

基于D-S证据组合规则的双模型融合局部放电模式识别方法

徐敏锐¹, 李云², 卢树峰¹, 窦晓波³, 陈刚¹, 郭家豪¹

(1. 国网江苏省电力有限公司 营销服务中心, 江苏 南京 210096;

2. 东南大学 网络空间安全学院, 江苏 南京 211189;

3. 东南大学 电气工程学院, 江苏 南京 210096)

摘要:针对传统的局部放电模式识别存在的特征提取单一、识别准确率低等缺点,提出了一种基于D-S证据组合规则的双模型融合局部放电模式识别方法。根据基于相位信息的局部放电(PRPD)谱图的统计数据特征和图像特征的特点,分别建立了反向传播(BP)识别模型和卷积神经网络(CNN)识别模型。根据2个识别模型的识别结果,提出了基于信息熵改进的D-S证据组合规则以解决常见的悖论问题,基于此建立了判定模型,更好地融合了2个识别模型的输出结果,实现了2种特征识别的优势互补。根据实际数据测试,与单一模型对比,所提方法可以稳定、准确地识别局部放电模式。

关键词:局部放电;特征提取;机器学习;模式识别;D-S证据组合

中图分类号:TM 507

文献标志码:A

DOI:10.16081/j.epae.202106002

0 引言

电力设备(如气体绝缘金属封闭开关设备、电力电缆等)在长期运行过程中,其绝缘性能会逐步恶化,该过程中会发生不同模式的局部放电(PD(Partial Discharge))^[1],通过检测电力设备的局部放电模式可以判断电力设备的运行状态,这对于电力设备的运行维护具有重要的作用。

目前,已有方法通常是基于相位信息的局部放电PRPD(Phase Resolved Partial Discharge)谱图进行局部放电模式的识别。PRPD谱图是局部放电数据的放电相位、放电幅值、放电次数的二维图像体现,可以直观反映局部放电情况。通过脉冲特征法、矩特征法、小波分析法等提取反映局部放电模式的数据特征^[2],采用机器学习方法建立局部放电模式识别模型。比较常用机器学习方法有反向传播BP(Back Propagation)算法、支持向量机SVM(Support Vector Machine)、极限学习机、概率神经网络等。文献[3]首先提取PRPD谱图中的统计特征,然后利用概率神经网络对统计特征进行分析;文献[4]基于PRPD谱图的统计特征组成不同的特征子集,通过概率神经网络算法剔除冗余特征,这2种方法对局部放电类型的识别准确率约为90%。文献[5]利用计算得到的PRPD谱图的相关参数(如灰度重心、矩特征参数等)识别局部放电模式。文献[6]通过提取的尖锐度、信息熵、稀疏度等特征识别局部放电模式。

由于PRPD谱图直观上以图像的形式呈现,文献[7]提取局部放电的时频分布图像特征,将其输入SVM中进行分类,但这种提取图像特征的方法需要人为进行各类变换,严重影响了局部放电模式识别的效率。近年来,图像识别技术越来越成熟,因此在图像分析领域中有显著效果的卷积神经网络(CNN)也被应用于局部放电模式的识别中。文献[8]采用CNN自动提取PRPD谱图中的图像特征,并通过分类器进行分类,实现了对PRPD谱图的图像识别。但是,单一PRPD谱图的数据统计特征或图像特征都存在缺陷:相似图像的外形轮廓接近,将严重影响局部放电模式识别的准确率,此时利用数据统计特征可以修正单一利用相似图像进行局部放电模式识别的结果;对于非常接近的数据统计特征参数值,单一的分析很难准确识别出局部放电模式,引入图像分析可以很好地解决这个问题。因此,对PRPD谱图的数据统计特征和图像特征进行融合分析,可以更好地识别局部放电模式。

D-S证据组合规则是一种无需先验知识的不确定推理方法,常被用于数据融合领域。文献[9]将深度置信网络与D-S证据组合规则结合,通过深度信念网络训练得到2级变压器故障诊断模型,并采用D-S证据组合规则融合2级的诊断结果得到最终的诊断结果。文献[10]中通过D-S证据组合规则将局部放电的灰度纹理特征、统计特征和油气特征进行两两融合后输入SVM中进行训练,从而得到油纸绝缘老化评估模型。因此,D-S证据组合规则适用于PRPD谱图的数据统计特征和图像特征的融合分析。但是D-S证据组合规则在处理高度冲突或完全冲突

收稿日期:2020-08-13;修回日期:2021-04-01

基金项目:国家电网公司科技项目(5600-201918181A-0-0-00)

Project supported by the Science and Technology Project of State Grid Corporation of China(5600-201918181A-0-0-00)

的证据时,会产生与常理相悖的结果。

综上所述,本文提出了一种基于D-S证据组合规则的双模型融合局部放电模式识别方法:提取典型的PRPD谱图数据统计特征,采用BP神经网络进行建模,剔除冗余特征,建立局部放电模式的BP识别模型;按照放电次数将PRPD谱图数据映射为灰度图,采用CNN提取PRPD谱图数据的图像特征,建立局部放电模式的CNN识别模型;为综合PRPD谱图的数据统计特征和图像特征分析的优势,采用基于信息熵改进的D-S证据组合规则对2个识别模型的输出结果进行融合,避免了常见的悖论问题,且该规则与贝叶斯概率论相比,需满足的条件更弱。

1 基于D-S证据组合规则的双模型融合局部放电模式识别方法的整体流程

本文方法的整体流程如图1所示。本文针对PRPD谱图的统计数据分析 and 图像数据分析分别建立了BP识别模型和CNN识别模型,2个模型的冲突性并不高,因此本文采用基于信息熵改进的D-S证据组合规则对2个模型的结果进行融合,最终得到局部放电模式判定模型(简称判定模型)。每个模型的输出为4种局部放电模式,而每个模型针对每种放电模式的识别准确率各不相同,对2个识别模型的输出结果进行融合可以修正单一模型的识别结果。




图1 基于D-S证据组合规则的双模型融合局部放电模式识别整体流程图

Fig.1 Overall flowchart of PD pattern recognition based on double models fusion with D-S evidence combination rule

2 PRPD谱图的数据统计特征分析

2.1 PRPD谱图的数据统计特征提取

PRPD谱图是基于放电脉冲的相位、幅值、次数建立的二维图像,其可以直观地反映局部放电情况。根据超宽带高频脉冲电流传感器HFCT(High Frequency Pulse Current Sensor)实测交联聚乙烯电缆局部放电数据^[11],4种局部放电模式的相位-幅值图见附录A图A1。根据PRPD谱图提取以下典型的统计特征参数。

1)偏斜度 S_k :反映谱图正、负半周期(本文中

相位 $0^\circ\sim 180^\circ$ 作为正半周期,相位 $180^\circ\sim 360^\circ$ 作为负半周期)的放电次数和放电量的分布相对于正态分布的偏斜程度^[12]。

$$S_k = \frac{\sum_{i=1}^N (x_i - \mu)^3}{\sigma^3} \quad (1)$$

式中: x_i 为二维谱图第*i*个相位小区间的相位中值; σ 为半个周期内相位分布的标准差; μ 为半个周期内放电相位的均值; N 为相位正、负半周期内相位小区间的个数。

2)陡峭度 K_u :反映谱图形状相对于正态分布的陡峭程度。

$$K_u = \frac{\sum_{i=1}^N (x_i - \mu)^4}{\sigma^4} - 3 \quad (2)$$

3)放电量因数 Q_c 。

$$Q_c = \frac{q_{\text{sum}}^-}{N_{\text{sum}}^-} / \frac{q_{\text{sum}}^+}{N_{\text{sum}}^+} \quad (3)$$

式中: q_{sum}^+ 、 q_{sum}^- 分别为相位正、负半周期放电量和; N_{sum}^+ 、 N_{sum}^- 分别为相位正、负半周期放电次数总和。

将上述统计特征依次存入数组中构成统计特征集 $\{S_k, K_u, Q_c\}$ 。

2.2 统计特征筛选与分析

统计特征中存在的冗余信息会降低机器学习模型的局部放电模式识别准确率^[13],剔除这些冗余信息尤为必要。由于本文提取的统计特征较少,因此首先将数组中的所有统计特征数据集作为输入进行机器学习训练,例如第1次输入的统计特征集为 $\{F_1, F_2, F_3\}$,然后再剔除其中一个统计特征进行机器学习训练(即选择的特征集为 $\{F_1, F_2\}$ 、 $\{F_1, F_3\}$ 或 $\{F_2, F_3\}$,下一次训练再剔除1个统计特征,如果局部放电模式识别准确率不再变化,则选择识别准确率最高的统计特征组合作为机器学习的输入特征。BP神经网络是机器学习中常用的一种结构简单的神经网络,其由输入层、隐藏层、输出层组成,采用全连接方式^[14],具有较强的非线性能力、泛化能力、自学习能力和自适应能力,以及一定的容错能力,常用于解决分类问题和线性回归问题。本文利用BP神经网络(隐藏层数为1,隐藏层含有10个节点)建立BP识别模型,通过不断地反馈更新权值矩阵和偏置矩阵来调整网络参数,当损失函数达到一定阈值时退出训练,完成模型建立。

3 PRPD谱图的图像数据分析

PRPD谱图直观上也是一种图像,因此图像分析的方法同样适用于PRPD谱图的图像数据分析。CNN可以共享卷积核,适用于高维数据处理,同时,CNN对数据具有位移、缩放、扭曲不变性,更有利于

对图像数据的处理,因此在图像领域得到了广泛的应用。CNN 结构包括输入层、卷积层、池化层、全连接层、输出层^[15],其中,卷积层、池化层通过不断地卷积与池化,得到最终的特征输入;全连接层连接着 CNN 提取的特征输入与输出。本文建立的 CNN 模型包含 2 个卷积层、2 个池化层、1 个全连接层,全连接层采用的神经网络算法同 BP 神经网络,输出层采用式(4)所示的 S_f 函数输出最终结果。

$$S_f(z_j) = \frac{e^{z_j}}{\sum_{j=1}^K e^{z_j}} \quad j=1, 2, \dots, K \quad (4)$$

式中: z_j 为第 j 个神经元的输出; K 为神经元总数。

基于 PRPD 谱图,以相位 ψ 为横轴数据、放电幅值 q 为纵轴数据、放电次数 n_d 为像素点,构建二维图形输入。由于单个相位可能存在多个放电次数,因此取平均放电次数 $\bar{n}_d$ 作为像素点,根据最大放电次数 n_{dmax} 将像素点的值映射到 0~255 范围内,以便输入 CNN 进行计算^[16]。利用式(5)将 PRPD 谱图图像数据映射为灰度图,结果如附录 A 图 A2 所示。

$$G = 255 \bar{n}_d / n_{dmax} \quad (5)$$

式中: G 为灰度值。

4 基于 D-S 证据组合规则的双模型融合方法

4.1 D-S 证据组合规则

识别框架 θ 可表示为包含 n 个元素的集合 $\theta = \{A_1, A_2, \dots, A_n\}$, 在该识别框架下, 如果存在一个函数 m 满足:

$$\begin{cases} m(\emptyset) = 0 \\ \sum_{A \subseteq \theta} m(A) = 1 \end{cases} \quad (6)$$

则 m 为该识别框架下的基本概率分配函数(也称为 mass 函数), 该函数反映在识别框架 θ 下对集合中的元素的支持程度。由 mass 函数引出信任函数 B_1 以及似然函数 P_1 分别如式(7)和式(8)所示。

$$\begin{cases} B_1(\emptyset) = 0 \\ B_1(\theta) = 1 \\ B_1\left(\bigcup_{i=1}^n A_i\right) \geq \sum_{I \subseteq \{1, 2, \dots, n\}, I \neq \emptyset} (-1)^{|I|+1} B_1\left(\bigcap_{i \in I} A_i\right) \end{cases} \quad (7)$$

$$P_1(A) = 1 - B_1(\bar{A}) \quad (8)$$

式中: $|I|$ 表示集合 I 中元素的个数; $\bar{A}$ 为集合 A 的补集。

本文中的 θ 有 2 个子集, 即 2 个局部放电模式识别模型, 其基本概率分配函数分别为 m_1 、 m_2 , 其元素为各识别模型下对 4 种局部放电模式(电晕放电、悬浮放电、内部放电、沿面放电)的识别准确率, 分别为 A_1 — A_4 和 B_1 — B_4 , 则融合后的结果如式(9)所示。

$$m(A) = \begin{cases} \frac{1}{1-k} \sum_{A_i \cap B_j = A} m_1(A_i) m_2(B_j) & A \subseteq \theta, A \neq \emptyset \\ 0 & A = \emptyset \end{cases} \quad (9)$$

$$k = \sum_{A_i \cap B_j = \emptyset} m_1(A_i) m_2(B_j) \quad (10)$$

式中: $m(A)$ 为融合后的基本概率分配函数; k 为冲突系数^[17-18]。采用 D-S 证据组合规则融合 2 个识别模型得到的结果, 可以更加准确地识别局部放电模式。

4.2 基于信息熵的改进 D-S 证据组合规则

D-S 证据组合规则在处理高度冲突或完全冲突的证据时, 会产生与常理相悖的结果, 例如 2 个识别模型在局部模式识别结果上的差别可能会引起误判。因此, 需要对 D-S 证据组合规则进行改进。目前针对 D-S 证据组合规则的改进方法主要分为修改证据理论合成规则和修改证据源 2 类。本文根据信息熵的大小赋给证据体相应的权重, 以此来修改证据源, 从而避免在融合高度冲突的数据时出现悖论问题。

信息熵反映了信息量的多少, 证据体的信息熵越小, 其所携带的有用信息越少, 稳定性越高, 在融合时所占的权重也就越大。信息熵 $H(X)$ 的定义为:

$$H(X) = -\sum p(x_i) \log_2 p(x_i) \quad (11)$$

式中: X 为信息源; $p(x_i)$ 为第 i 个信息 x_i 出现的概率。

2 个识别模型对每种局部放电模式的识别准确率反映了测试集中该局部放电模式被正确识别的概率, 即可看作是所携带的有用信息的概率。因此, 可将 2 个识别模型对每种局部放电模式的识别准确率作为信息概率值, 计算出各个模型中证据体的信息熵。各模型中的证据体即为局部放电模式, 依据证据体的信息熵占比设置证据体的权重 w_i , 如式(12)所示。

$$w_i = \exp(-\alpha_i) \quad (12)$$

$$\alpha_i = \frac{H(x_i)}{\sum_{i=1}^n H(x_i)} \quad (13)$$

式中: $H(x_i)$ 为证据体的信息熵; n 为证据体数量。根据证据体的权重修正证据源, 得到修正后的结果如式(14)所示。

$$m(A) = \sum_{i=1}^n w_i m_i(A) \quad (14)$$

根据修正证据源后的结果, 按照 D-S 证据组合规则, 对 2 个识别模型的结果进行融合, 从而得到判定模型。

4.3 模型融合过程

根据 BP、CNN 识别模型的局部放电模式识别结果, 按照未改进和基于信息熵的改进 D-S 证据组合规则得到的概率分配函数分别如式(15)和式(16)

所示。

$$m(A) = \frac{m_1(A_i)m_2(B_j)}{1 - \sum_{i=1}^n m_1(A_i)m_2(B_j)} \quad (15)$$

$$m(A) = \frac{w_i w_j m_1(A_i)m_2(B_j)}{1 - \sum_{i=1}^n w_i w_j m_1(A_i)m_2(B_j)} \quad (16)$$

由式(16)可见,当某个识别模型能够更加准确地识别某种局部放电模式时,该局部放电模式的信息熵更小,其mass函数的权重更大,则式(16)的分子增大、分母减小,所以式(16)的值增大。因此基于信息熵改进后的D-S证据组合规则进行模型融合时,将更加信赖识别准确率高的模型。

5 实验结果与分析

本文采集了电晕放电、悬浮放电、内部放电、沿面放电这4种局部放电模式的数据,每种模式有100组样本数据,共400组样本数据。为模拟实际情况并提高模型的泛化性能,在采集的数据中加入均值为0、标准差为5^[19]的高斯噪声,以电晕放电数据为例,加入高斯噪声后的数据见附录B图B1。在每种局部放电模式的每组样本数据中分别加入4次高斯噪声,则可将4种局部放电模式的数据样本数据扩充至6400组。对数据的分配见附录B表B1。在训练模型时采用五折交叉验证法。

5.1 BP识别模型的建立

为便于叙述,下文的图表中将电晕放电、悬浮放电、内部放电、沿面放电分别记为模式1—4。根据2.2节中的统计特征筛选方法,为消除统计特征之间的冗余度,需提取易于分类的特征组合,具体流程为:将偏斜度 S_k 、陡峭度 K_u 、放电电量因数 Q_c 分别记为特征 F_1 、 F_2 、 F_3 ,4种局部放电模式的特征参数如图2所示;分别以多个特征组合 $\{F_1, F_2, F_3\}$ 、 $\{F_1, F_2\}$ 、 $\{F_1, F_3\}$ 、 $\{F_2, F_3\}$ 以及单个特征 F_1 、 F_2 、 F_3 建立BP识别模型并进行训练,根据各特征组合作为输入时的损失函数值择优选择特征组合。传统的BP神经网络收敛速度慢,容易陷入局部最小值。因此,本文采用小批量梯度下降法训练BP神经网络,同时加入自适应学习率。BP识别模型采用归一化指数函数作为激活函数,采用均方误差函数作为损失函数,采用梯度下降算法作为优化策略,每批次设置输入量为10。BP识别模型训练过程如图3所示。根据训练结果可知,选择特征组合 $\{F_1, F_3\}$ 作为输入可以消除 $\{F_1, F_2, F_3\}$ 中的统计特征间的冗余度。按照前文的参数设置,建立以 $\{F_1, F_3\}$ 为特征输入的BP识别模型并进行训练。

5.2 CNN识别模型的建立

CNN识别模型采用归一化指数函数作为激活函






图2 4种局部放电模式的统计特征参数

Fig.2 Statistical characteristic parameters of four PD modes



(a) 单特征BP识别模型



(b) 多特征BP识别模型训练过程

图3 不同统计特征组合下的BP识别模型训练过程

Fig.3 Training process of BP recognition model under different statistical characteristic combinations

数,采用交叉熵作为损失函数,采用自适应梯度算法作为优化策略,每批次设置输入量为10。根据6400组样本数据以及附录B表B1所示的分配方式训练CNN识别模型。CNN识别模型在训练过程中的损失函数值如图4所示。当CNN识别模型保持稳定且损失函数值达到阈值时即完成训练。




图4 CNN识别模型在训练过程中的损失函数值

Fig.4 Loss function value of CNN recognition model during training process

5.3 双模型融合

利用 BP 识别模型和 CNN 识别模型检测测试样本,结果如表 1 所示。

表 1 BP 和 CNN 识别模型的测试准确率

Table 1 Test accuracy of BP and CNN

识别模型	测试准确率 / %			
	模式 1	模式 2	模式 3	模式 4
BP	88.0	87.0	89.5	88.75
CNN	89.5	94.5	93.0	88.75

根据 4.2 节中的方法计算 BP、CNN 识别模型中各类局部放电模式的权重。以 BP 识别模型为例,根据 BP 识别模型的局部放电模式识别准确率,可获得 BP 模型下电晕放电、悬浮放电、内部放电、沿面放电模式的信息熵分别为 0.162、0.175、0.143、0.153,从而计算得到各局部放电模式的权重见附录 B 表 B2。得到各局部放电模式的权重后,对 BP、CNN 识别模型输出的结果进行融合,得到最终的判定模型。

局部放电测试样本识别流程为:对每种局部放电模式测试样本分别采用 BP、CNN 识别模型进行模式识别,按照(BP 识别模型识别结果, CNN 识别模型识别结果)的方式记录模型输出结果,例如(1,3)表示 BP、CNN 识别模型输出的结果分别为电晕放电、内部放电模式。2 个识别模型对各类局部放电测试样本的识别结果如表 2 所示。

表 2 BP 和 CNN 识别模型对各类局部放电测试样本的识别结果

Table 2 Recognition results of various PD test samples by BP and CNN recognition models

实际模式	识别结果	占比 / %	实际模式	识别结果	占比 / %
1	(1,1)	77.50	3	(3,3)	82.50
	(1,3)	10.50		(1,3)	10.50
	(3,1)	12.00		(3,1)	7.00
2	(2,2)	87.00	4	(4,4)	88.75
	(4,2)	7.50		(1,2)	3.25
	(1,1)	5.50		(3,1)	8.00

利用未改进的 D-S 证据组合规则融合 BP、CNN 识别模型的识别结果时,计算得到的基本概率分配函数值如表 3 所示。D-S 证据组合规则中,基本概率分配函数值越大的证据,其可靠性越大。例如在对电晕放电和内部放电测试样本进行识别时,均输出了结果(1,3)(如表 3 中下划线所示),但是电晕放电模式对应的基本概率分配函数值更大,因此最终判定结果为电晕放电模式。

根据基于信息熵改进的 D-S 证据组合规则融合 BP 和 CNN 识别模型的输出结果后,计算得到的基本概率分配函数值如表 4 所示,双模型融合后的判定模型输出的结果如表 5 所示。可见,经过信息熵改

表 3 基于未改进的 D-S 证据组合规则

进行模型融合后的 mass 函数值

Table 3 Values of mass function after model fusion with original D-S evidence combination

实际模式	识别结果	mass 函数值	实际模式	识别结果	mass 函数值
1	(1,1)	0.960	3	(3,3)	0.980
	<u>(1,3)</u>	<u>0.017</u>		<u>(1,3)</u>	<u>0.016</u>
	(3,1)	0.023		(3,1)	0.007
2	(2,2)	0.990	4	(4,4)	0.990
	(4,2)	0.007		(1,2)	0.001
	(1,1)	0.004		(3,1)	0.008

进的 D-S 证据组合规则在进行模型融合时,将输出(1,3)对应的识别结果判定为内部放电模式,从而解决了未改进的 D-S 证据组合规则在模型融合时存在的悖论问题。利用该判定模型对测试样本进行检测,结果如表 6 所示。

表 4 基于改进的 D-S 证据组合规则

进行模型融合后的 mass 函数值

Table 4 Values of mass function after model fusion with improved D-S evidence combination

实际模式	识别结果	mass 函数值	实际模式	识别结果	mass 函数值
1	(1,1)	0.960	3	(3,3)	0.980
	<u>(1,3)</u>	<u>0.016</u>		<u>(1,3)</u>	<u>0.017</u>
	(3,1)	0.024		(3,1)	0.007
2	(2,2)	0.990	4	(4,4)	0.990
	(4,2)	0.008		(1,2)	0.002
	(1,1)	0.004		(3,1)	0.008

表 5 基于改进的 D-S 证据组合规则

进行模型融合后的判定结果

Table 5 Decision results after model fusion with improved D-S evidence combination

实际模式	识别结果	判定结果
1	(1,1)	1
	(3,1)	
2	(2,2)	2
	(4,2)	
3	(3,3)	3
	(1,3)	
4	(4,4)	4
	(1,2)	

表 6 基于改进的 D-S 证据组合规则

进行模型融合后的模型测试结果

Table 6 Test results after model fusion with improved D-S evidence combination

模式	测试准确率 / %	模式	测试准确率 / %
1	89.5	3	93.0
2	94.5	4	92.0

利用式(17)所示的召回率 R_{recall} 反映识别模型的稳定性,结果如图 5 所示。召回率越大,模型越稳定。由图 5 可知,采用基于信息熵改进的 D-S 证据组

合规则进行双模型融合后,可以修正单一模型识别的结果,对局部放电模型的识别更加稳定、准确。

$$R_{\text{recall}} = \frac{T_p}{T_p + F_N} \quad (17)$$

式中: T_p 、 F_N 分别为某种放电模式被预测正确、错误的个数。




图5 各模型的召回率

Fig.5 Recall rate of each model

6 结论

本文提取了2种不同类别的PRPD谱图数据特征,分别采用BP神经网络和CNN建立局部放电模式识别模型,通过基于信息熵改进的D-S证据组合规则对2种识别模型进行融合,解决了D-S证据组合规则常见的悖论问题,能够更加全面地包含PRPD谱图数据反映的局部放电类型的特征。实验结果表明,本文方法的识别结果更加稳定、准确。本文工作为局部放电模式识别提供了可借鉴的方法,今后将在电力设备运行状态评估及设备运维等方面做进一步研究。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 贾亚飞,朱永利,高佳程,等. 基于样本加权FCM聚类的未知类别局部放电信号识别[J]. 电力自动化设备,2018,38(12): 107-112.
- [2] JIA Yafei, ZHU Yongli, GAO Jiacheng, et al. Recognition of unknown partial discharge signals based on sample-weighted FCM clustering[J]. Electric Power Automation Equipment, 2018,38(12): 107-112.
- [3] 杨景刚,邓敏,马勇,等. 基于深度学习的PRPD数据特征提取方法[J]. 电测与仪表,2020,57(3):99-104,115.
- [4] YANG Jinggang, DENG Min, MA Yong, et al. Feature extraction method of PRPD data based on deep learning[J]. Electrical Measurement & Instrumentation, 2020,57(3):99-104,115.
- [5] 李正明,钱露先,李加彬. 基于统计特征与概率神经网络的变压器局部放电类型识别[J]. 电力系统保护与控制,2018,46(13):55-60.
- [6] LI Zhengming, QIAN Luxian, LI Jiabin. Type recognition of partial discharge in power transformer based on statistical characteristics and PNN[J]. Power System Protection and Control, 2018,46(13):55-60.
- [7] 王刘旺,朱永利,李莉,等. 基于特征子集的变压器局部放电小样本类型识别[J]. 电测与仪表,2015,52(24):40-45.
- [8] WANG Liuwang, ZHU Yongli, LI Li, et al. Partial discharge type recognition of small sample for power transformer based on feature subsets[J]. Electrical Measurement & Instrumentation, 2015,52(24):40-45.
- [9] 杨丰源,许永鹏,钱勇,等. 相关分析技术在直流电压下XLPE电缆局部放电信号特征提取与筛选中的应用[J]. 电网技术,2018,42(5):1653-1660.
- [10] YANG Fengyuan, XU Yongpeng, QIAN Yong, et al. Application of correlation analysis techniques in feature extraction and selection for DC partial discharge signals of XLPE cables[J]. Power System Technology, 2018,42(5):1653-1660.
- [11] 汪可,廖瑞金,王季宇,等. 局部放电UHF脉冲的时频特征提取与聚类分析[J]. 电工技术学报,2015,30(2):211-219.
- [12] WANG Ke, LIAO Ruijin, WANG Jiyu, et al. Time-frequency features extraction and clustering analysis of partial discharge UHF pulses[J]. Transactions of China Electrotechnical Society, 2015,30(2):211-219.
- [13] 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高频信号的特征参数提取方法[J]. 高压电器,2017,53(7): 30-37,44.
- [14] 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.
- [15] 李宏波,朱永利,王京保. 基于多层特征融合CNN的变压器PRPD图谱识别[J]. 电测与仪表,2020,57(18):63-68.
- [16] LI Hongbo, ZHU Yongli, WANG Jingbao. Transformer PRPD pattern recognition based on multi-layer feature fusion CNN[J]. Electrical Measurement & Instrumentation, 2020,57(18): 63-68.
- [17] 李刚,于长海,范辉,等. 基于多级决策融合模型的电力变压器故障深度诊断方法[J]. 电力自动化设备,2017,37(11):138-144.
- [18] LI Gang, YU Changhai, FAN Hui, et al. Deep fault diagnosis of power transformer based on multilevel decision fusion model[J]. Electric Power Automation Equipment, 2017,37(11):138-144.
- [19] 刘东超,林语,原辉,等. 灰度纹理与油气特征融合的油纸绝缘老化状态评估[J]. 中国电力,2020,53(12):159-166,197.
- [20] LIU Dongchao, LIN Yu, YUAN Hui, et al. Aging state evaluation of oil-paper insulation based on fusion of gray texture and oil gas features[J]. Electric Power, 2020,53(12):159-166,197.
- [21] 陈孝信,钱勇,许永鹏,等. 基于脉冲源的高频电流传感器传输阻抗测量新方法[J]. 电力自动化设备,2019,39(3):120-124,131.
- [22] CHEN Xiaoxin, QIAN Yong, XU Yongpeng, et al. A novel pulse-source-based method for measuring transfer impedance of high frequency current sensor[J]. Electric Power Automation Equipment, 2019,39(3):120-124,131.
- [23] 杨帆,王干军,彭小圣,等. 基于卷积神经网络的高压电缆局部放电模式识别[J]. 电力自动化设备,2018,38(5):123-128.
- [24] YANG Fan, WANG Ganjun, PENG Xiaosheng, et al. Partial discharge pattern recognition of high-voltage cables based on convolutional neural network[J]. Electric Power Automation Equipment, 2018,38(5):123-128.
- [25] 高佳程,曹雁庆,朱永利,等. 基于KELM-VPMCD方法的未知局部放电类型的模式识别[J]. 电力自动化设备,2018,38(5): 141-147.
- [26] GAO Jiacheng, CAO Yanqing, ZHU Yongli, et al. Pattern recognition of unknown PD types based on KELM-VPMCD[J]. Electric Power Automation Equipment, 2018,38(5):141-147.
- [27] 王克杰,张瑞. 基于改进BP神经网络的短期电力负荷预测方法研究[J]. 电测与仪表,2019,56(24):115-121.
- [28] WANG Kejie, ZHANG Rui. Research on short-term power load forecasting method based on improved BP neural network[J]. Electrical Measurement & Instrumentation, 2019,56(24): 115-121.
- [29] 周秀,朱洪波,马云龙,等. 基于深度学习的变压器局部放电模

- 式识别研究[J]. 高压电器,2019,55(12):98-105.
- ZHOU Xiu,ZHU Hongbo,MA Yunlong,et al. Partial discharge pattern recognition of transformer based on deep learning[J]. High Voltage Apparatus,2019,55(12):98-105.
- [16] 褚鑫,张建文,韩刚. 统计特征参数及多分类SVM的局部放电类型识别[J]. 电测与仪表,2015,52(7):35-39,96.
- CHU Xin,ZHANG Jianwen,HAN Gang. Partial discharge pattern recognition based on statistical parameters and multi-classifications SVM[J]. Electrical Measurement & Instrumentation, 2015,52(7):35-39,96.
- [17] 高湛军,李思远,彭正良,等. 基于网络树状图和改进D-S证据理论的配电网故障定位方法[J]. 电力自动化设备,2018,38(6):65-71.
- GAO Zhanjun,LI Siyuan,PENG Zhengliang,et al. Fault location method of distribution network based on tree structure diagram and improved D-S evidence theory[J]. Electric Power Automation Equipment,2018,38(6):65-71.
- [18] 胡嘉骥. 基于D-S证据理论的数据融合算法的研究[D]. 南京:东南大学,2016.
- HU Jiaji. The data fusion method research based on D-S evidence theory[D]. Nanjing:Southeast University,2016.
- [19] 刘文浩,李文泽,王洪雨,等. 基于可变噪音的高压电缆局部放电样本扩充[J]. 广东电力,2020,33(9):35-41.
- LIU Wenhao,LI Wenzhe,WANG Hongyu,et al. Partial discharge samples augmentation of high voltage cable based on variable noise[J]. Guangdong Electric Power,2020,33(9):35-41.

作者简介:



徐敏锐

徐敏锐(1976—),男,江苏南京人,教授级高级工程师,硕士,主要研究方向为电力计量、设备检测;

李云(1994—),男,江苏盐城人,硕士研究生,主要研究方向为电力设备状态检测与运维、电网运行大数据分析(E-mail: 1296793619@qq.com);

卢树峰(1972—),男,江苏南京人,高级工程师,硕士,主要研究方向为用电信息采集、电能计量。

(编辑 任思思)

Recognition method of partial discharge pattern based on double models fusion with D-S evidence combination rule

XU Minrui¹, LI Yun², LU Shufeng¹, DOU Xiaobo³, CHEN Gang¹, GUO Jiahao¹

(1. Marketing Service Center, State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210096, China;

2. School of Cyber Science and Engineering, Southeast University, Nanjing 211189, China;

3. School of Electrical Engineering, Southeast University, Nanjing 210096, China)

Abstract: The traditional PD(Partial Discharge) pattern recognition has the disadvantages of single feature extraction and low recognition accuracy, aiming at which, a PD pattern recognition based on double models fusion with D-S evidence combination rule is proposed. According to the characteristics of the statistical data and image features of PRPD(Partial Discharge based on Phase Information) spectrum data, BP(Back Propagation) recognition model and CNN(Convolutional Neural Network) recognition model are respectively established. According to the output results of the two recognition models, the improved D-S evidence combination rule based on information entropy is proposed to solve the common paradox problems. The decision model is established based on the improved D-S evidence combination rule, by which, the output results of the two recognition models are better integrated and complement the advantages of the two feature recognition methods. The actual data test shows that compared with the single model, the proposed method can recognize the PD patterns stably and accurately.

Key words: partial discharge; feature extraction; machine learning; pattern recognition; D-S evidence combination

附录 A




图 A1 4 种局部放电类型数据相位-幅值图

Fig.A1 Phase-amplitude diagram of four types of partial discharge data




图 A2 PRPD 数据灰度图形式

Fig.A2 Grayscale form of PRPD data

附录 B




图 B1 加入高斯噪声后的数据
Fig.B1 Data after adding Gaussian noise

表 B1 样本分配

Table B1 Sample allocation

局部放电模式	样本分配结果		
	训练集	验证集	测试集
电晕放电	1200	300	100
悬浮放电	1200	300	100
内部放电	1200	300	100
沿面放电	1200	300	100

表 B2 BP 和 CNN 模型中各类局部放电类型权重

Table B2 Weights of various PD types in BP and CNN models

模型	权重			
	电晕放电	悬浮放电	内部放电	沿面放电
BP	0.77	0.76	0.8	0.79
CNN	0.74	0.85	0.81	0.72