

# 基于图像处理及降噪的局部放电图谱智能识别方法

朱旭亮<sup>1</sup>, 刘创华<sup>2</sup>, 何金<sup>1</sup>, 宋晓博<sup>1</sup>, 陈荣<sup>1</sup>, 邢向上<sup>1</sup>

(1. 国网天津市电力公司电力科学研究院, 天津 300384; 2. 国网天津市电力公司, 天津 300232)

**摘要:**局部放电检测是目前电力设备状态评价的主要手段, 得到广泛应用推广。由于缺陷图谱的复杂性及现场干扰的多样性, 传统的局部放电模式识别方法正确率低, 且训练时间长。针对上述问题, 文章提出了一种基于图像处理技术及数据深度稀疏降噪的电力设备局部放电图谱智能识别方法。首先, 运用图像处理技术对检测得到的图谱进行预处理; 然后利用深度稀疏降噪自编码器进行数据稀疏降噪; 最后对得到的有效去噪的数学模型, 利用极限学习机(ELM, Extreme Learning Machine)网络, 实现对局部放电的智能分类和识别。利用在变电站现场实测数据对本方法进行验证, 证明本方法对含有多样干扰的局部放电信号有更好的识别效果, 能很好适用于目前的电力设备图像信息模式识别应用当中。

**关键词:**局部放电; 数据处理技术; 深度稀疏降噪; 极限学习机; 模式智能识别

**文章编号:**2096-4633(2018)11-0050-07 **中图分类号:**TM8 **文献标志码:**B

随着我国电网智能化进程的深入开展, 人们对电能质量的要求日益提高。凭借能够及时发现高压设备的内部缺陷, 避免局部放电引发电力故障的功能作用<sup>[1-3]</sup>, 状态检测技术的重要性越发突显。状态检测图像信息的价值挖掘利用, 紧迫且重要。专家学者在电力高压设备局部放电的模式识别和故障诊断方面, 开展了广泛的研究, 主要集中在局部放电检测数据特征量的提取<sup>[4]</sup>, 依据时间、相位数据, 如局部放电时间分布(TRPD)、脉冲序列相位分布(PRPS)和局部放电相位分布(PRPD)等<sup>[5-6]</sup>, 提取统计特征值进行缺陷判断识别。目前变电站现场局部放电检测中使用的仪器多样, 现有存储的局部放电数据多以图像的形式存在, 基于特征值的局部放电模式识别方法无法广泛适用于非结构化数据中。

另外, 变电站现场复杂的电磁环境, 使得检测受到各种干扰影响, 降低了基于特征值模式识别方法的识别正确率。传统学习识别算法, 例如BP神经网络<sup>[7]</sup>和支持向量机(Support Vector Machine, SVM)方法<sup>[8]</sup>都需要反复迭代阈值、权重, 大大增加了训练时间。这使得这些模式识别在实际应用受到限制。

基于上述情况, 本文研究了一种对局部放电图像信息数据的智能放电图谱模式识别方法: 首先采用图像处理技术, 分割、二值化等预处理图像数据, 然后深度稀疏降噪图像信息, 最后利用极限学习机

(Extreme Learning Machine, ELM)分类方法进行智能模式识别分类。

## 1 局部放电图谱处理

针对局部放电图谱的处理包括: 图像分割提取、图像灰度化、图像二值化、图像压缩<sup>[9-10]</sup>。

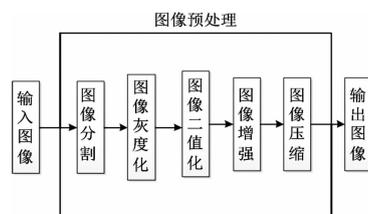


图1 图像预处理

Fig. 1 Pretreatment of waveform image

### 1.1 图像分割提取

根据图像特点对图像进行分割提取, 去除通道、标识等无关信息, 最终得到只含脉冲电压的图像。

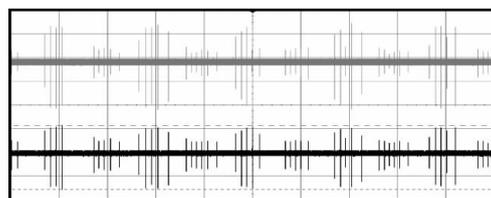


图2 波形图像分割

Fig. 2 Segmentation of time-domain waveform image

### 1.2 图像灰度化

得到的彩色图像由 R、G、B 三个通道的颜色分

$$f_1(i,j) = R(i,j); f_2(i,j) = G(i,j); f_3(i,j) = B(i,j) \quad (1)$$

其中  $f_k(i,j)$  ( $k = 1,2,3$ )  $f_k(i,j)$  ( $k = 1,2,3$ ) 为转换后的灰度图像在  $(i,j)$  处的灰度值。灰度图如图 3、4、5 所示。

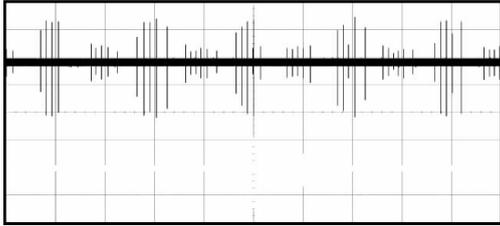


图 3 波形图像灰度图(R 通道)

Fig. 3 Grayscale image of time-domain waveform image(R channel)

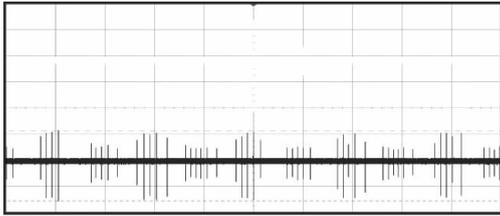


图 4 波形图像灰度图(G 通道)

Fig. 4 Grayscale image of time-domain waveform image(G channel)

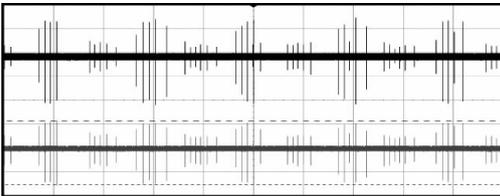


图 5 波形图像灰度图(B 通道)

Fig. 5 Grayscale image of time-domain waveform image(B channel)

### 1.3 图像二值化

对灰度图进行全局二值化操作,如下式(2):

$$g(x,y) = \begin{cases} 0, & f(x,y) < T \\ 1, & f(x,y) \geq T \end{cases} \quad (2)$$

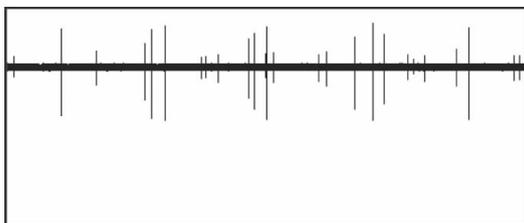


图 6 波形图像二值图

Fig. 6 Binary image of time-domain waveform image

量构成,采用分量法对彩色图像进行灰度化处理,如下式(1):

去除图像中的干扰通道与其他无关信息,只提取保留得到绿色通道。操作得到的二值图如图 6 所示。

### 1.4 图像压缩

通过图像二值化,得到 9 000 张时域波形图像。由于识别实验平台配置有限,本文将预处理得到的时域波形图像统一压缩尺寸成  $96 \times 96$  的图像。

对输入的局部放电波形图像进行图像预处理后,对得到的图像数据进行深度稀疏降噪。

## 2 深度稀疏降噪

Hinton 于 2006 年提出了数据降噪深度学习的思想,通过构造含有多层隐含层的神经网络,特征映射数据,获取数据深层本质信息。栈式自动编码器(stacked AutoEncoder, SAE)作为深度学习结构的重要组成部分,能够提取目标数据更深层次的特征,挖掘数据本质信息。

### 2.1 自编码器

自动编码器是一种无监督的学习算法,其结构图如图 7 所示,它通过让目标值与输入值相等,即  $y^{(i)} = x^{(i)}$ ,用来学习能够恢复自身的非线性编码。

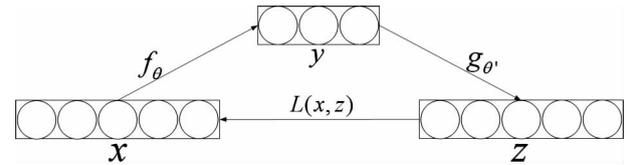


图 7 自编码器结构图

Fig. 7 AutoEncoder structure diagram

假如给定一个无标签的数据集  $\{x^{(i)}\}_{i=1}^m$ , 其每一个训练数据  $x^{(i)}$  经编码器操作,可得到隐含层的特征表达  $y^{(i)}$ ,  $y^{(i)} = f_{\theta}(x^{(i)}) = s(Wx^{(i)} + b)$ , 其中  $\theta = (W, b)$  为网络参数,  $W$  为权值矩阵,  $b$  为偏置向量,  $s(x)$  为激活函数,本文选用 sigmoid 函数,  $s(x) = 1/(1 + e^{-x})$ 。然后隐含层的特征表达经过解码器操作,得到重构向量  $z^{(i)}$ ,  $z^{(i)} = g_{\theta'}(y^{(i)}) = s(W'y^{(i)} + b')$ , 其中  $\theta' = (W', b')$ ,  $W'$  为权值矩阵,取  $W' = W^T$ 。则模型实际上需要最小化代价函数(本文采用交叉熵代价函数,优于平方差代价函数):

$$J_1 = -\frac{1}{m} \sum_{i=1}^m \sum_{j=1}^n (x_j^{(i)} \log z_j^{(i)} + (1 - x_j^{(i)}) \log(1 - z_j^{(i)})) \quad (3)$$

为了防止过拟合情况出现,需要对代价函数添加一个正则化,得到的代价函数为:

$$J_1' = -\frac{1}{m} \sum_{i=1}^m \sum_{j=1}^n (x_j^{(i)} \log z_j^{(i)} + (1 - x_j^{(i)}) \log(1 - z_j^{(i)})) + \frac{\lambda}{2} \|W\|^2 \quad (4)$$

### 2.2 稀疏自编码器

Bengio 于 2007 年提出了稀疏自编码器 (Sparse AutoEncoder, SAE), 在 AE 基础上添加稀疏约束条件, 要求大部分节点为 0, 从而有更好的鲁棒性和高效性<sup>[10-11]</sup>。SAE 代价函数为:

$$J_{sparse} = J_1' + \beta \sum_{j=1}^{s_2} KL(\rho || \hat{\rho}_j) \quad (5)$$

其中,  $s_2$  是隐含层神经元数量,  $KL(\rho || \hat{\rho}_j) = \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j}$ 。  $\rho$  是稀疏性参数, 通常是一个接近于 0 的较小的值。当稀疏性限制  $\hat{\rho}_j = \rho$  时,  $KL(\rho || \hat{\rho}_j)$  达到最小值 0, 当  $\hat{\rho}_j$  接近 0 或者 1 时,  $KL(\rho || \hat{\rho}_j)$  急剧增大。所以在代价函数中加入此项,

$$J = -\frac{1}{m} \sum_{i=1}^m \sum_{j=1}^n (x_j^{(i)} \log z_j^{(i)} + (1 - x_j^{(i)}) \log(1 - z_j^{(i)})) + \frac{\lambda}{2} \|W\|^2 + \beta \sum_{j=1}^{s_2} KL(\rho || \hat{\rho}_j) \\ = -\frac{1}{m} \sum_{i=1}^m \sum_{j=1}^n (x_j^{(i)} \log(g_{\theta}(f_{\theta}(\tilde{x}_j^{(i)}))) + (1 - x_j^{(i)}) \cdot \log(1 - g_{\theta}(f_{\theta}(\tilde{x}_j^{(i)})))) + \frac{\lambda}{2} \|W\|^2 + \beta \sum_{j=1}^{s_2} KL(\rho || \hat{\rho}_j) \quad (6)$$

### 2.4 深度稀疏降噪自编码器

深度稀疏降噪自编码器是由多个 SDAE 堆叠而成。因此, 深度 SDAE 可以得到输入数据更深信息量更大的特征。在学习过程中, 后一层网络利用前一层网络的输出作为输入, 逐层训练。首先用染噪输入数据训练第 1 个稀疏降噪自编码器 SDAE, 得到输入数据的 1 阶特征表示  $h_k^{(1)}$ , 然后将该特征表示作为下一个 SDAE 的输入, 得到 2 阶特征表示  $h_k^{(2)}$ , 依次类推, 将第  $(n - 1)$  阶特征表示作为第  $n$  个降噪稀疏自编码器的输入, 得到  $n$  阶特征表示  $h_k^{(n)}$ 。本文采用 4 层隐含层的深度 SDAE 网络。

## 3 极限学习机 (Extreme Learning Machine, ELM)

而新型的单隐含层神经网络——极限学习机 (Extreme Learning Machine, ELM) 作为分类器, 因其输入层与隐含层间的连接权值和隐含层神经元的阈值是随机产生的, 无需在训练过程中迭代和调整, 具有学习速率快和泛化性能好等优点<sup>[13-15]</sup>。

ELM 由输入层、单隐含层和输出层组成, 输入层与隐含层间的连接权值和隐含层神经元的阈值是随机产生的, 无需在训练过程中迭代和调整<sup>[16]</sup>。设有  $n$

可以使得  $\hat{\rho}_j$  更加接近于  $\rho$ 。  $\beta$  为稀疏值惩罚相的权重。

### 2.3 稀疏降噪自编码器

稀疏降噪自编码器 (Sparse Denoising AutoEncoder, SDAE) 是在 SAE 基础上, 使编码器学习去除输入数据中的噪声, 从而提高 SAE 的泛化能力和模型的鲁棒性<sup>[12]</sup>。SDAE 结构图如图 8 所示。

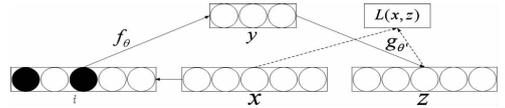


图 8 稀疏降噪自编码器结构图

Fig. 8 Sparse Denoising AutoEncoder structure diagram

图 8 中,  $x$  为原始输入数据,  $\tilde{x}$  为染噪的输入数据。稀疏降噪自编码器网络代价函数为:

个样本数据  $X = [x_1, x_2, \dots, x_n]^T$ ,  $x_i \in R^Q$ ,  $Q$  为输入特征向量的维数。输出矩阵为  $T = [t_1, t_2, \dots, t_n]^T$ ,  $t_i \in R^S$ ,  $S$  为输出向量的维数。设隐含层激活函数为  $g(x)$ , 随机产生输入层到隐含层的权值和阈值  $(w_i, b_i)$ ,  $w_i, b_i \in (-1, 1)$ ,  $i = 1, 2, \dots, \bar{N}$ ,  $\bar{N}$  为隐含层神经元个数。则隐含层输出为:

$$H = \begin{bmatrix} g(w_1 x_1 + b_1) & \cdots & g(w_{\bar{N}} x_1 + b_{\bar{N}}) \\ \vdots & \ddots & \vdots \\ g(w_1 x_n + b_1) & \cdots & g(w_{\bar{N}} x_n + b_{\bar{N}}) \end{bmatrix}_{n \times \bar{N}} \quad (7)$$

希望求得满足  $\|H\beta - T\|$  最小的  $\beta$ 。其中  $\beta$  为隐含层与输出层的连接权值。Huang 教授等人给出了两个定理<sup>[17-18]</sup>, 从理论上证明了任意区间无限可微的激活函数  $g(x)$ ,  $R \rightarrow R$ , 在随机赋值输入层到隐含层的权值矩阵  $w_i$  和阈值  $b_i$  的情况下, 当隐含层神经元个数与训练样本数据个数相同时,  $H$  广义可逆, 且存在  $\beta$  使得  $\|H\beta - T\| = 0$ , 从而可以求得:

$$\beta = H^{-1} T \quad (8)$$

## 4 识别结果与对比分析

本文提出了一种基于图像处理技术及数据深度

稀疏降噪的电力设备局部放电图谱智能识别方法,经图像处理和深度稀疏降噪,利用 ELM 作为分类器,配置酷睿 i7 处理器 3.7GHz,内存 8GB 实验平台,采用 Matlab 代码。分类目标 6 类,分别为:“悬浮电极缺陷”、“尖端电晕缺陷”、“气隙放电缺陷”、“沿面放电缺陷”,共计 9 000 组数据。随机选取 6 000 组作为训练学习样本训练 ELM、SVM 和 BPNN,余下的 3 000 组数据作为模式识别测试样本分别测试上述算法的识别结果,ELM 算法设置隐含层数  $L$  为 25(等于特征向量的维数),绘制出识别结果混淆矩阵。识别结果如表 1、2、3 所示。缺陷类别数据中对角线单元格内的数据表示预测类别与实际类别相符的样本数;对角线两侧单元格内的数据表示错误识别的样本数;最后一行为精确率(衡量预测系统

的查准率,指正确预测的样本数/预测的样本数);最后一列为召回率(衡量预测系统的查全率,指正确预测的样本数/实际的样本数);右下角召回率和精确率交汇处的单元格为总的识别正确率。

由表 1、表 2 和表 3 可以看出,ELM 的识别正确率最高,且精确率和召回率均很高(超过 89%),即查准率和查全率很高。相比之下 SVM 和 BPNN 不但识别正确率低于 ELM,而且出现了部分精确率或召回率很低(低于 80%)的情况。对比可知,ELM 用于局部放电的模式识别有很好的效果。由于训练数据样本是随机选择的,因而单次测试可能具有偶然性,本文对 ELM、SVM 和 BPNN 分别进行了 50 次测试,求得平均识别正确率和训练时间,结果如表 4 所示。

表 1 ELM 模式识别结果

Tab. 1 Pattern recognition result of ELM

		预测类别				
		尖端电晕	悬浮放电	绝缘气隙	沿面放电	召回率
实际类别	尖端电晕	703	5	5	0	98.60%
	悬浮放电	0	713	15	17	95.70%
	绝缘气隙	5	27	731	36	91.49%
	沿面放电	0	7	35	701	94.35%
	精确率	99.29%	94.81%	93.00%	92.97%	94.93%

表 2 SVM 模式识别结果

Tab. 2 Pattern recognition result of SVM

		预测类别				
		尖端电晕	悬浮放电	绝缘气隙	沿面放电	召回率
实际类别	尖端电晕	701	4	2	2	98.87%
	悬浮放电	0	655	44	9	92.51%
	绝缘气隙	1	51	673	15	90.95%
	沿面放电	0	26	106	711	84.34%
	精确率	99.86%	88.99%	81.58%	96.47%	91.33%

表 3 BPNN 模式识别结果

Tab. 3 Pattern recognition result of BPNN

		预测类别				
		尖端电晕	悬浮放电	绝缘气隙	沿面放电	召回率
实际类别	尖端电晕	619	37	62	11	84.91%
	悬浮放电	35	626	51	22	85.29%
	绝缘气隙	55	27	601	41	83.01%
	沿面放电	35	35	46	697	85.73%
	精确率	83.20%	86.34%	79.08%	90.40%	84.77%

表 4 3 种算法的模式识别正确率和训练时间比较

Tab. 4 Comparison of pattern recognition efficiency and training time of three algorithms

算法	训练集正确率/%	测试集正确率/%	训练时间/s
ELM	95.12	94.93	0.019891
SVM	92.89	91.33	1109.147892
BPNN	93.25	84.77	43.893451

由表 4 可知,ELM 相比识别正确率略高于 SVM,平均识别正确率远远超过了 BPNN。在相同训练样本情况下,SVM 由于交叉验证,其训练时间为 ELM 的 55761 倍,BPNN 训练时间为 ELM 的 2207 倍。ELM 算法相比 SVM 和 BPNN 算法有着极大的优势。所以本文使用 ELM 作为分类器,实现局部放电图谱的智能分类、识别。

### 5 结论

本文使用图像处理方法对局部放电波形图像进行预处理,基于深度稀疏降噪,利用极限学习机 ELM 作为分类器进行图像数据模式智能识别。结果表明:

- (1)图像处理方法可以读取预处理格式广泛的局部放电图像信息;
- (2)基于深度稀疏降噪的图像数据信息,可以有效去除部分现场干扰噪声对模式识别的影响;
- (3)将 ELM 作为分类器,进行训练学习,无需在训练过程中迭代和调整,具有学习速率快和泛化性能好等优点

本文所提的基于图像处理及降噪的电力设备局部放电图谱智能识别方法,能有效去除图像数据噪声干扰进而提高模式识别正确率,提高训练速度,降低学习时间,适用性强,前景广泛。

#### 参考文献:

[1] 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(08):2583-2601.  
 LI Junhao, HAN Xutao, LIU Zehui, et al. Review on partial discharge measurement technology of electrical equipment [J]. High Voltage Engineering,2015,41(08):2583-2601.

[2] 李军浩,郭飞,张亮,等. 变压器感应式振荡型操作冲击试验及局部放电测量技术[J]. 高电压技术,2016,42(04):1199-1206.  
 LI Junhao, GUO Fei, ZHANG Liang, et al. Inductive oscillating switching impulse test and partial discharge detection technology

for transformer[J]. High Voltage Engineering. 2016,42(04):1199-1206.

[3] 李军浩,司文荣,姚秀,等. 油/纸绝缘沿面局部放电特性研究[J]. 西安交通大学学报,2009,43(06):108-112.  
 LI Junhao, SI Wenrong, YAO Xiu, et al. Partial discharge characteristics over oil/paper interface [J]. Journal of Xi'an Jiao Tong University. 2009,43(06):108-112.

[4] 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.

[5] 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):947-955.  
 Huang Liang, Tang Ju, Ling Chao, et al. Pattern recognition for partial discharge based on multi-feature fusion technology [J]. High Voltage Engineering,2015,41(3):947-955.

[6] 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.  
 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.

[7] 律方成,张波. 基于 LLE 降维和 BP\_Adaboost 分类器的 GIS 局部放电模式识别[J]. 电测与仪表,2014,51(15):37-41.  
 LV Fangcheng, ZHANG Bo. Pattern recognition of GIS discharge types based on LLE dimensionality reduction and BP\_Adaboost classifier [J]. Electrical Measurement & Instrumentation, 2014, 51(15):37-41.

[8] 陶新民,李震,刘福荣,等. 基于精简集支持向量机的变压器故障检测方法[J]. 高电压技术,2016,42(10):3199-3206.  
 TAO Xinmin, LI Zhen, LIU Furong, et al. Fault detection method for power transformer based on SVM using reduced vector set [J]. High Voltage Engineering,2016,42(10):3199-3206.

[9] 曹健,魏星,李海生,等. 基于局部特征的图像分类方法[J]. 电子科技大学学报,2017,46(1):69-74.  
 CAO Jian, WEI Xing, LI Haisheng, et al. Image classification methods based on local features [J]. Journal of university of electronic science and technology of china,2017,46(1):69-74.

[10] WU R, YAN S, SHAN Y, et al. Deep image: Scaling up image recognition [J]. Computer Science,2015,7(8).

- [11] 曾安,张艺楠,潘丹,等. 基于稀疏降噪自编码器的深度置信网络[J]. 计算机应用,2017,37(9):2585-2589.  
ZENG An,ZHANG Yinan,PAN Dan, et al. Deep belief networks based on sparse denoising auto encoders[J]. Journal of Computer Applications,2017,37(9):2585-2589.
- [12] Xing C, Ma L, Yang X. Stacked denoise autoencoder based feature extraction and classification for hyperspectral images[J]. Journal of Sensors,2016,2016(1):1-10.
- [13] 贾伟,华庆一,张敏军,等. 改进极限学习机的移动界面模式半监督分类[J]. 计算机工程与应用,2018,54(02):11-19.  
JIA Wei, HUA Qingyi, ZHANG Minjun, et al. Semi-supervised classification of mobile interface pattern using improved extreme learning machine. Computer Engineering and Applications,2018,54(2):11-19.
- [14] 张炆,汪洋,祝宇翔,等. 基于 PAM 和 ELM 的电力短期负荷预测相似日选取算法[J]. 电力大数据,2017,20(12):84-87.  
ZHANG Yang, WANG Yang, ZHU Yuxiang, et al. Similarity day selection algorithm for power short-term load forecasting [J]. Power Systems and Big Data,2017,20(12):84-87.
- [15] Zeng Y, Xu X, Fang Y, et al. Traffic sign recognition using deep convolutional networks and extreme learning machine [C]// International Conference on Intelligent Science and Big Data Engineering. Springer, Cham,2015:272-280.
- [16] 苑津莎,张利伟,王瑜,等. 基于极限学习机的变压器故障诊断方法研究[J]. 电测与仪表,2013(12):21-26.  
YUAN Jinsha, ZHANG Liwei, WANG Yu, et al. Study of transformers fault diagnosis based on extreme learning machine [J]. Electrical Measurement & Instrumentation,2013(12):21-26.
- [17] LIANG N Y, HUANG G B, SARATCHANDRAN P, et al. A fast and accurate online sequential learning algorithm for feedforward networks. [J]. IEEE Transactions on Neural Networks,2006,17(6):1411-1423.
- [18] HUANG G B, CHEN L, SIEW C K. Universal approximation using incremental constructive feedforward networks with random hidden nodes[J]. IEEE Transactions on Neural Networks,2006,17(4):879-92.
- [19] 徐德荣,陈秀宏,田进. 稀疏自编码和 Softmax 回归的快速高效特征学习[J]. 传感器与微系统,2017,36(5):55-58.  
XU Derong, CHEN Xiuhong, TIAN Jin. Fast and efficient feature learning algorithm based on sparse autoencoder and Softmax regression[J]. Transducer and Microsystem Technologies,2017,36(5):55-58.
- [20] 张千千,张卫东,毕凯,等. 变电站局部放电区域检测与精确定位方法研究[J]. 电气自动化,2016,(03):108-110.  
ZHANG Qianqian, ZHANG Weidong, BI Kai, et al. A research on regional detection and precise location of partial discharge in substations[J]. Electrical Automation,2016,(03):108-110.
- [21] 许永鹏,杨丰源,钱勇,等. 基于改进 ECOC 分类器的直流电缆终端接头局放模式识别[J]. 中国电机工程学报,2017,37(4):1260-1267.  
XU Yongpeng, YANG Fengyuan, QIAN Yong, et al. Pattern Recognition of PD in DC Cable Terminal Joint Based on the Improved ECOC Classifier[J]. Proceedings of the CSEE,2017,37(4):1260-1267.
- [22] 戴庚,耿诗尧. 基于最小二乘支持向量机的 SOC 估计方法[J]. 信息与电脑(理论版),2018(02):31-32.  
DAI Geng, GENG Shiyao. SOC Estimation Based on Least Squares Support Vector Machines [J]. China Computer & Communication,2018(02):31-32.
- [23] CORTES CVV, C CORTESEVAPNIK V., et al. Support-vector networks[J]. Machine Learning,1995,20:273-297.
- [24] 张松兰. 支持向量机的算法及应用综述[J]. 江苏理工学院学报,2016,22(2):14-17.  
ZHANG Songlan. A survey of improved algorithm and application on support vector machine [J]. Journal of Jiangsu University of Technology,2016,22(2):14-17.
- [25] 王继东,宋智林,冉冉. 基于改进支持向量机算法的光伏发电短期功率滚动预测[J]. 电力系统及其自动化学报,2016,28(11):9-13.  
Wang Jidong, Song Zhilin, Ran Ran. Short-term photovoltaic power generation rolling forecast based on optimized SVM [J]. Proceedings of the CSU-EPSA,2016,28(11):9-13.

收稿日期:2018-09-18

作者简介:



朱旭亮(1989),男,汉族,硕士,工程师。主要从事高电压与绝缘技术方面的研究工作。

(本文责任编辑:龙海丽)

## Partial discharge pattern intelligent recognition algorithm based on image processing and noise reduction

ZHU Xuliang<sup>1</sup>, LIU Chuanghua<sup>2</sup>, HE jin<sup>1</sup>, SONG Xiaobo<sup>1</sup>, CHEN Rong<sup>1</sup>, XING Xiangshang<sup>1</sup>

(1. State Grid Tianjin Electric Power Research Institute, Tianjin 300384, China;

2. State Grid Tianjin Electric Power Company, Tianjin 300232, China)

**Abstract:** Partial discharge (PD) detection is the main means of power equipment status evaluation at present. Due to the complexity of defect map and the diversity of field interference, the traditional local discharge pattern recognition method has low recognition accuracy and long training time. Based on these problems, an intelligent recognition method of partial discharge map of power equipment based on image processing technology and sparse data depth de-noising is proposed in this paper. Firstly, image processing technology is used to preprocess the detected image data. Then the active de-noising is carried out by using the deep sparse de-noising self-encoder. Finally, extreme learning machine is used as classifier to realize intelligent classification and identification of partial discharge. Using this method to verify the measured data at the scene of the substation, prove that the method of partial discharge signals containing various interference has better recognition effect, can apply to the current electric power equipment images information pattern recognition applications.

**Key words:** partial discharge; image processing; deep sparse de-noising; extreme learning machine; pattern intelligent recognition