候选区域中提取出有效的尖端 T-F 信号簇的 CNN 特征。

表 1 多源放电类型识别结果

Tab.1 Recognition results of multi-source PDs

序号	多源放电类型	测试准确/谱图数量/张	识别出单源放电类型谱图数量/个				准确率/%	平均准确率/%
			尖端	悬浮	气隙	沿面		
1	悬浮+尖端	29/43	30	36	0	5	67.4	
2	沿面+气隙	35/45	2	4	36	37	77.8	72.1
3	尖端+沿面	29/41	31	3	1	33	70.7	

注:准确率指多源谱图中两类放电均被准确识别的比率。

图 11 为一组无法识别出尖端放电的尖端+沿面放电 T-F 谱图与 PRPD 谱图。从图 11(b)可以看到,在正半周峰值处已经存在有少量而明显的尖端放电信号,证明此时两类缺陷均已开始放电。在 T-F 谱图中,尖端放电点分布在高效频宽范围处(图 11(a)右侧),而沿面放电信号则位于低等效频宽范围处(图 11(a)左侧),因此两类信号之间的界限较为清晰。但由于尖端缺陷放电点数量过少,导致 T-F 谱图中难以出现类似于图 10(a)或者图 10(b)中的信号特征,导致尖端缺陷出现漏检的情况。而对于气隙+沿面缺陷,两类信号的放电均较为连续密集,在谱图中均可以很好的看到两类信号的特征,因此气隙+沿面多源缺陷的识别准确率明显高于另外两组多源缺陷。此外,在 3 组多源放电识别中均存在数个悬浮放电与沿面放电识别错误的样本,而气隙缺陷的漏检率和错检率相较于其他缺陷较低,这是由于气隙缺陷放电点数量密集,谱图特征也较为明

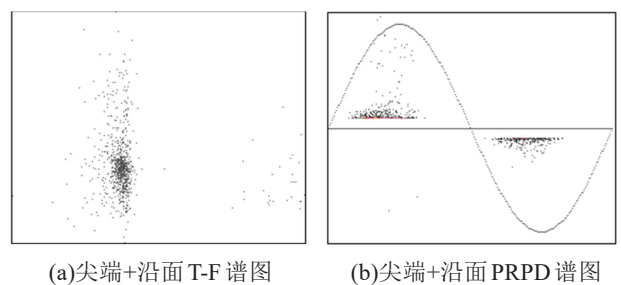


图 11 无法识别出尖端放电的多源谱图

Fig.11 Multiple source diagram where protrusion discharge cannot be detected

显,具有较好的可分辨性。除此之外,另一个影响多源局放谱图识别结果的因素是相同缺陷在单/多源放电条件下的放电特性也存在部分差异,由于训练集中的谱图均为单源放电时采集到的放电谱图,多源情况下会因为不同缺陷源间的影响而改变部分谱图的特征,因此在部分谱图中也难以识别出已被训练的缺陷放电类型。

5 结论

(1)本文搭建了35 kV变压器实验平台,设计了尖端、沿面、气隙、悬浮4种典型缺陷,并采用基于深度学习的Faster-RCNN算法从多源放电分离谱图中检测放电缺陷类型,通过从不同的候选区域中分别提取卷积神经网络特征来进行逐一识别,识别结果的平均准确率为72.1%。

(2)由于气隙缺陷放电点数量密集,谱图特征也较为明显,气隙缺陷的漏检率和错检率相较于其他缺陷较低,具有较好的可分辨性。气隙+沿面两类信号的放电均较为连续密集,在谱图中均可以很好的看到两类信号的特征,因此气隙+沿面多源缺陷的识别准确率明显高于另外两组多源缺陷。

(3)尖端缺陷的漏检率较高,相较于其他类型放电,尖端缺陷一方面呈现间断性放电的特点,另一方面PDIV较高,两个原因导致在T-F谱图中数量较少的尖端放电点未能体现出尖端放电谱图特征,也可能导致算法在候选区域选择中无法判断出合适的包含尖端缺陷的特征候选区域,造成漏检率较高。

本文在缺陷设计上,仅采用了尺寸较为单一的尖端、沿面、悬浮、气隙4种缺陷,由此导致训练样本集的涵盖面较窄,样本种类也一定程度受限,这也是影响实验结果准确率的重要因素。在后续研究中,应着重增强缺陷的尺度以及尺度之间的配合关系的多样性,从而建立更为完善的训练样本集,以实现更好的识别效果。

参考文献:

- [1] 范路,陆云才,陶风波,等.人工智能在局部放电检测中的应用(二):模式识别与状态评估[J].绝缘材料,2021,54(7):10-24.
- [2] BO Z Q, WELLER G, LOMAS T. A new technique for transformer protection based on transient detection[J]. IEEE Transactions on Power Delivery,2000,15(3):870-875.
- [3] MONTANARI G C, CAVALLINI A. Partial discharge diagnostics: From apparatus monitoring to smart grid assessment[J]. IEEE Electrical Insulation Magazine,2013,29(3):8-17.
- [4] 刘嘉林,董明,安珊,等.电力变压器局部放电带电检测及定位技术综述[J].绝缘材料,2015,48(8):1-7.
- [5] LAI K X, PHUNG B T, BLACKBURN T R. Application of data mining on partial discharge part I: Predictive modelling classification[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2010,17(3):846-854.
- [6] MA H, CHAN J C, SAHA T K, et al. Pattern recognition techniques and their applications for automatic classification of artificial partial discharge sources[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2013,20(2):468-478.
- [7] WANG K, LI J Z, ZHANG S Q, et al. A new image-oriented feature extraction method for partial discharges[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2015,22(2):1015-1024.
- [8] WOON W L, EL-HAG A, HARBAJI M. Machine learning techniques for robust classification of partial discharges in oil-paper insulation systems[J]. IET Science Measurement & Technology,2016,10(3):221-227.
- [9] HARBAJI M, SHABAN K, EL-HAG A. Classification of common partial discharge types in oil-paper insulation system using acoustic signals[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2015,22(3):1674-1683.
- [10] WU M, CAO H, CAO J N, et al. An overview of state-of-the-art partial discharge analysis techniques for condition monitoring [J]. IEEE Electrical Insulation Magazine,2015,31(6):22-35.
- [11] KREUGER F H, GULSKI E. Classification of partial discharges [J]. IEEE Transactions on Electrical Insulation,1993,28(6):917-931.
- [12] BRTNIKAS R. Partial discharges. Their mechanism, detection and measurement[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2002,9(5):763-808.
- [13] DANIKAS M G, GAO N, ARO M. Neural networks and their role in partial discharge recognition in gas insulated switchgear and transformers: A short review[J]. Journal of Electrical Engineering,2003,54(3-4):107-112.
- [14] HAO L, LEWIN P L. Partial discharge source discrimination using a support vector machine[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2010,17(1):189-197.
- [15] 程养春,张振亮.基于随机森林的变压器多源局部放电诊断[J].中国电机工程学报,2018,38(17):5246-5256,5322.
- [16] 刘诣,谢雄杰,罗晓庆,等.计及信号传输特性的变压器套管末屏高频局部放电信号时频分析方法[J].高电压技术,2020,46(2):594-602.
- [17] 王哲,蔡惟铮,陈学允,等.基于小波分析的高压变压器局部放电在线监测[J].电力系统自动化,1998(4):19-23.
- [18] 王永强,杨东星,何杰,等.基于小波包变换的干式变压器局部放电超声信号的模式识别[J].绝缘材料,2015,48(2):61-67.
- [19] CONTIN A, CAVALLINI A, MONTANARI G C, et al. Digital detection and fuzzy classification of partial discharge signals[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2002,9(3):335-348.
- [20] CAVALLINI A, CONTIN A, MONTANARI G C, et al. Advanced PD inference in on-field measurements. Part I: Noise rejection[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2003,10(2):216-224.
- [21] 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.
- [22] 王彩雄,唐志国,常文治,等.一种多源局部放电信号分离方法[J].中国电机工程学报,2013,33(13):212-219.
- [23] 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.
- [24] LUO L G, HAN B, CHEN J D, et al. Partial discharge detection and recognition in random matrix theory paradigm[J]. IEEE Ac-

- cess,2016(5):8205-8213.
- [25] 朱明晓,薛建议,邵先军,等.GIS局部放电特高频信号波形分析与特征参量提取[J].高电压技术,2017,43(12):4079-4087.
- [26] WANG Y B, CHANG D G, QIN S R, et al. Separating multi-source partial discharge signals using linear prediction analysis and isolation forest algorithm[J]. IEEE Transactions on Instrumentation and Measurement,2020,69(6):2734-2742.
- [27] 熊凯龙,范方亮,汪保玉,等.基于一种新的级联分类器的目标检测系统[J].现代电子技术,2020,43(1):48-52.
- [28] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on on Computer Vision and Pattern Recognition. Columbus, USA:IEEE,2014.
- [29] UIJLINGS J R R, VAN DE SANDE K E A, GEVERS T, et al. Selective search for object recognition[J]. International Journal of Computer Vision,2013,104(2):154-171.
- [30] FELZENSZWALB P F, HUTTENLOCHER D P. Efficient graph-based image segmentation[J]. International Journal of Computer Vision,2004,59(2):167-181.

收稿日期:2022-03-30 修回日期:2022-05-26

作者简介:王彦博(1992-),男(汉族),山西太原人,工程师,博士,主要从事电力设备绝缘状态诊断的研究。

版 权 声 明

凡是在本刊上刊登、并由本刊支付稿酬的作品,均视为该作者同意将作品的全部权利转让给本刊,且允许本刊以任何形式(包括但不限于纸质出版、网络出版、光盘等)使用、编辑、修改;本刊有权对作品再次使用,并可授权给第三方而无需另行支付稿酬。未经本刊书面许可,任何单位和个人都不得以任何形式(包括但不限于通过纸媒质、网络、光盘等介质转载、张贴、结集、出版)使用该作品。

《绝缘材料》编辑部