

## 基于融合极限学习机的局部放电模式识别

潘志新<sup>1</sup>, 刘利国<sup>1</sup>, 钱程<sup>2</sup>, 王震<sup>3</sup>, 袁栋<sup>1</sup>

(1. 国网江苏省电力有限公司, 江苏南京 210024; 2. 东南大学电气工程学院,  
江苏南京 210096; 3. 国网江苏省电力有限公司无锡供电公司, 江苏无锡 214012)

**摘要:**局部放电(PD)是配电设备绝缘故障早期的主要表现形式,放电类型的模式识别对于设备绝缘性能的判定具有重要意义。考虑到极限学习机(ELM)法结构简单、训练速度快,但初始参数选取随机性大,算法稳定性不够的特点,提出一种基于融合 ELM 算法的 PD 模式识别方法,综合考虑不同特征判断准确率的差异,采用自适应权值分配对子分类器输出结果实现决策级融合。文中设计了 4 种放电物理模型来模拟典型的设备绝缘缺陷,采用高频电流法对 PD 信号波形和相位-幅值谱图(PPRD)进行采集,获得足够样本的实验数据,提取时频域及统计特征值进行分类。结果表明融合 ELM 算法在保证训练速度的同时,在识别正确率和稳定性上均优于传统 ELM 算法和反向传播(BP)神经网络。

**关键词:**局部放电;模式识别;极限学习机;数据融合;配电设备

中图分类号:TM855

文献标志码:A

文章编号:2096-3203(2019)05-0042-07

## 0 引言

社会用电量的持续增长推动了配电网的迅速发展,越来越多的配电设备投入使用,其安全稳定运行将直接影响系统对于用户供电的可靠性,而设备的绝缘缺陷常会发展成为故障引起停电等事故<sup>[1—4]</sup>。局部放电(partial discharge, PD)既是设备绝缘老化的主要原因,也是表征绝缘性能的重要指标<sup>[5—8]</sup>,准确识别放电类型,能为设备绝缘状态的评估提供有效依据,并为有针对性地制定检修方案提供帮助<sup>[9—12]</sup>。

目前,国内外学者针对 PD 的模式识别已经开展了大量研究,提出的模式识别方法包括聚类算法<sup>[13—14]</sup>、多隐层神经网络<sup>[15—17]</sup>和支持向量机方法<sup>[18—19]</sup>等,但均存在不足。对于聚类算法,当提取特征维度较高时,计算量会显著提升;多隐层神经网络利用梯度下降法修正误差,收敛速度较慢,且容易陷入局部最优解;支持向量机方法适合小样本的训练和识别,对于大规模训练样本实施存在困难,核函数选取也缺乏统一标准,而且这些方法都需要反复训练和迭代确定模型参数,增加了训练时间。

极限学习机(extreme learning machine, ELM)作为一种新型单隐层前馈神经网络,其各层连接权值和阈值无需反馈调整,和传统的神经网络相比具有结构简单、学习速率快的优点<sup>[20—24]</sup>。在传统单一 ELM 分类器的基础上,结合数据融合技术,从不同

维度提取特征量,根据多个分类器的输出进行决策级融合,形成了一种改进方法——融合 ELM 算法。文中制作 4 种典型的 PD 模型模拟常见的设备绝缘缺陷,在实验室中采用高频电流法提取放电相位-幅值谱图(phase-resolved partial discharge, PRPD)和波形信号,将采集数据的特征量作为训练样本,利用融合 ELM 进行模式识别,并和传统 ELM 算法及反向传播(back propagation, BP)神经网络进行对比,结果表明融合 ELM 方法在识别准确度方面有较大提高,验证了该方法的有效性。

## 1 融合 ELM 原理

### 1.1 ELM

ELM<sup>[25—26]</sup>是基于单隐层前馈神经网络提出的一种高效简便的学习方法,其基本结构如图 1 所示。由输入层、单隐含层和输出层组成,输入层和隐含层之间的连接权值及隐含层各神经元的偏置均随机产生,隐含层至输出层的权重通过求解广义逆矩阵确定,无需进行误差反向传播来迭代调整,所以该算法具有学习速度快且泛化能力强的优点。

对一个含有  $N$  个不同样本的训练集  $\{\mathbf{x}_i, t_i\}, i=1, 2, \dots, N$ ;  $\mathbf{x}_i$  为  $d$  维输入向量;  $t_i$  为对应的期望输出。若隐层有  $L$  个节点, ELM 实际输出可表示为:

$$f_i(\mathbf{x}) = \sum_{j=1}^L \boldsymbol{\beta}_j G(\boldsymbol{\omega}_j \mathbf{x}_i + b_j) = \mathbf{h}(\mathbf{x}_i) \boldsymbol{\beta} \quad (1)$$

式中:  $\boldsymbol{\beta}_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jN}]^T$  为第  $j$  个隐层节点与输出层之间的权值向量;  $\boldsymbol{\omega}_j = [\omega_{j1}, \omega_{j2}, \dots, \omega_{jN}]^T$  为输入层与第  $j$  个隐层节点之间的权值向量;  $b_j$  为第  $j$  个

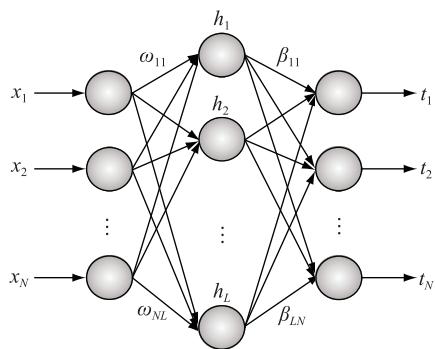


图 1 ELM 网络结构

Fig.1 Structure diagram of ELM

隐层节点的偏置值;  $G(\cdot)$  为隐层节点的激励函数,通常采用 sigmoid 或 sine 函数;  $\mathbf{h}(\mathbf{x}_i)$  为隐层对于  $\mathbf{x}_i$  的输出向量;  $f_i$  为网络的实际输出值。通过 ELM 网络,各样本的实际输出  $f_i$  应零误差地逼近对应的期望输出  $t_i$ , 即有:

$$\sum_{i=1}^N \|f_i - t_i\| = 0 \quad (2)$$

计算得到输出权重矩阵为:

$$\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{T} = \mathbf{H}^T (\mathbf{I}/C + \mathbf{H}\mathbf{H}^T)^{-1} \mathbf{T} \quad (3)$$

式中:  $\mathbf{H}^+$  称为隐层输出矩阵的广义逆矩阵;  $\mathbf{I}$  为单位矩阵;  $C$  为惩罚因子, 可以消除过拟合现象, 增强网络稳定性和泛化能力。ELM 的输出方程可以表示为:

$$\mathbf{y} = \mathbf{h}(\mathbf{x}) \boldsymbol{\beta} = \mathbf{h}(\mathbf{x}) \mathbf{H}^T (\mathbf{I}/C + \mathbf{H}\mathbf{H}^T)^{-1} \mathbf{T} \quad (4)$$

针对多分类问题, 输出向量中最大值对应的类别为实际输出值<sup>[27]</sup>。

## 1.2 决策级融合

在很多应用场景下, 训练集中待分类的样本标签较多、特征不够明显、样本数量不大, 传统 ELM 算法会存在分类性能不够理想, 稳定性较差的缺点<sup>[28]</sup>。为了提高识别结果的准确度和可靠性, 利用数据融合的技术进行改进。从不同维度提取训练样本的特征参数, 由子分类器对各自信息先做出初步判定, 然后对判定结果进行融合处理, 得到最终的输出判断。判断准确性的关键在于融合权值的分配以及各分类器输出向量应保证在相同取值范围。利用 sigmoid 函数对子 ELM 分类器的输出向量进行映射:

$$P(f_i(\mathbf{x})) = \frac{1}{1 + e^{-f_i(\mathbf{x})}} \quad i = 1, 2, \dots, m \quad (5)$$

经过映射后, 各标签概率之和不等于 1, 需进行归一化处理:

$$p_i(\mathbf{x}) = \frac{P(f_i(\mathbf{x}))}{\sum_{i=1}^m P(f_i(\mathbf{x}))} \quad (6)$$

若采用  $M$  个分类器进行融合判断, 则概率输出矩阵可表示为:

$$\mathbf{P}(\mathbf{x}) = \begin{bmatrix} p_{11}(\mathbf{x}) & p_{12}(\mathbf{x}) & \cdots & p_{1M}(\mathbf{x}) \\ p_{21}(\mathbf{x}) & p_{22}(\mathbf{x}) & \cdots & p_{2M}(\mathbf{x}) \\ \vdots & \vdots & \ddots & \vdots \\ p_{m1}(\mathbf{x}) & p_{m2}(\mathbf{x}) & \cdots & p_{mM}(\mathbf{x}) \end{bmatrix} \quad (7)$$

矩阵中每一列代表一个分类器的概率输出, 采用自适应权值分配的方式实现多个 ELM 分类器结果的判定融合。对同一样本进行模式识别, 若分类器将其归类为某一类标签的概率越大, 表明该分类器对此样本的识别准确率越高, 应分配的融合权值也越大, 反之亦然。融合权值计算方法如式(8)所示:

$$\mu_k = \frac{p_k}{\sum_{k=1}^M p_k} \quad (8)$$

式中:  $p_k$  为第  $k$  个分类器中最大的概率输出。确定融合权值后, 对各分类器输出加权, 加权和最大的标签作为融合判定的输出结果。

## 2 实验数据采集与特征构建

### 2.1 缺陷模型设计

配电设备包括开关柜、环网柜、电缆等, 其制造或安装过程难免存在问题而造成绝缘缺陷, 导体或外壳表面的金属凸起会引起尖端放电, 绝缘内部存在微小气泡容易形成内部气隙放电, 绝缘表面污秽或者导体表面接触不良是造成沿面放电的主要原因, 而柜体内部或者电缆接线头处存在悬浮颗粒将导致悬浮放电<sup>[29-30]</sup>。根据不同的放电机理, 在实验室制作 4 种典型放电物理模型来模拟不同的绝缘缺陷, 如图 2 所示。各板电极均为直径 50 mm, 厚度 10 mm 的圆形铜电极, 表面打磨光滑, 电极螺帽采用圆形螺帽。

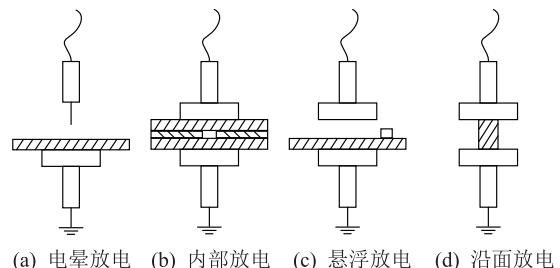


图 2 局部放电试验模型

Fig.2 PD experiment models

图 2(a) 为电晕放电模型, 高压端针尖长 15 mm, 曲率半径 0.5 mm, 接地电极上放置直径 100 mm, 厚度 3 mm 的环氧树脂板, 针板距离 5 mm; 图 2

(b) 为内部放电模型, 模型上下层为直径 100 mm, 厚度 3 mm 的环氧树脂板, 中间为直径 100 mm, 厚度 1 mm 的环氧树脂板, 其内部开直径 5 mm 的小孔作为放电腔, 各层间用环氧树脂胶可靠粘合; 图 2(c) 为悬浮放电模型, 直径 100 mm, 厚度 3 mm 的环氧树脂板边缘处放置直径 10 mm, 高度 5 mm 的铜块, 电极间距 10 mm; 图 2(d) 为沿面放电模型, 两电极间放置直径 10 mm, 高度 10 mm 的环氧树脂棒。

## 2.2 PD 模拟实验

在实验室中搭建的测试系统如图 3 所示, 利用高频电流法采集局放信号<sup>[31]</sup>。S 为交流电源; T<sub>1</sub> 为自耦调压器; T<sub>2</sub> 为升压变压器; R 为限流电阻, 阻值为 200 kΩ, 用来限制模型击穿时的短路电流; C<sub>x</sub> 为试验模型; M<sub>1</sub> 为高频电流传感器 (high-frequency current transformer, HFCT), 接在试品和地之间; Z<sub>m</sub> 为采样阻抗; 局放信号和电压同步信号通过同轴电缆传输到测试装置 M<sub>2</sub>, 测试装置采样率为 100 MHz, 能够同时采集到 PRPD 谱图和放电波形。

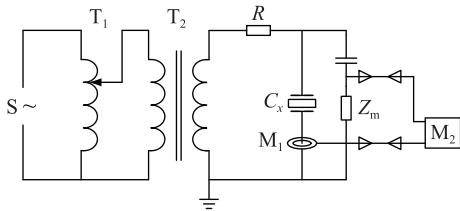


图 3 测试系统接线

Fig.3 Wiring diagram of measurement system

调节调压器逐步升高电压, 直至放电模型产生稳定的 PD 信号, 利用测试装置采集并存储放电 PRPD 谱图和波形。

## 2.3 特征量提取

由实验得到的 4 种模型测试结果如图 4 和图 5 所示, 可以看出, 不同放电模型的 PRPD 谱图和波形存在差异, 提取具有代表性的特征值, 降低后续模式识别中输入样本的维度。PRPD 谱图横坐标为放电相位, 纵坐标为放电量幅值, 波形信号横坐标为放电时间, 纵坐标为放电电压。针对 PRPD 谱图, 提取 6 个特征参数<sup>[32]</sup>, 分别为放电量因数  $R_Q$ 、正负半周相关系数  $C_C$ 、偏斜度  $S_k^\pm$  和峰度  $K_u^\pm$ 。

(1) 放电量因数  $R_Q$ , 反映正负半周的平均放电量的差异, 定义为负正半轴平均放电量的比值:

$$R_Q = Q_{\text{avg}}^- / Q_{\text{avg}}^+ = \frac{\sum_{\varphi^+} Q}{\sum_{\varphi^-} N} \left/ \frac{\sum_{\varphi^+} Q}{\sum_{\varphi^-} N} \right. \quad (9)$$

式中:  $\sum_{\varphi^+} Q$ ,  $\sum_{\varphi^-} Q$  分别为正负半周放电量之和;

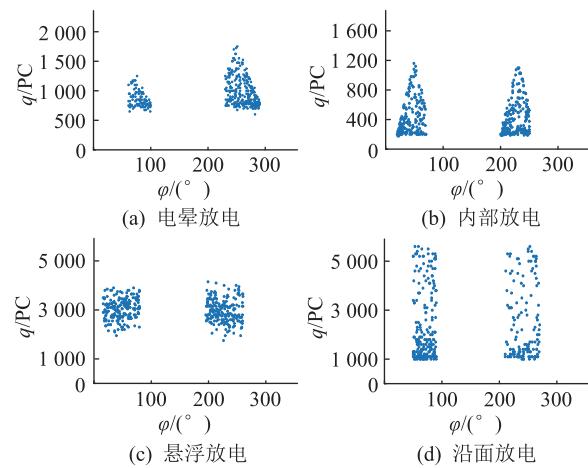


图 4 PRPD 谱图

Fig.4 PRPD

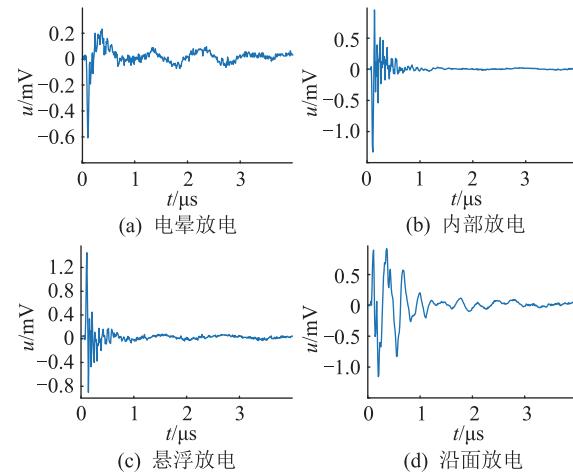


图 5 放电波形

Fig.5 PD waveforms

$\sum_{\varphi^+} N$ ,  $\sum_{\varphi^-} N$  分别为正负半周放电次数之和。

(2) 正负半周相关系数  $C_C$ , 反映 PRPD 谱图正负半周形状的差异, 计算公式如下:

$$C_C = \frac{\text{Cov}(x, y)}{\sqrt{\text{Var}(x) \text{Var}(y)}} = \frac{\sum_{i=1}^m (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^m (x_i - \bar{x}) \sum_{i=1}^m (y_i - \bar{y})}} \quad (10)$$

式中:  $\bar{x}$ ,  $\bar{y}$  分别为变量  $x$  与  $y$  的均值,  $\text{Cov}(x, y)$  为  $x$  与  $y$  的协方差;  $\text{Var}(x)$ ,  $\text{Var}(y)$  分别为  $x$  和  $y$  的方差;  $x_i, y_i$  分别为正负半周对应的相位窗口的放电参量, 文中取各窗口放电量总和;  $m$  为半个周期内相位窗口的个数。

(3) 偏斜度  $S_k^\pm$ , 反映 PRPD 谱图半个周期放电次数和放电量的分布相对于正态分布的偏斜情况, 以正半周为例, 其计算公式为:

$$S_k^+ = \frac{\sum (x_i - \bar{x})^3}{(n-1)\sigma^3} \quad (11)$$

式中: $x_i$ 为第*i*个相位小区间内PD总量;  $\sigma$ 为半个周期内相位概率分布的标准差。

(4) 峰度  $K_u^+$ , 反映PRPD谱图形状分布相对于正态分布的尖峰(陡峭)程度, 以正半周为例, 其计算公式为:

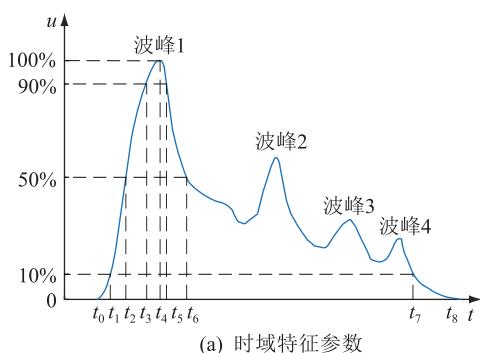
$$K_u^+ = \frac{\sum (x_i - \bar{x})^4}{(n-1)\sigma^4} - 3 \quad (12)$$

波形信号本质为时间序列信息, 其形状变化在一定程度上反映了PD的剧烈程度, 经过快速傅里叶变换后的频域特征也和缺陷类型相关联。提取表1中所列出的典型的时域和频域特征量, 其中部分参量的具体含义如图6所示。所求放电特征量即可作为输入, 对应的放电类型作为输出, 为后续神经网络算法的学习提供样本。

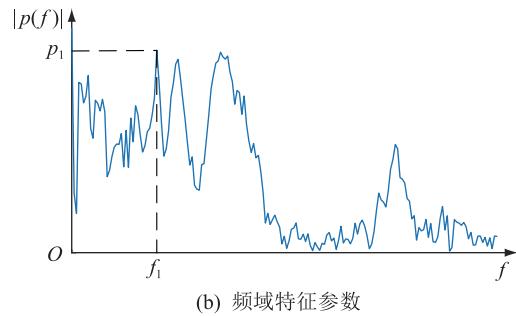
表1 波形信号的时频域特征量

Table 1 Time-domain and frequency features of PD waveforms

特征量	说明
上升时间 $t_u$	脉冲上升过程中瞬时值从峰值的10%至90%经过的时间( $t_3 - t_1$ )
峰值时间 $t_p$	脉冲上升过程中瞬时值从0至峰值经过的时间( $t_4 - t_0$ )
下降时间 $t_d$	脉冲下降过程中瞬时值从峰值的90%至10%经过的时间( $t_7 - t_5$ )
脉冲宽度 $t_w$	脉冲瞬时值从上升沿峰值的50%到下降沿峰值的50%经过的时间( $t_6 - t_2$ )
波峰个数 $N_{tp}$	脉冲时域波形极大值个数
包络面积 $A_t$	脉冲时域波形与时间轴围成面积的绝对值
时域均值 $\mu_t$	脉冲时域波形各采样点绝对值的平均值
时域方差 $\sigma_t^2$	脉冲时域波形各采样点绝对值的方差
主频峰值 $p_1$	频谱图中各频率点幅值中的最大值
主频频率 $f_1$	主频峰值对应的频率
谱峰个数 $N_{fp}$	频谱图中极大值个数
频谱均值 $\mu_f$	频谱各频率点幅值的平均值
频谱方差 $\sigma_f^2$	频谱各频率点幅值的方差



(a) 时域特征参数



(b) 频域特征参数

图6 PD 波形特征参数

Fig.6 Features of PD waveforms

### 3 实验结果与分析

利用第2节模拟实验可以获得PD的PRPD谱图和波形信号图, 因此文中融合ELM算法包含2个子分类器。采集400组PD信号样本, 每种放电类型各100组, 提取相应的PRPD谱图和波形时频域特征值, 从各放电类型中随机选取80组共计320组作为训练样本, 余下共80组数据作为测试样本, 利用文中的融合ELM算法、传统ELM算法和BP神经网络算法进行模式识别, 代码由Matlab R2018a实现。其中, 融合ELM算法中2个子分类器的隐层节点数各为15, 传统ELM算法中隐层节点数为20, BP神经网络为50。考虑到单次测试具有偶然性, 对3种方法分别进行10次测试, 计算平均值作为模式识别的准确率, 结果如表2所示。

表2 不同算法识别准确率

Table 2 Recognition accuracy of different algorithms

算法	识别准确率/%			
	电晕放电	内部放电	悬浮放电	沿面放电
融合ELM	92.5	82.5	87.5	95.0
ELM	92.5	77.5	72.5	92.5
BP神经网络	80.0	67.5	65.0	82.5

由表2可以看出, 融合ELM算法在识别准确率上比传统的ELM算法略有提高, 特别是内部放电和悬浮放电2种放电类型, 原因可能是这2种放电波形具有一定的相似性, ELM算法依靠波形特征参数可能存在误判, 而融合ELM能够在决策融合时自适应地调整各子分类器的权重, 即降低对波形分类结果的置信度, 更多依靠谱图信息做出判断。同时, 融合ELM算法的识别率也远高于BP神经网络。

ELM算法在训练和识别时间上也具有明显优势, 3种方法的平均训练时间为0.318 s, 0.231 s和12.671 s。其中传统ELM算法用时最短, 文中提出的融合ELM次之, 但差距并不明显, 其多余用时主要消耗在权值分配和数据融合阶段。BP神经网

络耗时最长,原因在于BP神经网络通过反复迭代修正连接权值和阈值,而ELM输入层到隐层的权值和阈值随机产生,通过求广义逆矩阵获得隐层到输出层的各参数,无需反复训练修改。3种方法的平均识别时间分别为0.033 s,0.042 s和0.057 s,ELM算法因为隐层节点数少,所以在进行放电测试样本模式识别时运算量比BP神经网络小,运算时间得以缩短。

融合ELM具有较好的算法稳定性,训练样本数量逐渐减少时,3种算法的准确率如图7所示。融合ELM算法的准确率始终保持最高,ELM算法次之,但随着样本数量减少,准确率下降较为明显,总训练样本数为100时,其识别准确率只有68.75%,而BP神经网络准确率一直较低。融合ELM算法在样本数量为100时,准确率还能够保持在77.5%左右,表现出良好的泛化性能。

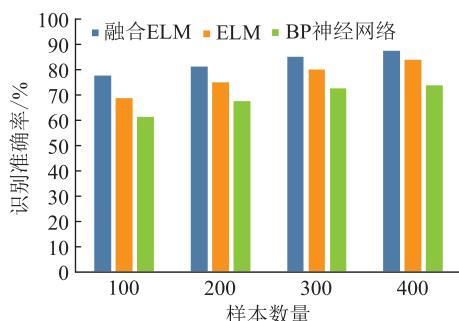


图7 不同大小训练样本集下识别准确率

Fig.7 Recognition accuracy of different size training sample sets

#### 4 结语

融合ELM继承了传统ELM算法训练时间短,学习效率高的优势,在PD模式识别的应用中表现出了良好的性能。文中针对不同类型的PD模型,利用高频电流法获得对应的PRPD谱图和放电脉冲波形,选取合适的特征量作为训练样本。测试结果表明,利用自适应权值分配的决策融合方法,融合ELM算法的识别准确率优于传统的ELM算法,远高于经典的BP神经网络,即使当训练样本数减小时,融合ELM算法还能够具有较强的泛化能力。同时,融合ELM各子分类器中参数维度更小,训练得到的传递矩阵占用内存少,更易移植到实际检测设备上实现应用。

本文得到国网江苏省电力有限公司科技项目(J2018008)资助,谨此致谢!

#### 参考文献:

[1] FOX G H, SUTHERLAND P E. A new standard for electrical

apparatus applications in industry [J]. IEEE Transactions on Industry Applications, 2014, 50(2):1266-1273.

- [2] 王昌长,李福祺,高胜友. 电力设备的在线监测与故障诊断 [M]. 北京:清华大学出版社,2006.  
WANG Changchang, LI Fuqi, GAO Shengyou. On-line monitoring and diagnosis for power equipments [M]. Beijing: Tsinghua University Press, 2006.
- [3] 张煦,张向伍. 计及运行工况影响的电力设备检修策略分析 [J]. 电力系统保护与控制, 2017, 45(1):74-80.  
ZHANG Xu, ZHANG Xiangwu. Comparative analysis on power equipment maintenance strategies considering the effect of operating conditions [J]. Power System Protection and Control, 2017, 45(1):74-80.
- [4] 马钊,周孝信,尚宇炜,等. 未来配电系统形态及发展趋势 [J]. 中国电机工程学报, 2015, 35(6):1289-1298.  
MA Zhao, ZHOU Xiaoxin, SHANG Yuwei, et al. Form and development trend of future distribution system [J]. Proceedings of the CSEE, 2015, 35(6):1289-1298.
- [5] 李军浩,韩旭涛,刘泽辉,等. 电气设备局部放电检测技术述评 [J]. 高电压技术, 2015, 41(8):2583-2601.  
LI Junhao, HAN Xutao, LIU Zehui, et al. Review on partial discharge measurement technology of electrical equipment [J]. High Voltage, 2015, 41(8):2583-2601.
- [6] 徐艳春,王泉,陈国训,等. 基于多重信号分类(MUSIC)算法的变压器局部放电定位研究 [J]. 电网与清洁能源, 2017, 33(3):35-42.  
XU Yanchun, WANG Quan, CHEN Guoxun, et al. Research on partial discharge location of transformers based on multiple signal classification algorithm [J]. Power System and Clean Energy, 2017, 33(3):35-42.
- [7] 朱正国,何斌斌,胡冉,等. 基于卷积神经网络的开关柜局部放电监测 [J]. 电网与清洁能源, 2017, 33(3):17-23.  
ZHU ZhengGuo, HE Binbin, HU Ran, et al. Switch-gear partial discharge detection based on convolutional neural network [J]. Power System and Clean Energy, 2017, 33(3):17-23.
- [8] 唐炬,龚宁淘,李伟,等. 高压交联聚乙烯电缆附件局部放电特性分析 [J]. 重庆大学学报, 2009, 32(5):528-534.  
TANG Ju, GONG Ningtao, LI Wei, et al. Characteristic analysis of partial discharge in high-voltage XLPE cable accessories [J]. Journal of Chongqing University, 2009, 32(5):528-534.
- [9] 程养春,刁常晋,刘少宇,等. 恒定电压下油纸绝缘局部放电发展规律及缺陷状态诊断 [J]. 高电压技术, 2013, 39(5):1061-1068.  
CHENG Yangchun, DIAO Changjin, LIU Shaoyu, et al. Developing laws and severity diagnosis of partial discharge defects on oil-paper insulation [J]. High Voltage, 2013, 39(5):1061-1068.
- [10] High-voltage test techniques: partial discharge measurements: IEC 60270 [S]. Geneva, Switzerland: International Electrotechnical Commission, 2015.
- [11] 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.
- LI Zhengming, QIAN Luxian, LI Jibin. 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.
- [12] 陈焕栩,解浩,张建文,等. 基于灰度共生矩阵纹理特征的局部放电模式识别[J]. 电力系统保护与控制, 2018, 46(5):25-30.
- CHEN Huanxu, XIE Hao, ZHANG Jianwen, et al. Partial discharge pattern recognition based on texture feature of gray level co-occurrence matrix[J]. Power System Protection and Control, 2018, 46(5):25-30.
- [13] 刘凡,张昀,姚晓,等. 基于K近邻算法的换流变压器局部放电模式识别[J]. 电力自动化设备, 2013, 33(5):89-93.
- LIU Fan, ZHANG Yun, YAO Xiao, et al. Recognition of PD mode based on KNN algorithm for converter transformer[J]. Electric Power Automation Equipment, 2013, 33(5):89-93.
- [14] 靖小平,彭小圣,姜伟,等. 基于K-means聚类算法的自动图谱识别在电缆局部放电在线监测系统中的应用[J]. 高电压技术, 2012, 38(9):2437-2446.
- JING Xiaoping, PENG Xiaosheng, JIANG Wei, et al. Phase resolved partial discharge pattern recognition method for on-line cable condition monitoring system based on K-means clustering [J]. High Voltage, 2012, 38(9):2437-2446.
- [15] 杨孝华,廖瑞金,胡建林,等. 基于BP人工神经网络的XLPE电力电缆局部放电的模式识别[J]. 高压电器, 2003(4):35-37.
- YANG Xiaohua, LIAO Ruijin, HU Jianlin, et al. Partial discharge pattern recognition for XLPE power cable based on back-propagation artificial neural network [J]. High Voltage Apparatus, 2003(4):35-37.
- [16] PATTANADECH N, NIMSANONG P, POTIBEJKUL S, et al. Partial discharge classification using probabilistic neural network model[C]//2015 18th IEEE International Conference on Electrical Machines & Systems. Pattaya, Thailand, 2015: 1176-1180.
- [17] 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.
- YAN 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.
- [18] 陆国俊,熊俊,李光茂,等. 振荡波电压下XLPE电缆局部放电模式识别研究[J]. 高压电器, 2017, 53(2): 95-100, 107.
- LU Guojun, XIONG Jun, LI Guangmao, et al. Pattern recognition of XLPE cable partial discharge under oscillating voltage [J]. High Voltage Apparatus, 2017, 53(2): 95-100, 107.
- [19] 尚海昆,苑津莎,王瑜,等. 多核多分类相关向量机在变压器局部放电模式识别中的应用[J]. 电工技术学报, 2014, 29(11):221-228.
- SHANG Haikun, YUAN Jinsha, WANG Yu, et al. Partial discharge pattern recognition in power transformer based on multi-kernel multi-class relevance vector machine[J]. Transactions of China Electrotechnical Society, 2014, 29(11): 221-228.
- [20] BHASKAR K, SINGH S N. AWNN-assisted wind Power forecasting using feed-forward neural network[J]. IEEE Transactions on Sustainable Energy, 2012, 3(2): 306-315.
- [21] SUNITHA R, KUMAR S K, MATHEW A T. Online static security assessment module using artificial neural networks[J]. IEEE Transactions on Power Systems, 2013, 28(4): 4328-4335.
- [22] 王欣,梁辉,秦斌. 基于OSELM的无刷直流电机无位置传感器控制[J]. 电机与控制学报, 2018(11):82-88.
- WANG Xin, LIANG Hui, QIN Bin. Sensorless control for brushless DC motors based on OSELM[J]. Electric Machines and Control, 2018(11):82-88.
- [23] 胥威汀,刘俊勇,唐权,等. 含风电系统断面TTC运行规则的极限学习机提取方法[J]. 电力系统保护与控制, 2018, 46(23):135-142.
- XU Weiting, LIU Junyong, TANG Quan, et al. Extreme learning machine-based estimation of total transfer capability of transmission corridors in wind-integrated power systems[J]. Power System Protection and Control, 2018, 46(23):135-142.
- [24] 林锐涛,潘可达,许韩斌,等. 基于用户电量特征匹配与鲁棒极限学习机的用户短期电量预测[J]. 智慧电力, 2018, 46(11):76-82.
- LIN Ruitao, PAN Keda, XU Hanbin, et al. Short-term electricity consumption forecasting for power consumers based on outlier robust extreme learning machine and electricity consumption characteristics of similarity customers [J]. Smart Power, 2018, 46(11):76-82.
- [25] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine:a new learning scheme of feedforward neural networks [C]//2004 IEEE International Joint Conference on Neural Networks. Budapest, Hungary, 2004:985-990.
- [26] HUANG G B, CHEN L, SIEW C K. Universal approximation using incremental constructive feedforward networks with random hidden nodes [J]. IEEE Transactions on Neural Network, 2006, 17(4):879-892.
- [27] YANG J, YANG J Y, ZHANG D, et al. Feature fusion: parallel strategy vs. serial strategy[J]. Pattern Recognition, 2003, 36(6):1369-1381.
- [28] 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.
- 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.
- [29] 刘蓉,李继胜,田维坚,等. XLPE电力电缆典型缺陷局部放电测量与分析[J]. 高压电器, 2015, 51(2):44-50.
- LIU Rong, LI Jisheng, TIAN Weijian, et al. Measurement and

- analysis of partial discharge on typical defects in XPLE power cable [J]. High Voltage Apparatus, 2015, 51(2): 44-50.
- [30] 魏振, 张强, 齐波, 等. 高压开关柜典型缺陷局部放电TEV特征的研究[J]. 高压电器, 2014, 50(2): 60-67.
- WEI Zhen, ZHANG Qiang, QI Bo, et al. Analysis of TEV caused by partial discharge of typical faults in HV switchgear [J]. High Voltage Apparatus, 2014, 50(2): 60-67.
- [31] 郭灿新, 张丽, 钱勇, 等. XLPE 电力电缆中局部放电检测及定位技术的研究现状[J]. 高压电器, 2009, 45(3): 56-60.
- GUO Canxin, ZHANG Li, QIAN Yong, et al. Current status of partial discharge detection and location techniques in XLPE power cable [J]. High Voltage Apparatus, 2009, 45(3): 56-60.
- [32] 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, 2017, 43(7): 2263-2277.

#### 作者简介:



潘志新

潘志新(1974),男,学士,高级工程师,从事配电设备运维检修工作(E-mail: pzx\_t@sina.com);

刘利国(1983),男,学士,高级工程师,从事配电设备运维检修工作;

钱程(1995),男,博士在读,研究方向为配  
电设备大数据及智能运维。

## Pattern recognition of partial discharge based on fusion extreme learning machine

PAN Zhixin<sup>1</sup>, LIU Liguang<sup>1</sup>, QIAN Cheng<sup>2</sup>, WANG Zhen<sup>3</sup>, YUAN Dong<sup>1</sup>

(1. State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210024, China;

2. School of Electrical Engineering, Southeast University, Nanjing 210096, China;

3. Wuxi Power Supply Company of State Grid Jiangsu Electric Power Co., Ltd., Wuxi 214012, China)

**Abstract:** Partial discharge is the main form of early insulation failure of electrical equipment. Pattern recognition of discharge type is of great significance for the estimation of equipment insulation performance. Considering that the extreme learning machine (ELM) method has the advantages of simple structure and fast training speed, yet the initial parameter selection is random and the algorithm is unstable. A pattern recognition method based on fusion ELM algorithm for partial discharge is proposed. Considering the different judgement precisions based on variable features, the adaptive weight assignment is used to achieve the decision-level fusion of the output. In this paper, four physical discharge models are designed to simulate typical partial discharge defects. Discharge signal waveform and phase-amplitude spectrum is collected by high-frequency current transformer method, sufficient samples of experiment data are obtained to extract time-frequency domain and statistical features for classification. The result shows that the fusion ELM algorithm is superior to the traditional ELM algorithm and BP neural network in the recognition accuracy and stability without sacrificing training speed.

**Keywords:** partial discharge; pattern recognition; extreme learning machine; data fusion; distribution equipment

(编辑 方晶)