

基于 WOA-BP 和 D-S 证据的高压电机局部放电模式识别方法

王 卓, 郑 祥, 王仁锋, 杨景杰, 许智海
(大连交通大学 自动化与电气工程学院, 辽宁 大连 116028)

摘 要: 针对单一信号源特征无法准确识别局部放电(PD)类型的问题,提出了一种基于改进 BP 神经网络(BPNN)和 D-S 证据的高压电机 PD 模式识别方法。对不同类型 PD 的脉冲相位信息、特高频信号和超声波信号进行采集,提取不同信号的特征向参数,再分别构造基于鲸鱼优化算法(WOA)改进的 BPNN 识别模型对 PD 类型识别,将 3 个识别模型的识别结果作为证据体采用 D-S 证据组合规则进行融合,最后对融合结果进行决策。研究表明:基于 3 类单一信号源独立识别各类 PD 类型的准确度存在差异性和不确定性,识别率分别为 83.3%、90.0%、83.3%,但 3 类信号源的共性和差异性可以融合互补,有各自优势,可以解决故障诊断中的不确定性问题。在此基础上,基于 D-S 证据融合的高压电机 PD 类型的整体识别率提升至 96.6%,实现了 3 种信号源的优势互补,与单一模型对比,所提方法可以稳定、准确地识别 PD 模式,具有更高准确率和可靠性,验证了所提方法的有效性与正确性。

关键词: 高压电机; 局部放电; 模式识别; D-S 证据理论; 信息融合

中图分类号: TM307 **文献标志码:** A **文章编号:** 1673-6540(2022)11-0040-08

doi: 10.12177/emca.2022.123

Partial Discharge Pattern Recognition Method for High Voltage Motor Based on WOA-BP and D-S Evidence

WANG Zhuo, ZHENG Xiang, WANG Renfeng, YANG Jingjie, XU Zhihai

(School of Automation and Electrical Engineering, Dalian Jiaotong University, Dalian 116028, China)

Abstract: The single signal source feature cannot accurately identify the type of partial discharge. In order to solve this problem, a partial discharge pattern recognition method for high-voltage motors based on improved BP neural network and D-S evidence is proposed. The pulse phase information, ultra-high frequency signal and ultrasonic signal of different types of partial discharges are collected, and the eigen parameters of different signals are extracted. Then, the improved back propagation neural network (BPNN) recognition model based on whale optimization algorithm (WOA) is constructed to identify the partial discharge types, respectively. The recognition results of each recognition model are used as the evidence body to be fused using the D-S evidence combination rule. Finally, the fusion result is decided. The research results show that there are differences and uncertainties in the accuracy of independently identifying various types of partial discharges based on three types of single signal sources, and the recognition rates are 83.3%, 90.0%, and 83.3%, respectively. However, the commonality and difference of the three types of signal sources can be integrated and complementary, and have their own advantages, which can solve the problem of uncertainty in fault diagnosis. On this basis, the overall recognition rate of high-voltage motor partial discharge types based on D-S evidence fusion has increased to 96.6%, and three signal sources have been realized. Compared with a single model, the proposed method can identify partial discharge patterns stably and accurately, and

收稿日期: 2022-07-18; 收到修改稿日期: 2022-09-22

作者简介: 王 卓(1998—),男,硕士研究生,研究方向为高电压检测技术。

郑 祥(1979—),男,博士,副教授,研究方向为高电压检测技术。

has higher accuracy and reliability, which verifies the effectiveness and correctness of the proposed method.

Key words: high voltage motor; partial discharge (PD); pattern recognition; D-S evidence theory; information fusion

0 引言

高压电机在制造、运输和运行过程中会产生各种微小的缺陷留下隐患最终出现绝缘缺陷,如果不及时处理,在运行过程中绝缘缺陷会由弱变强,逐步发展成绝缘故障最后击穿。由于高压电机在发生绝缘故障的前期表现形式为局部放电(PD),对PD信号检测可以判断高压电机的绝缘缺陷类型,有利于制定针对性维护措施,对于高压电机的安全稳定运行具有重要的意义^[1-3]。

目前,在PD模式识别领域,国内外学者开展了大量的相关研究工作,并取得了显著的成果。现有方法为基于脉冲相位信息的PD模式识别,如文献[4]对发电机在线测量获得相位分辨局部放电(PRPD)谱图,提取特征量输入到神经网络以此识别PD类型,准确度在88.0%~94.8%之间。文献[5]基于PRPD谱图提取特征输入到深度信念网络(DBN)中用于PD类型的识别,识别准确率约为90%。文献[6]将PD信号的放电量、放电次数和相位参数作为放电特征输入到反向传播神经网络(BPNN)进行训练,识别准确率均在92%以上。此外,还有基于特高频信号或超声波信号的PD模式识别方法。如文献[7]对PD特高频信号能量分布图的分形特征进行提取与降维处理,利用支持向量机(SVM)对PD类型进行识别,优于传统识别方法。文献[8]对不同PD模型超声波信号进行检测,提取波形特征分别输入到概率神经网络(PNN)和SVM算法中识别并比较分析,识别率在85%以上。文献[9]提取了5种PD超声波信号并提取特征参数,采用多尺度分析和神经网络相结合的方法识别PD类型。

上述方法可以较好地地区分不同PD类型,总体识别率均在85%以上,但均采用单一信号源进行PD模式识别,其结果存在不确定性。通过分析发现,造成上述问题的原因是采用单一信号源提取的特征信息进行PD模式识别,不能最大限度地利用PD信号的信息,影响模式识别的准确率。当出现单一数据源不同PD类型的特征参数值非常接近的情况时,引入另外的一种数据源分

析可以较好地解决这个问题。如文献[10-11]采用D-S证据理论融合了两种不同PD信号源的识别结果,实现了两种信号特征识别的优势互补,具有更高的准确率。但融合方法采用的是两种信号源融合的结果,当这两种数据源对同一PD故障的识别结果相对立时,同样较难判断哪个结果是正确的,且目前对于高压电机的PD信息融合领域的研究还鲜有报道。

综上所述,本文在改变用传统单一信号源进行PD模式识别基础上,综合高压电机PD的脉冲相位信号、特高频信号和超声信号等3种信号源,提出一种基于鲸鱼优化算法(WOA)改进BPNN和D-S证据的高压电机PD模式识别方法,分别提取脉冲信号的PRPD谱图统计特征、超声波信号和特高频信号的波形特征,采用WOA-BP进行PD类型的初步识别,将基于3种信号源的识别结果通过D-S证据融合,最后进行决策得出结果,进一步提升PD识别的准确率。

1 PD数据的采集与特征提取

1.1 PD数据采集

本文采用项目合作公司的PD试验数据进行验证,试验中设计的3种类型放电模型分别是悬浮放电、气隙放电和微粒放电。其中微粒放电模型和信号采集电路如图1和图2所示。




图1 电机放电模型

采集电路的主要结构有高压变压器、保护电阻、耦合电容和采集系统。脉冲相位信号连续采集50个周期作为一个信号,将检测到的信号传输到上位机转换成PRPD三维图。特高频和超声波的PD信号检测中,特高频信号的采样频率为2 GHz,超声波信号的采样频率为10 MHz。试验中各类型放电均采集100组样本信号,其中采集到的悬浮放电3类信号源PD数据如图3所示。




图2 信号采集电路




图3 三类信号源 PD 数据

1.2 特征提取

(1) 脉冲相位特征提取。为了更好地反映 PD 的相位与脉冲信息,本文采用文献[12]的特征提取方法,分别提取相位-放电均值图谱、相位-放电最值图谱与相位-放电次数图谱的特征构成特征集作为识别输入,具体特征参数如表 1 所示。

表 1 脉冲相位特征参数

图谱类型	数量	具体特征
相位-放电均值	7	陡峭度、偏斜度、均值、方差、互相关系数、相位不对称度、中位数
相位-放电最值	7	陡峭度、偏斜度、方差、互相关系数、相位不对称度、中位数、放电强度因数
相位-放电次数	1	放电次数比

(2) 特高频与超声波信号特征提取。为表征不同 PD 类型的特高频与超声波信号特点,本文分别提取信号的时域特征、频域特征和小波特征作为 PD 模式识别的输入,具体特征参数如表 2 所示。

表 2 特高频与超声波信号特征参数

特征类别	数量	具体特征
时域特征	8	方差、峭度、偏度、均方根、波形因子、峰值因子、脉冲因子、裕度因子
频域特征	4	平均频率、重心频率、频率均方根、频率标准差
小波特征	8	8 个子带的小波能量

2 基于 WOA-BP 算法的高压电机典型缺陷的初步识别

2.1 BPNN

BPNN 是 PD 模式识别领域中广泛应用的一类智能算法,可对基于 PD 特征量对放电数据进行训练与识别,其训练过程包括正向和反向传播,网络结构如图 4 所示^[13],由输入层、隐含层和输出层组成,其中输入层节点数 n 由特征维度决定,隐含层节点数 m 根据具体情况而定,输出节点数 l 个由 PD 类型数决定,本文为 3。




图4 BPNN 结构

BPNN 的学习过程如下:

- (1) 初始化网络结构,学习参数以及权值与阈值。
- (2) 输入提取的 PD 特征。
- (3) 前向传播计算输出层的每个节点值 z_i :

$$z_i = f[\sum_{i=1}^n w_{io} f(\sum_{i=1}^n w_{ih} x_i + B_{ih}) + B_{io}] \quad (1)$$

式中: w 为权重; B 为阈值。

- (4) 反向传播将预测值与实际值比较计算出误差,不断训练修改权值优化网络的性能,其误差计算式为

$$E_p = \frac{1}{n} \sum_{i=1}^n |(t_{pi} - z_{pi})| \quad (2)$$

式中: t_{pi} 为第 i 个节点的实际值; z_{pi} 为第 i 个节点的预测值,根据梯度下降法的调整式为

$$\begin{cases} w_i = -\eta \frac{\partial E}{\partial w_{io}} \\ B_i = -\eta \frac{\partial E}{\partial B_{io}} \end{cases} \quad (3)$$

式中: η 为学习率。

对 BPNN 分析可以发现, 权值与阈值的选取很大程度上会影响 PD 类型的识别效果, 若选取不当则会导致过拟合或欠拟合问题。原算法中采用梯度下降法进行 BPNN 的误差反向传播易陷入局部最小值, 且对权值与阈值的全局搜索能力有限。因此, 需要对 BPNN 的权值与阈值调节过程进行改进。

2.2 WOA

WOA 是模拟座头鲸围捕猎物行为的一种寻优新算法, 与传统的粒子群算法、遗传算法相比具有更强的寻优能力^[14-15], 其寻优过程主要为以下两个阶段。

2.2.1 气泡网攻击猎物

WOA 根据座头鲸攻击猎物的行为模拟了收缩包围圈与螺旋更新位置两种方式。

(1) 收缩包围圈。鲸鱼在包围猎物时需要先确定猎物的位置, WOA 算法假定当前个体适应度值最大的位置为目标位置, 其他鲸鱼会向目标位置收缩包围, 位置计算式为

$$X_i(t+1) = X^*(t) - AM \quad (4)$$

$$M = |EX^*(t) - X_i(t)| \quad (5)$$

式中: X 为整个鲸鱼集体, $X = (X_1, X_2, \dots, X_n)$; M 为收缩包围圈过程中鲸鱼个体到目标位置的距离; t 为当前迭代次数; $X_i(t)$ 为鲸鱼个体位置向量, $X^*(t)$ 为目标位置向量; A 为系数向量; E 为系数变量。

系数向量 A 、系数变量 E 的表达式为

$$A = 2ar_1 - a \quad (6)$$

$$E = 2r_2 \quad (7)$$

式中: r_1 与 r_2 均为 $[0, 1]$ 之间的常数; a 为收敛向量, $a = [a \ a \ \dots \ a]$, a 为收敛因子, 是随迭代从 2 线性递减到 0 的常数。

收敛因子 a 的表达式为

$$a = 2 - \frac{2t}{t_{\max}} \quad (8)$$

式中: $t_{\max}$ 为最大迭代次数。

收缩包围圈通过 a 的线性递减, 使包围圈逐

渐缩小, 鲸鱼群逐渐接近目标位置, 达到包围猎物的目的。

(2) 螺旋更新位置。螺旋更新位置利用螺旋线公式模拟鲸鱼的狩猎进行位置更新, 主要目的是通过对位置区域的搜索增大搜索范围, 表达式为

$$X_i(t+1) = M'e^{hl} \cos(2\pi l) + X^*(t) \quad (9)$$

$$M' = |X^*(t) - X(t)| \quad (10)$$

式中: M' 为螺旋更新过程中鲸鱼个体到目标位置的距离; h 为螺旋线常数, 可以改变螺旋线的形状; l 为 $[-1, 1]$ 之间的常数。

鲸鱼在攻击猎物过程中是在收缩包围圈的同时螺旋上升, 为了模拟这种行为通过概率参数 p 在两种行为之间选择, 表达式为

$$X(t+1) = \begin{cases} X^*(t) - AM, & p < 0.5 \\ M'e^{hl} \cos(2\pi l) + X^*(t), & p \geq 0.5 \end{cases} \quad (11)$$

2.2.2 搜索猎物

为了增强全局寻优的能力, 鲸鱼群会在大范围内随机游走来保持种群的多样性。WOA 算法利用 $|A|$ 的变化模拟这种行为, 当 $|A| > 1$ 时强制部分非最优位置的鲸鱼个体进行位置更新, 表达式为

$$X(t+1) = X_{\text{rand}}(t) - AM \quad (12)$$

$$M = |EX_{\text{rand}}(t) - X(t)| \quad (13)$$

式中: $X_{\text{rand}}(t)$ 为鲸鱼群中随机一个鲸鱼的位置。

2.3 WOA-BP

为提升 BPNN 对 PD 模式识别的效果, 改进原本的梯度下降算法修正权值与阈值, 采用 WOA 算法对 BPNN 算法的权值与阈值进行搜索迭代, 具体过程如下:

步骤 1, 对数据集进行划分, 50% 为训练集, 40% 为验证集, 10% 为测试集。

步骤 2, 设置鲸鱼个数 N , 最大迭代次数 T , 将 BPNN 的权值与阈值作为鲸鱼个体进行初始化。

步骤 3, 将训练集和权值与阈值输入到 BPNN 中进行训练, 采用验证集测试, 利用均方根误差作为适应度函数计算适应度值。

步骤 4, 比较确定当前的最优值, 通过 WOA 算法的位置更新公式进行位置更新。

步骤 5, 判断是否到达最大迭代次数, 若到达则停止输出结果, 否则重复步骤 3~步骤 5。

WOA-BP 算法的流程图如图 5 所示。




图5 WOA-BP 算法流程图

2.4 高压电机典型 PD 缺陷的初步识别

2.4.1 脉冲相位信号识别

对脉冲相位信号的识别,BPNN 的输入层节点为 15,隐藏层节点设为 30,输出层节点为 3,学习步长为 0.001,正则化系数 0.01,WOA 算法的种群数目设置为 30,训练集的最大训练次数为 50 次。将训练集与验证集输入 WOA-BP 算法中进行迭代确定最优权值 ω 与阈值 B 。

为了验证 WOA 算法优化的有效性,将 WOA-BP 与 BP 的训练迭代过程进行比较,迭代曲线如图 6 所示。




图6 脉冲相位信号识别迭代曲线

从图 6 的 WOA-BP 与 BP 迭代曲线可以发现,随着迭代次数的增加,WOA-BP 的均方根误差值下降速度比 BP 的速度快,且最终平稳时 WOA-BP 的均方根误差值为 0.69,BP 为 0.75。WOA-BP 的训练效果更好,说明采用 WOA 算法优化 BP 算法的参数取得了良好的效果。

将经 WOA-BP 训练好的最优权值 ω 和阈值 B 与测试集输入到 BPNN 中进行 PD 类型识别,结果如图 7 所示。

预测标签	悬浮	8 26.7%	0 0%	0 0%	100% 0%
	气隙	0 0%	7 23.3%	0 0%	100% 0%
	微粒	2 6.7%	3 10.0%	10 33.3%	66.7% 33.3%
		80.0% 20.0%	70.0% 30.0%	100% 0%	83.3% 16.7%
		悬浮	气隙	微粒	真实标签

图7 脉冲相位信号识别结果

从图 7 可见,基于脉冲相位信号的 PD 类型识别总体识别率为 83.3%,且微粒放电的识别率为 100%,而气隙放电的识别率相对就很低了,仅有 70%。说明脉冲相位信号对于微粒放电的辨识度较高。

2.4.2 特高频信号

对于特高频信号的识别,BPNN 的输入层节点为 20,隐藏层节点设为 40,输出层节点为 3,分别对应 3 个缺陷类别,学习步长为 0.001,正则化系数 0.01,WOA 算法的种群数目设置为 30,训练集的最大训练次数为 50 次。将 WOA-BP 与 BP 的训练迭代过程进行比较,如图 8 所示。




图8 特高频信号识别迭代曲线

从图 8 的 WOA-BP 与 BP 迭代曲线可以看出,迭代的前期,BP 的迭代速度优于 WOA-BP 的迭代速度,但随着迭代次数的增加,WOA-BP 的迭代优化效果更加稳定,最终平稳时 WOA-BP 的均方根误差值为 0.67,BP 为 0.73,说明采用 WOA 算法优化 BP 算法参数更加稳定,搜索性能更好。

将经 WOA-BP 训练好的最优权值 ω 和阈值 B 与测试集输入到 BPNN 中进行 PD 类型识别,结果如图 9 所示。

预测标签	悬浮	10 33.3%	1 3.3%	1 3.3%	83.3% 16.7%
	气隙	0 0%	8 26.7%	0 0%	100% 0%
	微粒	0 0%	1 3.3%	9 30.0%	90.0% 10.0%
		100% 0%	80.0% 20.0%	90.0% 10.0%	90.0% 10.0%
		悬浮	气隙	微粒	
		真实标签			

图9 特高频信号识别结果

从图9可见,基于特高频信号的PD类型识别总体识别率为90%,且悬浮放电的识别率为100%,而气隙放电的识别率同样最低,仅有80%。说明特高频信号对于悬浮放电的辨识度很高。针对前两种信号的识别分别对微粒放电与悬浮放电有较高的辨识度,将识别结果结合可以一定程度地提高这两种放电模式的识别效果。

2.4.3 超声波

对超声波信号的识别,BPNN的输入层节点为20,隐藏层节点设为40,输出层节点为3,学习步长为0.001,正则化系数0.01,WOA算法的种群数目设置为30,训练集的最大训练次数为50次。将WOA-BP与BP的训练迭代过程进行比较,如图10所示。




图10 超声波信号识别迭代曲线

经过迭代,最终平稳时WOA-BP的均方根误差值为0.71,BP为0.83。同样,采用WOA算法优化BP算法的参数取得了较好的效果。

将经WOA-BP训练好的最优权值 ω 和阈值 B 与测试集输入到BPNN中进行PD类型识别,结果如图11所示。

从图11可见,基于特高频信号的PD类型识别总体识别率为83.3%,且气隙放电与微粒放电的识别率均为90%,悬浮放电的识别率为70%。从超声波信号的识别结果判断,对不同类型缺陷

预测标签	悬浮	7 23.3%	1 3.3%	1 3.3%	77.8% 22.2%
	气隙	3 10.0%	9 30.0%	0 0%	75.0% 25.0%
	微粒	0 0%	0 0%	9 30.0%	100% 0%
		70.0% 30.0%	90.0% 10.0%	90.0% 10.0%	83.3% 16.7%
		悬浮	气隙	微粒	
		真实标签			

图11 超声波信号识别结果

的识别率均没有到达100%,但对于气隙放电的识别准确率比前面两种高,说明超声波信号对于气隙放电的辨识度较高,可以弥补前两种信号气隙放电辨识度不高的缺陷。3种识别结果的结合可以提高PD模式的整体识别效果。

3 基于D-S证据的PD多源信息融合识别

3.1 D-S证据理论

D-S证据是多源信息融合的一种有效手段,可以将不同信息源进行融合计算,得到更加准确的结果^[16-17]。具体融合规则如下:

(1) 建立识别框架 Θ 。对于模式识别融合,识别框架为所有的识别对象与不确定性,本文的识别框架为悬浮放电 A_1 、气隙放电 A_2 、微粒放电 A_3 以及不确定性 θ ,即 $\Theta = \{A_1, A_2, A_3, \theta\}$ 。

(2) 设置基础概率分配BPA。BPA代表不同框架中不同类型的基本可信度,本文计算方法为

$$m_i(A_j) = \alpha_{ij} \cdot \mu_i \quad (14)$$

$$m_i(\theta) = 1 - \sum_{j=1}^3 m_i(A_j) \quad (15)$$

式中: α_{ij} 为可靠系数, $\alpha_{ij} \in [0,1]$,是WOA-BP算法的识别率; $m(\cdot)$ 为基本可信数,其反映的是对框架 Θ 的可信度大小; $m_i(A_j)$ 为第 i 个证据不确定性的BPA值; μ_i 为第 i 个证据的隶属度。

(3) Dempster证据融合。Dempster是D-S证据的融合式,对于3个信息源的合成计算式如下:

$$m_{1,2,3}(A_j) = (m_1 \oplus m_2 \oplus m_3)(A_j) = \frac{1}{K} \sum_{A_1 \cap A_2 \cap A_3 = A_j} m_1(A_1) \cdot m_2(A_2) \cdot m_3(A_3) \quad (16)$$

$$K = 1 - \sum_{A_1 \cap A_2 \cap A_3 = \emptyset} m_1(A_1) \cdot m_2(A_2) \cdot m_3(A_3) \quad (17)$$

式中: $\oplus$ 为异或运算; K 为归一化因子; $m_{1,2,3}(A_j)$ 为通过式(16)、式(17)合成的BPA,即3个信息源的共同识别结果。

(4) 决策。融合结束后,选择融合BPA的最大值PD类型作为最后的识别结果输出。

3.2 识别

将前文基于脉冲相位信号、特高频信号和超声波信号的识别结果作为D-S证据融合的输出,计算各证据体的基本可信度,利用Dempster融合公式计算共同识别结果,最后决策规则判断PD的类型。气隙放电类型的其中两个识别结果如表3和表4所示。

表3 融合结果1

局放类型	脉冲	特高频	超声波	DS
悬浮放电	0.002 6	0.042 9	0.093 4	0.004 4
气隙放电	0.847 4	0.794 5	0.754 9	0.991 3
微粒放电	6.99×10^{-10}	0.012 6	0.001 7	3.79×10^{-4}
不确定性	0.150 0	0.150 0	0.150 0	0.003 9

表4 融合结果2

局放类型	脉冲	特高频	超声波	DS
悬浮放电	0.066 5	0.005 4	0.089 1	0.030 0
气隙放电	0.780 3	0.005 0	0.743 9	0.807 2
微粒放电	0.003 2	0.839 6	0.016 9	0.141 1
不确定性	0.150 0	0.150 0	0.150 0	0.021 7

从表3中可以看出,3类信号源识别结果一致,均识别为气隙放电类型,但BPA值分别为0.847 4、0.794 5和0.754 9,将3类识别结果进行融合后,其BPA值变为0.991 3,可信度更大,使结果更加具有确定性,说明D-S融合识别具有较强的抗干扰性,可以使识别效果更好。

从表4中可以看出,3类信号源的识别结果不一致,其中特高频信号识别为微粒放电的概率更高,而脉冲相位和超声波信号识别为气隙放电的概率更高。3类信号源经D-S融合后判断为气隙放电的概率更高,与真实结果一致。可以发现通过D-S融合输出使3类信号源原本冲突的结果变得一致,从而使判决更具有确定性和正确性。由此可见,当3类信号源结果存在互斥时,多信息融合识别方法能有效地提高判决结果的确定度和可靠度。

所有测试集的识别结果如图12所示。从图12可见,基于D-S证据融合的PD类型识别总体识别率为96.7%,悬浮放电与微粒放电的识别率为100%,气隙放电的识别率为90%。比单一信号源的识别结果明显提升。说明了将不同信号源的识别结果融合可以弥补各自的不足,提高PD模式的整体识别效果,证明了D-S融合的有效性。

测试集 真实标签	悬浮	气隙	微粒	
	10 33.3%	0 0%	0 0%	100% 0%
	0 0%	9 30.0%	0 0%	100% 0%
	0 0%	1 3.3%	10 33.3%	90.9% 9.1%
	100% 0%	90.0% 10.0%	100% 0%	96.7% 3.3%
	悬浮	气隙	微粒	
	真实标签			

图12 识别结果

4 结 语

本文基于PD的脉冲相位信号、特高频信号、和超声波信号采用WOA算法改进的BPNN进行初步识别,再将基于3种信号源的识别结果采用D-S证据融合,对高压电机PD类型进行融合识别,得到了以下结论:

- (1) 采用WOA-BP的PD识别方法,与原始BPNN相比,其迭代速度与识别结果均有提升。
- (2) 将脉冲相位信号、特高频信号和超声波信号等3种PD信号的识别结果作为输入采用D-S证据融合进行识别,不仅能降低识别不确定性,且可以提高整体识别准确率。
- (3) 将不同信号源的识别结果经D-S证据融合后可得到比单一信号源更加突出的识别结果。

【参考文献】

[1] JIANG J, ZHANG B, LI Z, et al. Partial discharge features for power electronic transformers under high-frequency pulse voltage [J]. IEEE Transactions on Plasma Science, 2021, 49(2): 845.

[2] LEE S B, NAEINI A, JAYARAM S, et al. Surge test-based identification of stator insulation component with partial discharge activity for low voltage AC motors [J]. IEEE Transactions on Industry Applications, 2020, 56(3): 2541.

- [3] CHENG J, XU Y, DING D, et al. Investigation of the UHF partial discharge detection characteristics of a novel bushing tap sensor for transformers [J]. IEEE Transactions on Power Delivery, 2021, 36(5): 2748.
- [4] ARAÚJO R C F, DE OLIVEIRA R M S, BARROS F J B. Automatic PRPD image recognition of multiple simultaneous partial discharge sources in on-line hydro-generator stator bars [J]. Energies, 2022, 15(1): 1.
- [5] KARIMI M, MAJIDI M, MIRSAEEDI H, et al. A novel application of deep belief networks in learning partial discharge patterns for classifying corona, surface, and internal discharges [J]. IEEE Transactions on Industrial Electronics, 2020, 67(4): 3277.
- [6] 杨旗, 曾华荣, 黄欢, 等. 基于 BP 神经网络的输电线路隐患预放电识别研究 [J]. 电力大数据, 2020, 23(3): 47.
- [7] 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.
- [8] 韩世杰, 吕泽钦, 隋浩冉, 等. 基于 EFPI 传感器的 GIS 局部放电模式识别研究 [J]. 电力工程技术, 2022, 41(1): 149.
- [9] WANG Y, ZHANG X, LI Y, et al. Multi-scale analysis and pattern recognition of ultrasonic signals of PD in a liquid/solid composite of an oil-filled terminal [J]. Energies, 2020, 13: 366.
- [10] 黄亮, 唐炬, 凌超, 等. 基于多特征信息融合技术的局部放电模式识别研究 [J]. 高电压技术, 2015, 41(3): 947.
- [11] 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/OL]. 高电压技术. doi: 10. 13336/j. 1003-6520. hve. 20211249.
- [12] 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.
- [13] YAO Y, TANG J, PAN C, et al. Optimized extraction of PD fingerprints for HVDC XLPE cable considering voltage influence [J]. International Journal of Electrical Power & Energy Systems, 2021, 127: 106644.
- [14] XIONG X, HU X, GUO H. A hybrid optimized grey seasonal variation index model improved by whale optimization algorithm for forecasting the residential electricity consumption [J]. Energy, 2021 (234): 121127.
- [15] YANG W, XIA K, FAN S, et al. A multi-strategy whale optimization algorithm and its application [J/OL]. Engineering Applications of Artificial Intelligence, 2022, 108. <https://doi.org/10.1016/j.engappai.2021.104558>.
- [16] XU Y, LI Y, WANG Y, et al. Integrated decision-making method for power transformer fault diagnosis via rough set and DS evidence theories [J]. IET Generation Transmission & Distribution, 2020, 14(24): 5774.
- [17] PAN Y, ZHANG L, LI Z W, et al. Improved fuzzy Bayesian network-based risk analysis with interval-valued fuzzy sets and D-S evidence theory [J]. IEEE Transactions on Fuzzy Systems, 2020, 28(9): 2063.

[主要栏目]

- | | | |
|--------------|-----------|-------------|
| · 控制与应用技术 | · 研究与设计 | · 故障诊断与保护 |
| · 新能源发电与局域电网 | · 新能源汽车技术 | · 发电机组及其控制 |
| · 测试技术与测控系统 | · 材料与工艺 | · 电机生产及质量管理 |
| · 电力电子变流器技术 | · 智能制造 | · 节能应用 |
| · 实用技术成果 | | |