

DOI: 10.13382/j.jemi.B2306683

# 基于 Choi-Williams 分布和排列熵的开关柜 局部放电类型识别\*

王 非<sup>1,2</sup> 徐 伟<sup>1,2</sup>

(1. 南京信息工程大学气象灾害预报预警与评估协同创新中心 南京 210044;  
2. 南京信息工程大学江苏省气象探测与信息处理重点实验室 南京 210044)

**摘 要:**开关柜局部放电类型识别对了解绝缘状态并及时维护有着重要的指导意义。局部放电类型识别的关键在于提取局部放电信号的特征。提出一种 Choi-Williams 分布与排列熵相结合的局部放电超声信号的特征提取方法,利用 Choi-Williams 分布获得局部放电超声信号的时频特征,求解局部放电超声信号的排列熵,得到信号时间序列的复杂度特征量,与时域特征量组合成特征向量,使用粒子群算法优化的 BP 神经网络对放电信号进行分类识别。实测数据分析表明,该方法对放电类型识别的准确率达到了 96.67%,相较于传统的分形和时频分析方法,分别提高了 11.67% 和 1.67%。

**关键词:**局部放电;超声波;崔-威廉斯分布;排列熵

**中图分类号:** TM591 **文献标识码:** A **国家标准学科分类代码:** 470.40

## Partial discharge type identification of switchgear based on Choi-Williams distribution and permutation entropy

Wang Fei<sup>1,2</sup> Xu Wei<sup>1,2</sup>

(1. Collaborative Innovation Center on Forecast and Evaluation of Meteorological Disasters, Nanjing University of Information Science & Technology, Nanjing 210044, China; 2. Jiangsu Key Laboratory of Meteorological Observation and Information Processing, Nanjing University of Information Science & Technology, Nanjing 210044, China)

**Abstract:** The identification of partial discharge type of switchgear has important guiding significance for understanding the insulation state and timely maintenance. The key to partial discharge type identification is to extract the characteristics of the partial discharge signal. A feature extraction method for partial discharge ultrasonic signals combining Choi-Williams distribution and permutation entropy is proposed, the time-frequency characteristics of partial discharge ultrasonic signals are obtained by using Choi-Williams distribution, the permutational entropy of partial discharge ultrasonic signals is solved, the complexity feature quantity of signal time series is obtained, the time domain and complexity features are composed into feature vectors, and the BP neural network optimized by particle swarm optimization is used to classify and identify discharge signals. The measured data analysis shows that the accuracy of the method for the identification of discharge type reaches 96.67%, which is 11.67% and 1.67% higher than the traditional fractal and time-frequency analysis methods, respectively.

**Keywords:** partial discharge; ultrasonic; Choi-Williams distribution; permutation entropy

## 0 引 言

高压开关柜由于高压、过载、工作环境潮湿等因素的影响,内部的绝缘材料逐渐劣化,进而产生局部放电现象。开关柜局部放电是一种微弱的放电现象,通常有针

板放电、悬浮放电、沿面放电等多种放电类型。不同类型的局部放电信号特征不同,对开关柜产生的影响也不同,可通过局部放电类型识别为放电风险评估提供可靠的参考信息,有助于对开关柜进行有效的检测和维修。

局部放电类型识别的关键之一在于局部放电特征的提取,目前已有多种特征提取方法。2011 年任先文等<sup>[1]</sup>

利用检测电阻,采集了局部放电脉冲电流信号,并采用分形特征提取了局部放电脉冲电流信号的分形维数特征量,但是采集到的信号长度对分形维数的计算影响较大。2015 年律方成等<sup>[2]</sup>使用超高频传感器,采集了开关柜局部放电超高频信号,用统计特征提取了局部放电超高频信号的 26 个特征参量,但是由该方法得到的特征量维数较高,会出现信息冗余现象,造成识别率下降。2018 年魏宏安等<sup>[3]</sup>利用超声波传感器采集了开关柜局部放电超声信号,并用离散小波变换提取了局部放电超声信号的边际谱作为特征量,但预定义的窗口长度固定,在处理开关柜局部放电这类非平稳信号时,会出现模式混叠、过包络和欠包络现象。2019 年刘云鹏等<sup>[4]</sup>、2022 年戴昕宇等<sup>[5]</sup>都使用超声波传感器采集了开关柜局部放电超声信号,利用短时傅里叶变换提取了局部放电超声信号的二维时频图作为特征量,但是由于测不准原理对短时傅里叶变换窗函数的制约,实际应用中难以选取合适的窗函数。

Choi-Williams 分布(Choi-Williams distribution, CWD)具备良好的时频分辨率,在计算时无需加窗,避免了时域分辨率与频域分辨率之间的矛盾,同时克服了模式混叠现象。能够准确反映信号丰富的时频特性,深度挖掘信号的特征。非常适合于局部放电超声信号这类非平稳、非线性信号的处理。

排列熵(permutation entropy, PE)是一种度量时间序列复杂性的方法,它具有计算简单,抗干扰能力强的优势,可以很好的检测出局部放电超声信号的突变。目前,排列熵已经应用在生物医学、图像处理等不同领域,Chen 等<sup>[6]</sup>提取了脑电信号的排列熵特征,精确测量了麻醉深度;Fabila-Carrasco 等<sup>[7]</sup>利用排列熵量化了图像的不规则性。

结合 Choi-Williams 分布和排列熵<sup>[8]</sup>的优点,利用 Choi-Williams 分布提取局部放电超声信号的时频特征,使用排列熵提取局部放电超声信号时间序列复杂度特征,将时频特征与排列熵特征结合形成局部放电超声信号特征向量,最后利用 PSO-BP (particle swarm optimization-back propagation neural network)实现局部放电类型识别。

1 研究方法

局部放电超声信号是一种非平稳瞬态信号,单次放电量很小,可以通过双指数振荡衰减模型进行等效<sup>[9]</sup>,其表达式如下:

$$x(t) = A(e^{\frac{\alpha_1 t}{\tau_1}} - e^{\frac{\alpha_2 t}{\tau_2}})\sin(2\pi ft)$$

(1)

式中:  $A$  表示信号幅值,单位是 mV;  $\alpha_1$  和  $\alpha_2$  表示衰减系

数,无量纲值;  $\tau_1$  和  $\tau_2$  表示衰减周期,单位是 ns;  $f$  表示振荡衰减频率,单位是 kHz。

对式(1)按照表 1 进行参数配置,得到局部放电超声模拟信号  $x(t)$ ,设置采样频率为 2 GHz,得到局部放电超声采样信号  $x(i)$ ,时域波形示意图如图 1 所示。

表 1 局部放电超声仿真信号参数  
Table 1 Partial discharge ultrasonic simulation signal parameters

| $A/\text{mV}$ | $\alpha_1$ | $\alpha_2$ | $\tau_1/\text{ns}$ | $\tau_2/\text{ns}$ | $f/\text{kHz}$ |
|---------------|------------|------------|--------------------|--------------------|----------------|
| 5             | -1.3       | -2.2       | 5.2                | 15.3               | 40             |




图 1 局部放电超声信号时域波形  
Fig. 1 Time-domain waveform of partial discharge ultrasonic signal

1.1 提取局部放电超声信号时频特征

CWD 有着最小的交叉项干扰,在不同时间或频率上对信号有高分辨率和识别精度的优势,其表达式为:

$$CWD_x(t, f) = \iint \sqrt{\frac{\sigma}{4\pi\tau^2}} e^{-\frac{\sigma(u-\tau)^2}{4\tau^2}} \times x(u + \frac{\tau}{2})x*(u - \frac{\tau}{2})e^{-j2\pi f\tau} du d\tau$$

(2)

式中:  $t$  表示时间,  $f$  表示频率,  $x(u + \frac{\tau}{2})x*(u - \frac{\tau}{2})$  表示信号  $x(u)$  的瞬时自相关,  $u$  为  $x(u)$  的自变量,  $\tau$  表示时移,  $e^{-\frac{\sigma(u-\tau)^2}{4\tau^2}}$  表示核函数,  $\sigma$  为衰减系数,其值越大,自项的分辨率越高;其值越小,抑制交叉项的能力越强。

计算局部放电超声模拟信号  $x(t)$  的 CWD 分布得到时频谱图如图 2 所示。提取 CWD 时频谱图最大和最小值处的时间、频率、幅值作为特征量,分别记为  $t_{\max}, f_{\max}, v_{\max}, t_{\min}, f_{\min}, v_{\min}$ 。将这 6 个特征量组合成局部放电超声信号时频特征向量  $C_E$ 。

1.2 提取局部放电超声信号排列熵

对局部放电超声信号  $\{x(i), i = 1, 2, \dots, n\}$  进行相空间重构,得到局部放电超声信号的重构矩阵  $X$ :




图 2 局部放电超声波信号时频谱图

Fig. 2 Spectrogram of partial discharge ultrasonic signal

$$\mathbf{X} = \begin{pmatrix} x(1) & x(1+\tau) & \cdots & x(1+(m-1)\tau) \\ x(2) & x(2+\tau) & \cdots & x(2+(m-1)\tau) \\ x(j) & x(j+\tau) & \cdots & x(j+(m-1)\tau) \\ \vdots & \vdots & & \vdots \\ x(K) & x(K+\tau) & \cdots & x(K+(m-1)\tau) \end{pmatrix} \quad (3)$$

式中:  $j=1,2,\dots,K$ ;  $m$  为嵌入维数,  $\tau$  为延迟时间,  $K=m-(m-1)\tau$ 。矩阵  $\mathbf{X}$  中的任意一行  $\{x(j) \ x(j+\tau) \ \cdots \ x(j+(m-1)\tau)\}$  为重构分量, 矩阵  $\mathbf{X}$  共有  $K$  个重构分量, 对各重构分量中  $x$  按照值的大小进行升序排列可得:

$$x(j+(r_1-1)\tau) \leq x(j+(r_2-1)\tau) \leq \cdots \leq x(j+(r_m-1)\tau) \quad (4)$$

式中:  $r_1, r_2, \dots, r_m$  表示原重构分量中每个元素所在的列数。若出现相同值的情况, 例如:

$$x(j+(r_p-1)\tau) = x(j+(r_q-1)\tau) \quad (5)$$

按照  $r_p, r_q$  的大小对重构分量进行排列, 如  $r_p < r_q$  时, 应将其排列为:

$$x(j+(r_p-1)\tau) \leq x(j+(r_q-1)\tau) \quad (6)$$

由式(4)可知, 重构矩阵  $\mathbf{X}$  中的每一行都会生成一组序列:

$$\mathbf{s}(l) = \{\mathbf{r}_1 \mathbf{r}_2 \cdots \mathbf{r}_m\} \quad (7)$$

式中:  $l=1,2,\dots,k$  且  $k \leq m!$ ,  $m$  维相空间映射共有  $m!$  种不同的映射序列  $\{\mathbf{r}_1 \mathbf{r}_2 \cdots \mathbf{r}_m\}$ , 序列  $\mathbf{s}(l)$  只是其中一种情况。假设每一种映射序列出现的概率分别是  $p_1, p_2, \dots, p_k$ , 此时  $k$  种不同的映射序列的排列熵可以被定义为:

$$H_p = - \sum_{j=1}^k P_j \ln P_j \quad (8)$$

当  $P_j = 1/m!$  时,  $H_p$  达到最大值  $\ln(m!)$ 。

对  $H_p$  做归一化处理:

$$0 \leq H_N = \frac{H_p}{\ln(m!)} \leq 1 \quad (9)$$

$H_N$  值的大小表示了局部放电超声信号的随机程度。 $H_N$  的值越大, 表示局部放电超声信号的随机程度越大, 规则程度越小,  $H_N$  的值越小, 表示局部放电超声信号的随机程度越小, 规则程度越大。

### 1.3 构建局部放电类型识别模型

局部放电类型识别是一个分类问题, 特征量与局部放电类型存在非线性关系, BP 神经网络是一种利用误差逆向传播算法训练的多层前馈网络, 具备极强的非线性映射能力, 因此适合用于局部放电类型识别。

神经网络输入层为时频特征向量  $\mathbf{C}_E$  和排列熵  $H_E$  组成的特征向量, 其中  $\mathbf{C}_E$  为 CWD 时频谱图最大和最小值处的时间、频率、幅值组成的特征量, 即输入层神经元数目为 7, 以预测结果为输出层, 输出层神经元数目为 1, 隐含层神经元数目由式(10)确定:

$$n = \sqrt{i+o} + a \quad (10)$$

式中:  $n$  为隐含层神经元数目,  $i$  为输入层神经元数目,  $o$  为输出层神经元数目,  $a$  为调节常数, 其取值范围是 1~10 的整数。

确定网络结构后, 对其进行初始化, 激活函数选择 logistic 函数, 其表达式为:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (11)$$

隐含层输出为:

$$H = f\left(\sum_{i=1}^7 \omega_{ij} x_j - a\right) \quad (12)$$

输出层输出为:

$$O = H\omega_{jk} - b \quad (13)$$

更新权值:

$$\omega_{ij} = \omega_{ij} + \eta H_i (1 - H_i) x_i \omega_{jk} e \quad (14)$$

$$\omega_{jk} = \omega_{jk} + \eta H e \quad (15)$$

更新阈值:

$$a = a + \eta H (1 - H) \omega_{jk} e \quad (16)$$

$$b = b + \eta e \quad (17)$$

粒子群算法的基本思想是通过群体中个体之间的协作和信息共享来寻找最优解<sup>[10]</sup>。利用该算法对 BP 神经网络进行参数寻优。粒子的速度和位置更新公式为:

$$v_{id}^k = \omega v_{id}^{k-1} + c_1 r_1 (pbest - x_{id}^{k-1}) + c_2 r_2 (gbest - x_{id}^{k-1}) \quad (18)$$

$$x_{id}^k = x_{id}^{k-1} + v_{id}^k \quad (19)$$

式中:  $k$  表示当前迭代次数,  $d=1,2,\dots,D$ ,  $i=1,2,\dots,n$ ,  $\omega$  表示惯性权重,  $v_{id}^k$  表示第  $k$  次迭代粒子  $i$  的速度,  $x_{id}^k$  表示第  $k$  次迭代粒子  $i$  的位置,  $c_1, c_2$  是加速度常数, 用来调节最大学习步长, 其取值范围是  $[0,4]$ ,  $r_1, r_2$  是随机数, 其取值范围是  $(0,1)$ 。根据粒子速度和位置的更新公

式,可以得到神经网络权值和阈值的最优值。

1.4 局部放电类型识别流程

提出的局部放电类型识别流程如图 3 所示,具体步骤如下:

- 步骤 1) 利用实验平台采集开关柜局部放电信号  $x(n)$ 。
- 步骤 2) 利用 CWD 变换,将局部放电超声信号映射到时频域,提取 CWD 时频域特征向量  $C_E$ 。
- 步骤 3) 计算局部放电超声信号的排列熵  $H_N$ 。
- 步骤 4) 建立局部放电类型识别模型,将步骤 2) 和 3) 提取的特征量作为输入进行训练。
- 步骤 5) 利用步骤 4) 所得模型对测试集进行预测,给出局部放电类型识别结果。




图 3 局部放电类型识别流程

Fig. 3 Partial discharge type identification process

2 实验分析

2.1 实验数据

为了获取开关柜局部放电超声信号<sup>[11-15]</sup>,搭建了开关柜局部放电检测实验平台。实验平台如图 4 所示。所用高压源为便携式耐压测试仪,其输出交流电压的最大值为 5 kV,误差±5%,漏电流的最大值为 200 mA,误差±5%。开关柜所用型号为 XL-21 动力柜,模型高 100 cm、宽 60 cm、纵深 40 cm。为获取局部放电超声信号,使用中心频率为 40 kHz 的压电型超声传感器采集局部放电产生的超声信号。

设计了悬浮放电、针板放电以及沿面放电 3 种放电模型。模型实物图如图 5 所示。模型的相关参数如下: 3 个模型的接地板电极为直径 50 mm、厚 20 mm 的铜板;



图 4 开关柜局部放电检测实验

Fig. 4 Partial discharge detection experiment of switchgear  
悬浮放电模型的悬浮颗粒物用螺母模拟,距离高压电极 8 mm;针板放电模型的针电极采用直径 10 mm、长 15 mm、尖端角度为 45°的铜针,高压针电极与接地板电极之间相距 8 mm;沿面放电模型,两极板之间放置一个直径 50 mm、厚 6 mm 的环氧树脂圆板。




图 5 局部放电模型

Fig. 5 Partial discharge model

实验时将局部放电模型放入开关柜中,由高压源对局部放电模型两端施加电压,超声波传感器靠近局部放电模型采集局部放电超声信号,再由同轴电缆将采集到的超声信号传输至示波器,测量并记录信号的波形。

对 3 种局部放电模型进行检测,得到相应的超声信号,示波器采样点数为 2 000,时域波形如图 6 所示。

每种局部放电模型测量并记录了 50 组局部放电数据,共 150 组独立数据,随机选取 90 个样本数据作为训练集,60 个样本数据作为测试集,如表 2 所示。

表 2 实验数据集说明

Table 2 Description of the experimental dataset

| 局部放电类型 | 类型标签 | 训练集数量 | 测试集数量 |
|--------|------|-------|-------|
| 悬浮放电   | 1    | 30    | 20    |
| 针板放电   | 2    | 30    | 20    |
| 沿面放电   | 3    | 30    | 20    |




图 6 局部放电超声信号时域波形

Fig. 6 Partial discharge ultrasonic signal time-domain waveform

## 2.2 特征提取

以实验测得的悬浮放电超声信号数据为例进行特征提取,信号波形图如图 6(a) 所示。

提取时频特征<sup>[16-21]</sup>时,为了减少交叉项的干扰,悬浮放电超声信号首先进行希尔伯特变换,变为解析信号后进行 CWD 变换,得到悬浮放电超声信号的时频谱图,如图 7 所示。提取 CWD 时频谱图最大和最小值处的时间、频率、幅值作为特征向量  $C_E$ 。

排列熵表征时间序列复杂度能力的好坏关键在于嵌入维数和延迟时间的选取。需要对嵌入维数和延迟时间的取值进行研究。

选取不同的嵌入维数以及延迟时间后,得到的排列熵值也略有不同,选取了嵌入维数  $m = 2 \sim 9$ ,延迟时间  $\tau = 1 \sim 7$  来求解排列熵值,结果如图 8 所示。

从图 8 中可以看出,嵌入维数对排列熵的影响大于延迟时间。在实际计算过程中,随着嵌入维数的增加,计算时间也在增加,当嵌入维数大于 7 时,计算时间明显增加,不同延迟时间下排列熵值的差距明显缩小,此时排列熵表征悬浮放电超声信号时间序列复杂度的能力也在下降。根据实际运算时的速度,将嵌入维数取值为 5。从




图 7 悬浮放电超声信号时频谱图

Fig. 7 Suspension discharge ultrasonic signal time spectrogram




图 8 不同嵌入维数和延迟时间下的排列熵值

Fig. 8 Permutation entropy values for different embedding dimensions and delay times

图 8 中可以看出延迟时间的值越大,排列熵表征悬浮放电局放信号时间序列复杂度的能力越好,在 5~7 时能力近似,为使排列熵所含信息更多,将延迟时间取值为 7。最终,利用排列熵理论处理局部放电超声信号时,选择嵌入维数  $m = 5$ ,延迟时间  $\tau = 7$ 。

为了验证排列熵的性能,对求得的排列熵归一化处理后进行 K-means 聚类,分析其分布情况,结果如图 9 所示。从图 9 中可以看出,针板放电超声信号的边界最为清晰,沿面放电和悬浮放电的超声信号边界较为清晰,但是存在交叉重叠的情况。

## 2.3 放电类型识别

将本文所提特征提取方法与分形特征提取方法、CWD 时频特征提取方法进行对比。将不同特征提取方法得到的特征向量分别送入 PSO-BP 神经网络进行训练,随后利用训练好的模型进行局部放电类型识别预测<sup>[22-23]</sup>。最终的局部放电类型识别结果如图 10 所示。




图 9 排列熵分布结果

Fig. 9 Permutation of entropy distribution results

识别率如图 11 所示。

由图 10(a) 可知,分形特征提取方法识别结果中有 9 个样本识别错误,其中有 3 个悬浮放电样本被误判为沿面放电,2 个沿面放电样本被误判为悬浮放电,可见该方法对悬浮放电和沿面放电分辨能力较差。由图 10(b) 可知,CWD 时频特征提取方法识别结果中,有 3 个样本识别错误,其中有 1 个悬浮放电样本被误判为沿面放电,1 个沿面放电样本被误判为悬浮放电,可见该方法对悬浮放电和沿面放电的分辨能力仍然有提升空间。由图 10(c) 可知,本文提出的时频与排列熵特征相结合的特征提取方法能够较为准确的识别出不同开关柜局部放电类型,识别结果比前两种方法准确。

由图 11 可知,时频与排列熵特征相结合的特征提取方法的识别率可达 96.67%,优于分形特征提取方法的 85%,相较于单一采用 CWD 时频特征提取方法提升了 1.67%,表明时频与排列熵特征相结合的特征提取方法能够较好提取出不同局部放电类型的特征。


为了观察 3 种特征提取方法的表现,引入混淆矩阵,如图 12 所示。

根据混淆矩阵,可以得到 3 种提取方法的精确率、召回率、 $F_1$  得分,以此对 3 种特征提取方法进行评估。从表 3 中可以看出本文所提方法识别率更高,评价指标更好,总体性能更好,可以应用在开关柜局部放电类型识别领域。

表 3 评估结果


Table 3 Evaluate results ( % )

|          | 精确率   | 召回率   | $F_1$ 得分 |
|----------|-------|-------|----------|
| 分形方法     | 85.00 | 85.50 | 85.25    |
| CWD 时频方法 | 95.00 | 95.50 | 95.25    |
| 本文方法     | 96.67 | 96.75 | 96.71    |




(a) 分形识别结果

(a) Fractal recognition results



(b) CWD 识别结果

(b) CWD recognition results



(c) 本文识别结果

(c) This article recognition results

图 10 不同特征提取方法识别结果

Fig. 10 Identification results of different feature extraction methods

### 3 结 论

针对开关柜局部放电检测问题,提出了一种 Choi-Williams 分布和排列熵相结合的开关柜局部放电超声信




图 11 不同特征提取方法的识别率

Fig. 11 Recognition rate of different feature extraction methods




图 12 不同特征提取方法的混淆矩阵

Fig. 12 Confusion matrix for different feature extraction methods

号特征提取方法。Choi-Williams 分布克服了短时傅里叶变换时间和频率分辨率的矛盾,克服了离散小波变换的模式混叠现象,解决了统计特征参数过多的问题,能够较

好地表征开关柜局部放电信号的时频特征。排列熵能够有效反映开关柜局部放电超声信号的时间序列复杂度,从开关柜局部放电超声信号的排列熵计算结果可以看出,排列熵能够有效提取时间序列特征信息,较好地表征局部放电超声信号的特征。

实际实验数据分析表明,本文所提出的特征提取方法能够融合 Choi-Williams 分布和排列熵的优势,有效提取开关柜局部放电信号的特征,能够满足开关柜局部放电类型识别的要求,对开关柜局部放电检测有一定的指导作用。

参考文献

[ 1 ] 任先文, 薛雷, 宋阳, 等. 基于分形特征的最小二乘支持向量机局部放电模式识别[J]. 电力系统保护与控制, 2011,39(14): 143-147.  
REN X W, XUE L, SONG Y, et al. The pattern recognition of partial discharge based on fractal characteristics using LS-SVM [ J ]. Power System Protection and Control, 2011,39(14): 143-147.

[ 2 ] 律方成, 金虎, 王子建, 等. 基于主成分分析和多分类相关向量机的 GIS 局部放电模式识别[J]. 电工技术学报, 2015,30(6): 225-231.  
LYU F CH, JIN H, WANG Z J, et al. GIS partial discharge pattern recognition based on principal component analysis and multiclass relevance vector machine [ J ]. Transactions of China Electrotechnical Society, 2015,30(6): 225-231.

[ 3 ] 魏宏安, 陈尧. 基于超声波的局部放电特征提取法的研究[J]. 电气开关, 2018,56(2): 9-12.  
WEI H AN, CHEN Y. Research on the extraction method of the partial discharge characteristic based on ultrasonic wave[J]. Electric Switchgear, 2018,56(2): 9-12.

[ 4 ] 刘云鹏, 王江伟, 裴少通, 等. 基于短时傅里叶变换和稀疏表示的局放识别分类方法[J]. 电测与仪表, 2019,56(23): 31-36.  
LIU Y P, WANG J W, PEI SH T, et al. Method for identifying and classifying partial discharge based on short time Fourier transform and sparse representation [ J ]. Electrical Measurement & Instrumentation, 2019, 56(23): 31-36.

[ 5 ] 戴昕宇, 徐焕宇, 张宁. 移动端卷积神经网络开关柜局部放电样本生成与检测[J]. 电子测量技术, 2022, 45(12): 141-147.  
DAI X Y, XU H Y, ZHANG N. Partial discharge sample generation and detection of convolutional neural network switchgear at mobile end [ J ]. Electronic Measurement Technology, 2022,45(12): 141-147.

- [ 6 ] CHEN Y, FAN S, ABBOD M F, et al. Nonlinear analysis of electroencephalogram variability as a measure of the depth of anesthesia [ J ]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-13.
- [ 7 ] FABILA-CARRASCO J S, TAN C, ESCUDERO J. Permutation entropy for graph signals [ J ]. IEEE Transactions on Signal and Information Processing over Networks, 2022, 8: 288-300.
- [ 8 ] ZUNINO L, ZANIN M, TABAK B M, et al. Forbidden patterns, permutation entropy and stock market inefficiency [ J ]. Physica A: Statistical Mechanics and its Applications, 2009, 388(14): 2854-2864.
- [ 9 ] 尚海昆, 李宇才, 林伟. 基于 EWT-MQE 的变压器局部放电特征提取 [ J ]. 电力系统保护与控制, 2022, 50(14): 161-171.  
SHANG H K, LI Y C, LIN W. Partial discharge feature extraction of a transformer based on EWT-MQE [ J ]. Power System Protection and Control, 2022, 50(14): 161-171.
- [ 10 ] 朱菊香, 谷卫, 罗丹悦, 等. 基于 PSO 优化 BP 神经网络的多传感器数据融合 [ J ]. 中国测试, 2022, 48(8): 94-100.  
ZHU J X, GU W, LUO D Y, et al. Multi-sensor data fusion based on PSO optimized BP neural network [ J ]. China Measurement & Test, 2022, 48(8): 94-100.
- [ 11 ] 周梦茜, 唐志国, 王泽瑞, 等. 基于声纹识别系统的局部放电超声信号识别研究 [ J ]. 高压电器, 2022, 58(9): 127-133.  
ZHOU M X, TANG ZH G, WANG Z R, et al. Study on ultrasonic signal recognition of partial discharge based on voiceprint recognition system [ J ]. High Voltage Apparatus, 2022, 58(9): 127-133.
- [ 12 ] 杨凯, 张认成, 杨建红, 等. 基于频率约束独立分量分析的开关柜局部放电故障识别 [ J ]. 高电压技术, 2014, 40(11): 3452-3460.  
YANG K, ZHAGN R CH, YANG J H, et al. Partial discharge fault identification of switchgear based on frequency constrained independent component analysis [ J ]. High Voltage Apparatus, 2014, 40(11): 3452-3460.
- [ 13 ] 唐云辉, 胡曦琳. 基于声信号分析的开关柜局部放电检测算法研究 [ J ]. 电子器件, 2018, 41(3): 644-648.  
TANG Y H, HU X L. Research on partial discharge detection algorithm for switchgear based on acoustic signal analysis [ J ]. Chinese Journal of Electron Devices, 2018, 41(3): 644-648.
- [ 14 ] BESHARATIFARD H, HASANZADEH S, HEYDARIAN-FORUSHANI E, et al. Detection and analysis of partial discharges in oil-immersed power transformers using low-cost acoustic sensors [ J ]. Applied Sciences, 2022, 12(6): 3010.
- [ 15 ] THUNGSUK N, MUNGKUNG N, SONGRUK A, et al. The investigation of detect position of partial discharge in cast-resin transformer using high-frequency current transformer sensor and acoustic emission sensor [ J ]. Applied Sciences, 2022, 12(3): 1310.
- [ 16 ] 王猛, 谈克雄, 高文胜, 等. 局部放电脉冲波形的时频联合分析特征提取方法 [ J ]. 电工技术学报, 2002(2): 76-79.  
WANG M, TAN K X, GAO W SH, et al. Time-frequency distribution method for extracting features of partial discharge pulse shape [ J ]. Transactions of China Electrotechnical Society, 2002(2): 76-79.
- [ 17 ] 郑重, 谈克雄, 王猛, 等. 基于脉冲波形时域特征的局部放电识别 [ J ]. 电工电能新技术, 2001(2): 20-24.  
ZHENG ZH, TAN K X, WANG M, et al. Partial discharge recognition based on time domain features of pulse waveform [ J ]. Advanced Technology of Electrical Engineering and Energy, 2001(2): 20-24.
- [ 18 ] IMBURGIA A, RIZZO G, ROMANO P, et al. Time evolution of partial discharges in a dielectric subjected to the DC periodic voltage [ J ]. Energies, 2022, 15(6): 2052.
- [ 19 ] LIU J, WEI D, ZHAO Z, et al. Partial discharge detection and type identification of typical defects of XLPE cables under AC voltage [ J ]. Journal of Physics. Conference Series, 2022, 2187(1): 12061.
- [ 20 ] MAHDI A S, ABDUL-MALEK Z, ARSHAD R N. SF6 decomposed component analysis for partial discharge diagnosis in GIS: A review [ J ]. IEEE Access, 2022, 10: 27270-27288.
- [ 21 ] 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): 326.
- [ 22 ] KARANDAIEV A S, YACHIKOV I M, RADIONOV A A, et al. Fuzzy algorithms for diagnosis of furnace transformer insulation condition [ J ]. Energies, 2022, 15(10): 3519.
- [ 23 ] 黄雪薇, 熊俊, 张宇, 等. 基于残差卷积神经网络的开关柜局部放电模式识别 [ J ]. 中国电力, 2021, 54(2): 44-51.  
HUANG X Y, XIONG J, ZHANG Y, et al. Partial discharge pattern recognition of switchgear based on residual convolutional neural network [ J ]. Electric Power, 2021, 54(2): 44-51.

## 作者简介



王非, 2021 年于南京信息工程大学获得学士学位, 现为南京信息工程大学电子与信息工程学院硕士研究生, 主要研究方向为仪器仪表。

E-mail: 1349090822@qq.com

**Wang Fei** received his B. Sc. degree from Nanjing University of Information Science & Technology in 2021. Now he is a M. Sc. candidate at the School of Electronics and Information Engineering, Nanjing University of Information Science and Technology. His main research interest includes instrumentation.



徐伟 (通信作者), 2004 年、2007 年、2019 年于南京信息工程大学获得学士、硕士、博士学位, 现为南京信息工程大学正高级实验师, 主要研究方向为气象观测方法及仪器。

E-mail: xw@nuist.edu.cn

**Xu Wei** (Corresponding author), received his B. Sc. degree, M. Sc. degree and Ph. D. degree in Nanjing University of Information Science and Technology in 2004, 2007, 2019, respectively. Now he is a senior experimentalist. His main research interests include meteorological observation methods and instruments.