

# 联合同步挤压小波变换和多尺度排列熵的局部放电类型识别

马晓燕<sup>1</sup>, 王文波<sup>2</sup>

(1. 华中农业大学 理学院, 武汉 430070; 2. 武汉科技大学 理学院, 武汉 430065)

**摘要:** 为稳定提取变压器局部放电信号的特征, 提出一种基于同步挤压小波变换和多尺度排列熵的局部放电特征提取方法, 再通过 GK 模糊聚类方法对局部放电信号的特征进行识别分类; 首先, 通过同步挤压小波变换对 4 种典型变压器故障产生的局部放电信号进行分解, 将其分解为一组含有局部放电特征信息的模态分量; 然后, 通过多尺度排列熵量化各模态分量的局部放电特征信息, 使用各模态分量多尺度排列熵的平均值作为识别特征向量; 最后, 利用模糊聚类得到的局部放电样本标准聚类中心, 采用欧式贴进度进行局部放电识别分类; 将提出的方法应用于变压器局部放电的实验数据上, 并与基于小波分解方法和经验模态分解的识别方法进行对比分析, 实验结果表明, 所提出的方法具有更好的分类性, 对变压器局部放电分类具有更高的识别精度, 平均识别精度达到 93.60%。

**关键词:** 同步挤压小波; 局部放电; 多尺度排列熵; 模糊聚类

## Partial Discharge Recognition Based on Synchrosqueezing Wavelet Transform and Multi-scale Permutation Entropy

Ma Xiaoyan<sup>1</sup>, Wang Wenbo<sup>2</sup>

(1. College of Science, Huazhong Agriculture University, Wuhan 430070, China;

2. College of Science, Wuhan University of Science and Technology, Wuhan 430065, China)

**Abstract:** In order to stable extraction of the characteristics of partial discharge signal of transformer, a method of partial discharge feature extraction based on synchrosqueezing wavelet transform (SWT) and multi-scale permutation entropy is proposed, and then the characteristics of partial discharge signal are identified and classified by GK fuzzy clustering method. Firstly, the partial discharge signals generated by four typical transformer faults are decomposed into a set of modal components containing the characteristic information of local discharge. Then, the partial discharge characteristic information of each modal component is quantified by multi-scale permutation entropy, and the average of the multi-scale permutation entropy of each modal component is used as the identification feature vector. Finally, using the standard cluster center of partial discharge samples obtained by GK fuzzy clustering, European proximity was used to classify partial discharge. The proposed method is applied to the experimental data of transformer partial discharge and compared with the recognition method based on wavelet decomposition and empirical modal decomposition. The experimental results show that the proposed method has better classification, and the classification of transformer partial discharge has higher recognition accuracy, the average recognition accuracy is 93.60%.

**Keywords:** synchrosqueezing wavelet transform; partial discharge; multi-scale permutation entropy; GK fuzzy clustering

## 0 引言

在电力系统中, 电力变压器作为整个系统的关键设备, 其对整个电网运行的安全性和稳定性有极大影响<sup>[1]</sup>。局部放电 (partial discharge, PD) 是设备绝缘损坏的主要原因, 绝缘损坏程度随 PD 类型的不同而不同, 其形成机理也存在差异。因此, 快速准确地识别不同放电类型, 可为确定故障位置和判别放电类型提供可靠的依据, 对维持电力系统的稳定性和安全运行具有重要意义<sup>[2]</sup>。当前, 在放电信号的检测中, 主要方法包括: 超高频法、超声波

法、脉冲电流法、光学法、化学法等<sup>[3-4]</sup>。其中, 超高频法 (ultra-high frequency, UHF) 具有较多的优点, 包括: 现场安装方便、灵敏度高、抗干扰能力强等, 因此被广泛应用于局部放电信号的在线监测<sup>[5]</sup>。由于现场复杂的监测环境, 很难从检测出的超高频局部放电信号 (UHF PD) 中直接区分缺陷类型。因此, 需要对 UHF PD 信号进行特征提取, 通过提取得到的特征信息对放电缺陷类型进行有效识别, 缺陷类型识别结果的准确性受到特征信息提取的直接影响。

小波变换 (wavelet transform) 和经验模态分解 (empirical mode decomposition, EMD) 被广泛地应用在局部放电分类识别中<sup>[6-7]</sup>。但是, 在小波变换中, 每次仅对信号的低频部分作进一步分解, 而高频部分保持不变, 导致高频部分的频率分辨率较差。而且, 小波变换分解的 PD 信号的

收稿日期: 2019-06-12; 修回日期: 2019-07-15。

基金项目: 国家自然科学基金项目 (61671338)。

作者简介: 马晓燕 (1976-), 女, 宁夏银川市人, 讲师, 主要从事小波理论与应用, 信号处理方向的研究。

幅频响应曲线具有交错的频带，且各子带间往往存在严重的频谱混叠和能量泄漏<sup>[8-9]</sup>，所以 PD 信号的时频信息不能够通过小波分解的子带进行精确描述，不利于后继的缺陷分类识别。EMD 是一种自适应的信号分解方式，可以将 PD 信号分解为一组有限的内蕴模态函数 (intrinsic mode function, IMF) 之和。但 EMD 的抗噪性很差，而且其分解结果也存在较严重的模态混叠，因此，EMD 也无法对 PD 信号进行精确多尺度时频描述。同步挤压小波变换 (synchrosqueezing wavelet transform, SWT) 是在小波变换的基础上发展起来的一种新的时频分析方法，它以连续小波变换为基础，具有极高的频谱分辨率<sup>[9-10]</sup>和抗噪性能，信号经 SWT 分解后，得到的子带间基本没有频谱混叠和能量泄漏的情况。因此，SWT 可以对非线性、非平稳信号的时频特征进行更准确的描述。SWT 已经广泛应用在时变信号谱分析<sup>[11]</sup>、地震信号检测<sup>[12]</sup>、声呐信号分析<sup>[13]</sup>和机械故障诊断<sup>[14]</sup>等领域。

由于 PD 信号在多重尺度上都含有重要的特征信息，为了更好地提取 PD 信号在不同尺度下的放电特性，本文将 SWT 引入到变压器局部放电类型的识别中，首先利用 SWT 对 PD 信号进行分解，然后提前 PD 信号的多尺度特征信息。

排列熵 (permutation entropy, PE) 是由 Bandt 等提出一种用来检测一维时间序列随机性和复杂性的算法，其在信号变化情况分析表现出很强的敏感性，非常适合对不同放电类型的多尺度特征进行量化处理。本文将 SWT 和 PE 算法相结合，构造了基于 SWT 分解的多尺度排列熵 (multi-scale permutation Entropy, MPE) 算法，对 PD 信号进行放电特征提取，同时考虑到局部放电特征的模糊性，应用 GK 模糊聚类算法对局部电类型进行最终的分类识别。

## 1 基于同步挤压小波变换和多尺度排列熵的特征提取方法

### 1.1 同步挤压小波变换

时变信号  $f(t)$  一般以可分解为多个本征函数的叠加，即信号  $f(t)$  可表示为：

$$f(t) = \sum_{k=1}^K f_k(t) = \sum_{k=1}^K A_k(t) \cos(\theta_k(t)) \quad (1)$$

式中， $\theta_k(t)$  表示第  $k$  个分量的瞬时相位， $A_k(t)$  表示第  $k$  个分量的瞬时振幅； $e(t)$  表示噪声或误差， $K$  表示的是信号的分量个数。SWT 在连续小波变换的基础上，对其时频曲线进行挤压，从而提高时变信号的频谱分辨率。

同步挤压小波变换中首先对信号  $f(t)$  进行连续小波变换，得到小波系数：

$$W_f(a, b) = \frac{1}{\sqrt{a}} \int f(t) \psi^* \left( \frac{t-b}{a} \right) dt \quad (2)$$

式中， $\psi^*$  表示母小波函数的共轭， $a$  为尺度因子， $b$  为平移因子。根据 Plancherel 定理，式 (2) 在频率域的等价变换为：

$$W_f(a, b) = \frac{1}{2\pi} \int \sqrt{a} \hat{f}(\xi) \hat{\psi}^*(a\xi) e^{i b \xi} d\xi \quad (3)$$

式中， $\hat{f}(\xi)$ 、 $\hat{\psi}(\xi)$  分别是  $f(t)$ 、 $\psi(t)$  的傅里叶变换。考虑简单的谐波函数  $f(t) = A \cos(\omega t)$ ，其傅里叶变换为  $\hat{f}(\xi) = \pi A [\delta(\xi - \omega) + \delta(\xi + \omega)]$ ，根据式 (3)，其连续小波变换为：

$$W_f(a, b) = \frac{A}{4\pi} \int \sqrt{a} [\delta(\xi - \omega) + \delta(\xi + \omega)] \times \hat{\psi}^*(a\xi) e^{i b \xi} d\xi = \frac{A}{4\pi} \sqrt{a} \hat{\psi}^*(a\omega) e^{i b \omega} \quad (4)$$

若  $\hat{\psi}(\xi)$  在  $\xi = \omega_0$  处的分布集中，则小波系数  $W_f(a, b)$  将会分布在尺度  $a = \frac{\omega_0}{\omega}$  附近。然而，小波系数在时频图中的分布范围较宽、边界较模糊，而且分辨率较低。信号的瞬时频率可以使用小波系数来求导估计，即：

$$\omega_f(a, b) = \begin{cases} \frac{-i \partial_b W_f(a, b)}{W_f(a, b)} & W_f(a, b) \neq 0 \\ \infty & W_f(a, b) = 0 \end{cases} \quad (5)$$

根据 (5) 式可估计信号的瞬时频率  $\omega_f(a, b)$ ，从而建立  $(b, a) \rightarrow [b, \omega_f(a, b)]$  的映射，将小波系数  $W_f(a, b)$  从“时间—尺度”的平面上转化到“时间—频率”的平面上。如果将任一中心频率  $\omega_i$  所处区间  $[\omega_i - \frac{1}{2} \Delta\omega, \omega_i + \frac{1}{2} \Delta\omega]$  内所有的小波系数值压缩到中心频率  $\omega_i$  位置上，就可得到信号的同步挤压值  $T_f(\omega_i, b)$ ，从而减小频谱混叠、提高频率分辨率。在实际计算中，对参数  $a, b, \omega$  进行离散化处理，假设  $a_i - a_{i-1} = (\Delta a)_i$ ，同步挤压小波变换值  $T_f(\omega_i, b)$  可表示为：

$$T_f(\omega_i, b) = \sum_{a_i: |\omega_f(a_i, b) - \omega_i| \leq \frac{\Delta\omega}{2}} W_f(a_i, b) a_i^{-3/2} (\Delta a)_i$$

同步挤压小波变换是可逆的，通过  $T_f(\omega_i, b)$  不仅可以精确重构原始信号  $f(t)$ ，而且可以精确重构每一个分量信号  $f_k(t)$ 。假设  $L_k(t)$  是时频图中以  $f_k(t)$  的脊线为中心的一个小区间，则  $f_k(t)$  的重构公式为：

$$f_k(t) = \text{Re} [C_\psi^{-1} \sum_{t \in L_k(t)} T_f(\omega_i, t) (\Delta\omega)]$$

式中， $C_\psi = \frac{1}{2} \int_0^{+\infty} \hat{\psi}^*(\xi) \frac{d\xi}{\xi}$ 。

由于 EMD 和小波分解不能实现对频带的精确划分，因此 PD 信号经分解后子带间往往存在较严重的频谱混叠和能量泄露，导致 PD 信号的多尺度特征信息不能被准确描述，严重影响缺陷类型识别精度。而 PD 信号可以被 SWT 更精确的分解，分解后的子带间基本不存在频谱混叠和能量泄露，因此，通过 SWT 分解后的子带信号，可以更精确地提取不同类型局部放电信号的多尺度特征信息。

### 1.2 同步挤压小变换多尺度排列熵

利用 SWT 对 PD 信号进行分解后，所得到的内蕴模态类函数 (IMTF) 可以精确描述局放信号在不同尺度下的振动特性，通过计算 IMTF 的多尺度排列熵值就可以从中发现 PD 信号中存在的微小而短促的异常。基于 PD 信号的多尺度表示，并参照文献 [15]，则可以定义沿着尺度分布的

同步挤压小波变换排列熵的测度如下所示。

设局部放电信号经同步挤压小波变换 (synchrosqueezing window fourier transform, SWT) 后的内蕴模态类函数为  $f_k$  ( $k = 1, 2, \dots, K$ ), 对模态类函数  $f_k$  进行相空间重构, 可得:

$$\begin{bmatrix} f_k(1) & f_k(1+\tau) & \cdots & f_k(1+(m-1)\tau) \\ \vdots & \vdots & \cdots & \vdots \\ f_k(j) & f_k(j+\tau) & \cdots & f_k(j+(m-1)\tau) \\ \vdots & \vdots & \cdots & \vdots \\ f_k(Q) & f_k(Q+\tau) & \cdots & f_k(Q+(m-1)\tau) \end{bmatrix} \quad (6)$$

$j = 1, 2, \dots, J$

式中,  $m$ 、 $\tau$  分别表示嵌入维数和延迟时间;  $Q = N - (m-1)\tau$ ,  $N$  表示的  $f_k$  长度。使用该矩阵的每一行元素作为一个 PD 信号重构分量, 则可得到  $Q$  个重构分量。对式 (6) 中的第  $j$  个分量  $[f_k(j), f_k(j+\tau), \dots, f_k(j+(m-1)\tau)]$ , 对其元素按增序方式重新排列, 设  $i_1, i_2, \dots, i_m$  表示重新排列后各元素所在位置的索引, 即有:

$$\begin{aligned} f_k[j+(i_1-1)\tau] &\leq f_k[j+(i_2-1)\tau] \leq \\ &\cdots \leq f_k[j+(i_m-1)\tau] \end{aligned} \quad (7)$$

如果有两个分量的值相等, 即:

$$f_k[j+(i_1-1)\tau] = f_k[j+(i_2-1)\tau] \quad (8)$$

则在排列时按照索引值  $i_1$  和  $i_2$  的大小来排列, 即当  $i_1 < i_2$  时,  $f_k[j+(i_1-1)\tau]$  排在  $f_k[j+(i_2-1)\tau]$  的前面, 此时排列顺序为:

$$f_k[j+(i_1-1)\tau] \leq f_k[j+(i_2-1)\tau] \quad (9)$$

因此, 对于  $f_k$  所得到的重构矩阵, 对其中的每一行进行重新排列后, 都可以得到一组基于排列顺序的符号序列:

$$S(r) = (i_1, i_2, \dots, i_m), \text{ 其中 } r = 1, 2, \dots, q, \text{ 且 } q \leq m!$$

将该重构矩阵的每一行进行重新排列, 如果不用考虑每行的元素值大小顺序进行任意排列, 则其  $m$  个元素共有  $m!$  中排列方法, 即总共存在  $m!$  个符号序列  $(i_1, i_2, \dots, i_m)$ , 按其元素值大小顺序进行排列, 而符号序列  $S(r)$  所有符号序列中的一种。分析每种不同的符号序列  $S(r)$  出现在重构矩阵排列中次数, 并计算其相应的概率, 假设分别为  $P_1, P_2, \dots, P_q$ , 则可以根据 Shannon 熵的定义计算内蕴模态类函数  $f_k$  的  $q$  种不同符号序列的排列熵  $E_p(m)$ , 即:

$$E_p(m) = -\sum_{r=1}^q P_r \ln(P_r) \quad (10)$$

当重构矩阵的排列  $S(r)$  最为分散, 也即每一个  $P_r = \frac{1}{m!}$  时, 排列熵达到最大值  $E_p(m) = \ln(m!)$ 。因此, 排列熵  $E_p(m)$  的大小可以描述内蕴模态类函数  $f_k$  中序列的随机程度: 排列熵  $E_p(m)$  的值越小, 表明  $f_k$  中的数据越规则; 排列熵  $E_p(m)$  的值越大, 则表明  $f_k$  中的数据越不规则, 越接近于随机序列。排列熵  $E_p(m)$  的变化可以反映并放大了多尺度内蕴模态类函数  $f_k$  中数据序列的细节变化, 可以准

确的检测出序列的突变, 在局部放电分类时可获得较高的分辨率。为了便于使用, 通常需要对  $E_p(m)$  进行归一化处理, 即令  $E_p = \frac{E_p(m)}{\ln(m!)}$ , 则  $0 \leq E_p \leq 1$ 。

## 2 基于 GK 模糊聚类算法的缺陷类型识别

### 2.1 GK 模糊聚类算法

GK 模糊聚类算法是自适应动态聚类方法的一种模糊推广, 其主要思想是利用协方差矩阵对类间距离进行自适应的度量。假设收集到的数据为  $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ , 利用 GK 模糊聚类中定义的最小化目标函数, 可求出其隶属度矩阵  $\mathbf{U} = [u_{ij}]_{c \times n}$  和聚类中心  $\mathbf{V} = \{v_1, v_2, \dots, v_c\}^T$ 。式中,  $c$  表示聚类的个数,  $v_i$  表示第  $i$  个聚类中心,  $n$  表示所收集的样本的总个数,  $u_{ij}$  表示第  $j$  个元素属于第  $i$  类的隶属度,  $u_{ij}$  应满足:

$$\sum_{i=1}^c u_{ij} = 1, u_{ij} \in [0, 1] \quad (11)$$

在 GK 模糊聚类算法中, 目标函数被定义为:

$$J(\mathbf{X}, \mathbf{V}, \mathbf{U}) = \sum_{i=1}^c \sum_{j=1}^n (u_{ij})^\theta D_{ij}^2 \quad (12)$$

式中,  $\theta$  的取值范围为  $\theta \geq 1$ , 表示模糊指数,  $\theta$  越大, 表示聚类后各个类之间的重叠度越大;  $D_{ij}$  表示第  $j$  个样本与第  $i$  类聚类中心的马氏距离, 其计算公式为:

$$D_{ij}^2 = (x_j - v_i)^T \mathbf{Z}_i (x_j - v_i) \quad (13)$$

式 (13) 中,  $\mathbf{Z}_i = \det(\mathbf{F}_i)^{-\frac{1}{2}} \mathbf{F}_i^{-1}$ ,  $\mathbf{Z}_i$  是一个正定的对称矩阵, 其值可通过聚类协方差矩阵  $\mathbf{F}_i$  直接计算。由拉格朗日乘数法的可知, 当式 (12) 取得极小值时,  $u_{ij}$  和  $v_i$  的取值分别为:

$$u_{ij} = \frac{1}{\sum_{z=1}^c (D_{zj}^2 / D_{zj}^2)^{\frac{2}{\theta-1}}}, v_i = \frac{\sum_{j=1}^n (u_{ij})^\theta x_j}{\sum_{j=1}^n (u_{ij})^\theta} \quad (14)$$

因此, GK 模糊聚类算法的具体实现步骤如下:

- 1) 根据采集数据的类别信息, 确定聚类数目  $c$  和模糊指数  $\theta$ , 并在式 (11) 的条件限制下构造初始隶属矩阵  $\mathbf{U}$ ;
- 2) 根据隶属度矩阵  $\mathbf{U}$  和式 (14), 计算新的聚类中心  $v_i$ , 实现聚类中心的更新;
- 3) 计算第  $i$  个聚类中心的协方差矩阵:

$$\mathbf{F}_i = \frac{\sum_{j=1}^n (u_{ij})^m (x_j - v_i)(x_j - v_i)^T}{\sum_{j=1}^n (u_{ij})^m}$$

- 4) 根据聚类中心的协方差矩阵  $\mathbf{F}_i$  和公式  $\mathbf{Z}_i = \det(\mathbf{F}_i)^{-\frac{1}{2}} \mathbf{F}_i^{-1}$ , 求出  $\mathbf{Z}_i$ , 在此基础上利用式 (13) 计算参数  $D_{ij}^2$ 。

- 5) 根据  $D_{ij}^2$  和式 (14) 中  $u_{ij}$  计算公式, 对隶属度矩阵  $\mathbf{U}$  进行更新。设第  $L$  次迭代时的隶属度矩阵为  $\mathbf{U}^{(L)}$ , 迭代循环终止的允许误差为  $\eta > 0$ , 当  $\|\mathbf{U}^{(L+1)} - \mathbf{U}^{(L)}\| < \eta$  成立时, 迭代终止; 否则继续迭代, 直到误差小于允许误差  $\eta$ 。

### 2.2 模式识别

利用 SWT 和 MPE 提取特征向量后，在 GK 模糊聚类算法的基础上，采用择近原则对变压器局部放电缺陷类型进行分类识别。在择近原则中，需要计算两个模糊子集的贴进度，贴进度越大，表明两个模糊子集越相近；贴进度越小，表明两个模糊子集间的差异越大，越不相近。欧式贴进度计算简单且识别效果好，因此本文选择欧式贴进度作为模糊子集差异性的衡量标准。本文提出的基于 GK 模糊分类的局部放电缺陷类型识别的具体步骤如下：

1) 通过 SWT 和 MPE 对采集到的实验数据进行特征提取，并将数据分为两组：一组作为训练样本，另外一组作为测试样本。

2) 对于训练样本，采用 GK 模糊聚类算法对其进行分类，计算每一类的聚类中心。

3) 计算待分类的局部放电信号的测试样本  $\Omega$  与聚类中心  $V$  的欧式贴进度  $E(\Omega, V)$ 。设  $\Omega$  和  $V$  的样本集为  $B = \{b_1, b_2, \dots, b_n\}$ ，其欧式贴进度的计算公式为：

$$E(\Omega, V) = 1 - \frac{1}{\sqrt{n}} \sqrt{\sum_{i=1}^n [\Omega(b_i) - V(b_i)]^2}$$

式中， $n$  表示测试样本的总个数， $\Omega(b_i)$  表示集合  $\Omega$  的隶属度函数， $V(b_i)$  表示集合  $V$  的隶属度函数。

4) 计算测试样本  $\Omega(b_i)$  与所有聚类中心的欧式贴进度，将其划分到欧式贴进度最大的类中，进而完成变压器局部放电信号的缺陷类型识别。

## 3 实验分析

### 3.1 放电信号采集

根据变压器内部绝缘结构特点，可以将变压器局部放电形式划分为 4 类<sup>[16]</sup>：悬浮放电 (P1)、针板放电 (P2)、沿面放电 (P3) 和气隙放电 (P4)，如图 1 为各类型的局部放电模型的模拟结构。选取直径为 80 mm 的圆板电极，其厚度为 10 mm，选取厚度为 1 mm 的纸板。图 1 (a) 表示的电极结构形式是模拟油中悬浮放电，在环氧板边缘放置一个直径为 0.3 mm 的金属颗粒；图 1 (b) 表示模拟油中电晕放电的针板极结构形式，针颈直径为 0.2 mm，针与板




图 1 局部放电模型

电极间的环氧板厚度为 0.5 mm，直径为 1 mm；图 1 (c) 表示模拟油中沿面放电的形式；图 1 (d) 表示模拟绝缘内部结构气隙放电的模型结构形式，气隙使用三层直径为 60 mm、厚度为 1 mm 的环氧板来组成，中心的圆孔直径大小为 20 mm。这四种缺陷放电模型均被放置在装有变压器油的油箱中，对每种模型结构进行局部放电实验。在表 1 中，试验电压 15/24 表示在悬浮放电试验中电压为 15 kV 和 24 kV，在实验中的样本个数表示为 40/40。进行放电信号收集采样使用的是频带宽度为 0.5~16 MHz 的高频传感器和 TWPDP-ZE 局部放电分析仪。

表 1 放电模型实验条件

放电类型	试验电压/kV	样本个数
悬浮放电	15/24	40/40
针板放电	10/15	40/40
沿面放电	15/20	40/40
气隙放电	10/15	40/40

通过表 1 中给出的局部放电模型参数，在实验室对变压器局部放电进行模式实验，选取脉冲电流法对实验信号进行检测，使用示波器对实验中的局部放电信号数据进行采集。为了避免试验数据存在随机性，各类放电环境下分别进行了 40 次独立实验。局部放电仿真实验信号的一组波形如图 2 所示。




图 2 4 种局部放电的仿真实验信号波形

### 3.2 缺陷类型识别

每类缺陷放电类型使用 80 组实验作为样本数据，选取 50 组样本对识别模型进行训练，另外 30 组样本作为测试数据对模型进行测试。对于每组实验信号，分别利用小波变换、经验模态分解和同步挤压小波变换对其进行多尺度分解，抽取对应的模态分量函数  $\{f_k\}$ 。在模态分量函数

的基础上, 利用 MPE 算法计算的排列熵, 取各模态分量多尺度排列熵的平均值作为特征向量。进而结合模糊聚类的方法, 分别构造 WT-MPE-GK 方法、EMD-MPE-GK 方法和 SWT-MPE-GK 方法对放电缺陷类型进行识别。以 db10 小波为小波基进行小波分解, 将分解的层数设置为 10; 在使用同步挤压小波变换中, 连续小波变换的小波基选择 Morlet 小波, 所有实验均在 Matlab2016a 环境下进行。三种方法的识别结果如表 2 所示, 表中单位为 %。

通过实验数据的识别结果对比可以发现, 采用 SWT 分解方法得到的缺陷类型识别率明显高于使用 EMD 方法和小波分解方法的缺陷类型识别率, 与小波方法相比, SWT 方法的识别率提高约 9.02%; 与 EMD 方法相比, SWT 方法的识别率提高约 4.85% 因为 SWT 分解的各个子带之间没有频谱混叠和能量泄漏, 且利用多尺度排列熵可以将原始 PD 信号的时频特征更加精确地描述出来, 因此得到了非常好的缺陷类型识别效果。从表 2 可以看出, 本文提出的 SWT-MPE-GK 方法对局部放电缺陷类型的平均识别率高于 90%。

表 2 局部放电识别结果

放电类型	识别精度/%		
	WT-MPE-GK	EMD-MPE-GK	SWT-MPE-GK
悬浮放电	92.29	95.44	97.31
针板放电	77.86	84.17	90.46
沿面放电	82.72	85.63	92.38
气隙放电	85.43	89.75	94.05
平均精度	84.58	88.75	93.60

#### 4 结论

本文针对变压器局部放电信号的类型识别, 提出了一种基于 SWT 和 MPE 的局部放电特征提取和缺陷类型识别的方法。SWT 是一种以连续小波变换为基础的自适应模态分解方法, 可以准确分解 PD 信号在不同尺度的放电特征信息; 在 SWT 分解的基础上, 利用 MPE 对 SWT 分解出的各内蕴模态类函数进行放电特征信息量化, 选取不同尺度 IMTF 的 MPE 平均值作为放电类型识别的特征向量, 该特征向量可以非常有效地表征变压器局部放电信号的特征。采用 SWT-MPE-GK 法对变压器局部放电的类型进行识别, 并与 WT-MPE-GK 和 EMD-MPE-GK 的方法相互比较, 通过实验结果验证了本文所提方法的有效性: 与基于小波和 EMD 的方法相比, 本文方法可以获得更高的放电缺陷类型识别精度。

#### 参考文献:

[1] Pompili M. Partial discharge development and detection in dielectric liquids [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2009, 16 (6): 1648-1654.  
 [2] Wang M H. Partial discharge pattern recognition of current

transformers using an ENN [J]. IEEE Transactions on Power Delivery, 2005, 20 (3): 1984-1990.  
 [3] Tang J, Fan L, Zhang X X, et al. Multi-scale feature parameters extraction of GIS partial discharge signal with harmonic wavelet packet transform [J]. Transaction of China Elerotechnical Society, 2015, 30 (3): 250-257.  
 [4] 赵建利, 刘海峰, 刘 婷, 等. 变压器局部放电信号检测与类型识别 [J]. 现代电子技术, 2016, 39 (6): 166-170.  
 [5] Judd M D, Cleary G P, Bennoch C J. Applying UHF partial discharge detection to power transformers [J]. IEEE Power Engineering Review, 2002, 22 (8): 57-59.  
 [6] Li J, Wang X W, Jin Z R, et al. Multi-scale grid dimension extraction and recognition of ultra-high frequency signals of transformer partial discharge [J]. Power System Technology, 2010, 34 (2): 159-163.  
 [7] 张征凯, 谷立臣, 曹向辉, 等. 基于最优小波包的电机定子电流故障特征提取方法 [J]. 煤矿机械, 2016, 37 (8): 149-151.  
 [8] Mihalec M, Slavic J, Boltezar M. Synchrosqueezed wavelet transform for damping identification [J]. Mechanical Systems & Signal Processing, 2016, 80: 324-334.  
 [9] Holighaus N, Prusa Z, Sondergaard P L. Reassignment and synchrosqueezing for general time-frequency filter banks, subsampling and processing [J]. Signal Processing, 2016, 125 (C): 1-8.  
 [10] Sylvain M, Thomas O, Stephen M. A new algorithm for multicomponent signals analysis based on synchroqueezing: with an application to signal sampling and denoising [J]. IEEE Trans. on Signal Processing, 2012, 60 (11): 5787-5798.  
 [11] Tary J B, Herrera R H, Van d B M. Analysis of time-varying signals using continuous wavelet and synchrosqueezed transforms [J]. Philos. Trans. A Math. Phys. Eng. Sci., 2018, 376(2126).  
 [12] 刘 晗, 张建中, 黄忠来. 利用同步挤压变换检测微地震信号 [J]. 中国科技论文, 2015 (21).  
 [13] Wan T, Gao J H, Chen W C, et al. TP wavelet and its applications to analysis of seismic data of thin interbeds [J]. Coal Geology & Exploration, 2005, 33 (4): 69-72.  
 [14] Li C, Liang M. Time-frequency signal analysis for gearbox fault diagnosis using a generalized synchrosqueezing transform [A]. Mechanical Systems and Signal Processing [C]. 2012, 26: 205-217.  
 [15] Imene M, Gordon M, Alan N, et al. Classification of partial discharge signals by combining adaptive local iterative filtering and entropy features [J]. Sensors, 2018, 18 (2): 1-14.  
 [16] Li J, Wang X W, Jin Z R, et al. Multi-scale grid dimension extraction and recognition of ultra-high frequency signals of transformer partial discharge [J]. Power System Technology, 2010, 34 (2): 159-163.