

文章编号:1000-582X(2013)05-056-08

基于S变换和双向二维主成分分析的局部放电模式识别

廖瑞金¹,袁磊^{1,2},汪可^{1,3},杨丽君¹,聂仕军¹

(1. 重庆大学输配电装备及系统安全与新技术国家重点实验室,重庆 400044;

2. 厦门供电局,厦门 361004;3. 中国电力科学研究院,北京 100192)

摘要:为对不同类型局部放电信号进行识别,笔者提出一种新的特征提取方法。首先,制作了4种典型的局部放电人工缺陷模型,并通过S变换对采集的局部放电UHF信号进行时频分析;然后,采用双向二维主成分分析(2DPCA)对S变换幅值矩阵进行压缩以提取特征;最后,引入基于粒子群算法优化参数的支持向量机对样本特征集进行模式识别。识别结果表明:4种特征维数组合中,(10,5)组合的平均识别率最高,(5,5)组合最低;粒子群优化算法的引入大幅提高了支持向量机的分类性能,平均识别率均在94.43%以上,最高可达到97.67%。由此可见,经过S变换和双向2DPCA提取的特征集在维数显著约减的同时,保留了原始数据大部分信息量,能够获得较为理想的分类识别率。

关键词:局部放电;模式识别;S变换;双向2DPCA;粒子群优化算法;支持向量机**中图分类号:**TM835**文献标志码:**A

Partial discharge pattern recognition based on S transform and two-directional 2DPCA

LIAO Ruijin¹, YUAN Lei^{1,2}, WANG Ke^{1,3}, YANG Lijun¹, NIE Shijun¹

(1. State Key Laboratory of Power Transmission Equipment & System Security and New Technology,

Chongqing University, Chongqing 400044, China; 2. Xiamen Electric Power Bureau,

Xiamen 361004, China; 3. China Electric Power Research Institute, Beijing 100192, China)

Abstract: A new feature extraction method is proposed to recognize different types of partial discharge (PD) signals. Firstly, four typical categories of PD artificial defect models are made and S transform (ST) is employed to obtain a time-frequency representation of the recorded UHF signals. Then, two-directional two-dimensional principal component analysis ((2D)²PCA) is applied to compress the ST amplitude (STA) matrix to extract features. Finally, support vector machine (SVM) combined with particle swarm optimization (PSO) algorithm is introduced to accomplish the recognition of experimental samples. Classification results demonstrate that the average recognition rate of (10, 5) combination is the highest while the one of (5, 5) combination is the lowest among four kinds of feature dimension combinations. Moreover, PSO can obviously improve the classification performance of SVM. Specifically, all the average recognition rates of PSO-SVM are higher than 94.43% and the maximum value comes to 97.67%. Therefore, the feature sets extracted by ST and (2D)²PCA can not only achieve dramatic dimension reduction, but also retain the major information of original data. It is proved that the proposed algorithm can

收稿日期:2012-12-20**基金项目:**国家创新研究群体基金资助项目(51021005);国家自然科学基金资助项目(51277187)**作者简介:**廖瑞金(1963-),男,重庆大学教授,博士生导师,主要从事电气设备绝缘在线监测与故障诊断等领域研究,
(E-mail)rjliao@cqu.edu.cn。

obtain ideal results in PD pattern recognition.

Key words: partial discharge; pattern recognition; S transform; $(2D)^2$ PCA; particle swarm optimization algorithm; support vector machine

局部放电(partial discharge, PD)监测与分析被认为是预防绝缘系统失效最重要的方法之一^[1]。输变电装备内部常因各种潜伏性缺陷而出现局部放电,其对绝缘系统的累积损伤效应严重威胁电网的安全运行。多项研究结果表明,不同缺陷类型的局部放电信号存在一定的差异,而不同缺陷处局部放电的发展规律及对绝缘劣化的加速机理也不同。因此,研究局部放电的模式自动识别技术,对电气设备的绝缘诊断与故障辨识有重要意义。

局部放电脉冲是典型的暂态、非平稳信号,其能量一般集中于有限的频段内,单一的时域或频域特征量均难以充分反映其所含的时变信息^[2]。时频联合分析因其能同时挖掘信号在时域和频域两个方面的信息而成为近年来研究的热点^[3-5]。常见的时频分析方法包括短时傅里叶变换(short time fourier transform, STFT)^[6]、魏格纳-维尔分布(Wigner-Ville distribution, WVD)^[7]以及连续小波变换(continuous wavelet transform, CWT)^[8]等,但这些方法均存在各自的不足。STFT固定的窗口函数决定其无法同时兼顾局部放电信号较高的时域和频域分辨率;WVD存在严重的交叉项干扰;CWT虽然具有良好的平移伸缩特性及较高的时频分辨率,但却易受外界噪声的干扰。S变换(stockwell transform, ST)结合了STFT和CWT的优点,采用高度与频率成正比而宽度与频率成反比的高斯窗口函数,能够在低频区获得较高的频率分辨率,同时在高频区产生较高的时间分辨率,因而非常适合非平稳信号的分析^[9],目前已广泛应用于电能扰动检测^[10]、机械装置故障诊断^[11]以及临床医学信号处理^[12]等方面。

然而,采用各种数学方法提取的特征参量并非完全相互独立,内部可能包含较多的冗余信息和噪声干扰,需要采取进一步的降维措施,从中提取最有效的特征。降维处理得到的新特征应该具备两个基本特性:1)尽可能多地包含原始数据的主要信息;2)将数据维数约减到合理的、可操作的范围。主成分分析(principal component analysis, PCA)是一种基于多元统计的特征提取方法,通过构造一个最佳映射矩阵,将高维空间中的原始数据投影到彼此不相

关的低维变量空间,由此实现复杂数据的维数约减,同时较大程度地保留原始数据的特征,因而在各个领域得到了广泛应用^[13-15]。但是,PCA算法的分析对象是一维向量,对二维时频数据来说,处理时必须先将其转换成一维向量形式,不仅破坏了原始数据的结构信息,导致分类识别率降低,而且大幅增加了求解样本协方差矩阵时的计算量,容易导致分类器的“维数灾”。

二维主成分分析(two-dimensional principal component analysis, 2DPCA)是一种面向图像矩阵的特征提取方法,在处理二维数据时可直接利用原始数据形式构造协方差矩阵,很好地克服了PCA分析二维数据时的缺点。然而,2DPCA实质上是将二维矩阵在水平(或垂直)方向压缩为一组列(或行)向量,仅去除了原始矩阵列(或行)间的相关性,提取的特征维数仍然很大,降维效果不够理想^[16]。双向2DPCA(two-directional 2DPCA, $(2D)^2$ PCA)对二维数据矩阵同时在行和列方向上进行2DPCA运算,不仅能有效去除矩阵行之间和列之间的相关性,显著降低特征集的维数,而且保留了原始数据的主要信息量^[17],克服了2DPCA在处理大规模矩阵数据时的不足。

笔者提出一种ST和 $(2D)^2$ PCA相结合的局部放电信号特征提取方法。首先,在实验室环境下测量得到不同缺陷类型的局部放电超高频(ultra high frequency, UHF)信号,采用ST获取局部放电UHF信号的时频信息;然后,引入 $(2D)^2$ PCA对S变换幅值矩阵(S transform amplitude, STA)进一步提取特征,得到4种不同压缩组合下的低维特征集;最后,采用基于粒子群算法优化参数的支持向量机(support vector machine combined with particle swarm optimization algorithm, PSO-SVM)对提取的样本特征集进行模式识别,得出识别效果最佳的压缩组合。整个PD模式识别系统框图如图1所示。

1 ST基本原理

ST是Stockwell等人^[18]1996年提出的一种新型时频分析方法,可以看作是CWT的母小波经相

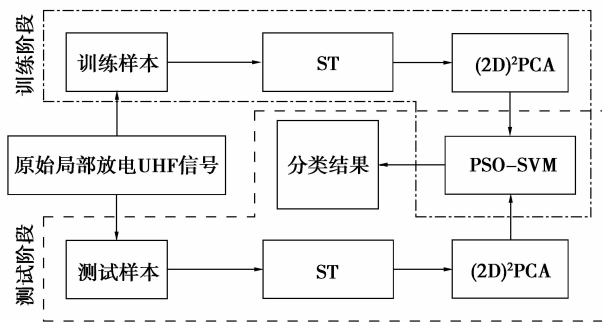


图 1 局部放电模式识别系统框图

位修正后的产物^[19]。信号 $x(t)$ 的连续 ST 定义为

$$S(\tau, f) = \int_{-\infty}^{+\infty} x(t) \frac{|f|}{\sqrt{2\pi}} e^{-\frac{(t-\tau)^2 f^2}{2}} e^{-i2\pi ft} dt, \quad (1)$$

式中: $g(t) = \frac{|f|}{\sqrt{2\pi}} e^{-\frac{(t-\tau)^2 f^2}{2}}$ 为高斯窗函数; $\sigma = \frac{1}{|f|}$

定义为高斯窗宽度; τ 为时移参数, 控制高斯窗函数在时间轴上的位置; i 为虚数单位。

$x(t)$ 的离散 ST 公式可由傅里叶变换快速给出:

$$S\left[jT, \frac{n}{NT}\right] = \sum_{m=0}^{N-1} x\left[\frac{m+n}{NT}\right] e^{-\frac{2\pi^2 m^2}{n^2}} e^{j\frac{2\pi mn}{N}}, \quad n \neq 0, \quad (2)$$

$$S[jT, 0] = \frac{1}{N} \sum_{m=0}^{N-1} x\left(\frac{m}{NT}\right), \quad n = 0, \quad (3)$$

式中: T 、 N 分别为时间采样间隔和时间采样点数, $j, n, m = 0, 1, \dots, N-1$ 。

ST 的结果是一个复时频矩阵, 求模后即得一个对应的 STA 矩阵。该矩阵每行表征该频率点处信号 STA 随时间变化的分布规律, 每列则表征该时刻信号 STA 随频率变化的分布规律。

2 (2D)²PCA 基本原理

2.1 1DPCA

1DPCA 只适合处理一维向量。假设存在 N 个 $1 \times D$ 维向量样本 $X_i (i=1, 2, \dots, N)$, 1DPCA 的基本思想是在满足最小均方误差的前提下寻找一个最佳投影矩阵 U , 样本 X_i 经 $Y_i = X_i U$ 正交变换后, 得到的特征向量 Y_i 不仅在维数上得到约减, 而且较大程度地保留了 X_i 中的主要信息。

根据 K-L 变换相关理论, 样本协方差矩阵的非零特征值对应的特征向量组成的矩阵即是最佳投影矩阵。实际应用时, 一般选择 M 个样本用于构造协方差矩阵 C , 选取 C 矩阵的前 $n (n \leq D)$ 个最大特征值 $e_j (j=1, 2, \dots, n)$ 所对应的特征向量 U_j 组成最佳投影矩阵 U , U 的大小为 $D \times n$ 。于是, 每个样本 X_i 经 U 矩阵投影后的特征向量为

$$F_i = X_i U. \quad (4)$$

由式(4)可知, 每一个 $1 \times D$ 维样本 X_i 经投影后得到一个 $1 \times n$ 维特征向量 F_i , 称 F_i 是 X_i 的 1DPCA 变换特征向量。

2.2 2DPCA

2DPCA 与 1DPCA 的分析思想基本相同, 核心内容都是要设法找到最佳投影矩阵 U 。唯一的区别在于, 2DPCA 的分析对象是二维矩阵, 可直接由二维原始数据构造协方差矩阵, 因而使得原始数据的结构信息不被破坏, 也避免了二维矩阵转换为一维向量时的计算负担。

假设所有样本均为 $p \times q$ 维矩阵 $A_i (i=1, 2, \dots, N)$, 从中选取 M 个样本 $B_k (k=1, 2, \dots, M)$ 用于构造协方差矩阵 C , C 的表达式如下:

$$C = \frac{1}{M} \sum_{k=1}^M (B_k - \bar{B})^T (B_k - \bar{B}), \quad (5)$$

式中: C 矩阵大小为 $q \times q$, 平均样本矩阵 $\bar{B} =$

$$\frac{1}{M} \sum_{k=1}^M B_k.$$

类比 1DPCA, 由 C 矩阵的前 n 个最大特征值求得 $q \times n$ 维最佳投影矩阵 U , 则每个样本矩阵 $A_i (i=1, 2, \dots, N)$ 经 2DPCA 后的特征矩阵为

$$F_i = A_i U. \quad (6)$$

由式(6)可知, 每一个 $p \times q$ 维样本矩阵 A_i 经投影后得到一个 $p \times n$ 维特征矩阵 F_i 。

2.3 (2D)²PCA

由 2.2 节分析可知, 2DPCA 只是在水平方向对二维数据进行了压缩, 将每个样本矩阵由 q 列映射为 n 列, 因而仅去除了列间的相关性, 忽略了行间的相关性, 导致压缩后的数据仍存在一定的冗余和干扰信息, 并且 2DPCA 的降维效果并不明显, 影响分类速度和识别率。针对此问题, 文献[20]提出了 (2D)²PCA 算法, 同时对原始二维数据在水平和垂直方向进行 2DPCA 运算, 去除了行间和列间的相关性, 取得了良好的降维效果。

(2D)²PCA 算法的实现步骤如下:

1) 计算选取的 M 个样本 $B_k (k=1, 2, \dots, M)$ 的平均样本矩阵 \bar{B} , 分别构造水平压缩 2DPCA 的协方差矩阵 C 和垂直压缩 2DPCA 的协方差矩阵 G 。

$$C = \frac{1}{M} \sum_{k=1}^M (B_k - \bar{B})^T (B_k - \bar{B}), \quad (7)$$

$$G = \frac{1}{M} \sum_{k=1}^M (B_k - \bar{B}) (B_k - \bar{B})^T, \quad (8)$$

式中: C 、 G 矩阵的大小分别为 $q \times q$ 和 $p \times p$ 。

2) 求取 C 矩阵的前 d_1 个最大特征值对应的特征

向量组成 $q \times d_1$ 维矩阵 \mathbf{H} , 称 \mathbf{H} 为水平压缩最佳投影矩阵; 同理求取 \mathbf{G} 矩阵的前 d_2 个最大特征值对应的特征向量组成 $p \times d_2$ 维垂直压缩最佳投影矩阵 \mathbf{V} 。

3) 将每个样本矩阵 $\mathbf{A}_i (i=1, 2, \dots, N)$ 在 \mathbf{H} 和 \mathbf{V} 上投影, 得到经过 $(2D)^2$ PCA 压缩后的特征矩阵为

$$\mathbf{Y}_i = \mathbf{V}^T \mathbf{A}_i \mathbf{H}. \quad (9)$$

可见, $p \times q$ 维样本矩阵 \mathbf{A}_i 经投影后变为 $d_2 \times d_1$ 维特征矩阵 \mathbf{Y}_i , 不仅特征维数大幅度降低, 还保留了原始数据的有效信息, 有利于后续的分类。

3 分类器设计

SVM 是 Vapnik 提出的一种建立在统计学习基础上的非线性数据处理方法^[21], 其基于“结构风险最小化原理”的独特决策规则能较好地克服传统分类算法“维数灾”和“过拟合”等问题, 并且具有很强的泛化能力, 在处理二分类和多分类模式识别问题上有着优异表现, 因而备受研究人员青睐^[22-23], 目前已开发出 LIBSVM、LS-SVMLAB、OSU SVM 等诸多软件包。然而, SVM 模型参数的选取没有既定的标准, 需要很强的经验与技巧, 取值不当就会直接影响到最终的分类效果。

PSO 是 Kennedy 和 Eberhart 等人通过研究鸟类觅食行为提出的一种群智能自适应优化算法^[24]。每个粒子表示待优化问题中的一个随机解, 并被赋予一个随机的初始位置和速度, 同时还具有一个与目标函数相关的个体适应度值, 用来评判不同粒子的优劣程度。算法运行过程中, 每个粒子根据当前自身最优解和种群最优解不断更新自己的位置和速度, 逐步向更好的区域逼近, 直至找到全局最优解为止。PSO 算法简单易用, 处理连续非线性最优化问题时稳定性高, 具有良好的收敛特性, 其基本原理介绍详见文献^[25-26]。


笔者引入 PSO 算法对 LIBSVM 工具箱的惩罚参数 c 和核函数参数 g 进行优化, 然后采用训练完成的 PSO-LIBSVM 对不同缺陷类型的 PD 信号进行分类识别。

4 PD 模式识别

4.1 原始 PD 数据的采集

笔者制作了 4 种典型的局部放电人工缺陷模型, 如图 2 所示。图 2(a) 是内部气隙放电模型(记作类型 1), 采用绝缘薄膜在板电极表面支撑环氧板形成厚度为 0.15 mm, 直径为 38 mm 的气隙, 球电极直径为 5.6 mm, 板电极直径为 60 mm。图 2(b) 是

油中电晕放电模型(记作类型 2), 针电极尖部与环氧板间的距离为 1 mm。图 2(c) 是油中沿面放电模型(记作类型 3), 柱电极直径是 10 mm。图 2(d) 是油中悬浮电极放电模型(记作类型 4), 环氧板边缘处放置了一个直径 0.3 mm 的金属颗粒。人工缺陷模型均浸入变压器油中。



1. 球电极; 2. 圆板电极; 3, 10. 环氧板; 4. 气隙;
5. 有机玻璃板; 6. 绝缘螺帽; 7. 绝缘螺栓;
8. 针电极; 9. 圆柱电极; 11. 金属颗粒

图 2 4 种人工缺陷模型

PD 试验产生的 UHF 信号由四阶 Hilbert 分形天线接收后经同轴电缆传入 LeCory7100 数字示波器中进行分析 and 存储, 示波器采样率为 5GS/s, 采样电压为起始放电电压的 1.3~1.5 倍, 每种放电类型取 3 个不同等级的采样电压。原始 PD 数据样本见表 1 所示。每种放电类型制备 10 个尺寸相同的人工缺陷模型, 每个缺陷模型在该类型的每个采样电压下测得 5 个数据样本, 共采集了 $5 \times 3 \times 10 \times 4 = 600$ 个原始 PD 数据样本。

表 1 原始 PD 数据样本

PD 类型	起始放电电压/kV	采样电压/kV	样本数
类型 1	5.2~5.6	7	50
		8	50
		9	50
类型 2	6.9~7.2	9	50
		10	50
		11	50
类型 3	7.4~8.2	10	50
		11	50
		12	50
类型 4	6.6~7.1	9	50
		10	50
		11	50

4.2 原始 PD 数据的预处理

局部放电 UHF 信号通常持续时间为几百纳秒,由于放电的随机性,不同类型的局部放电 UHF 信号幅值和波形存在较大的分散性。为了消除这种分散性对特征提取的影响,笔者采集了 1 000 ns 范围内完整的放电波形,并采用一定方法对不同类型的放电信号进行预处理。

预处理的第一步是对局部放电 UHF 信号按式(10)进行归一化:

$$x_n(t) = \frac{x(t)}{\max(|x(t)|)}, \quad (10)$$

式中: $x(t)$ 为测得的原始局部放电 UHF 信号; $\max(|x(t)|)$ 为 $x(t)$ 的最大模值; $x_n(t)$ 为 $x(t)$ 对应的归一化信号。

对被测信号的统计分析表明,所有的放电波形均可由 1 000 个数据点完全的描述。因此,预处理的第二步是从归一化信号中挑选出 1 000 个最重要的采样点,以此来表征原始局部放电 UHF 信号。笔者选取的是数据点 2 451~3 450 之间的信号,如图 3 所示。




图 3 局部放电 UHF 信号的预筛选

上述预处理措施能够有效地降低白噪声和波形分散性对特征提取的影响。不同缺陷类型产生的局部放电 UHF 信号经预处理后的典型波形如图 4 所示。





图 4 不同缺陷类型局部放电信号预处理后典型波形

4.3 PD 特征提取

笔者采用 ST 和 $(2D)^2$ PCA 对 PD 数据样本进行特征提取。不同缺陷类型的 PD 信号经 ST 后的时频分布如图 5 所示。

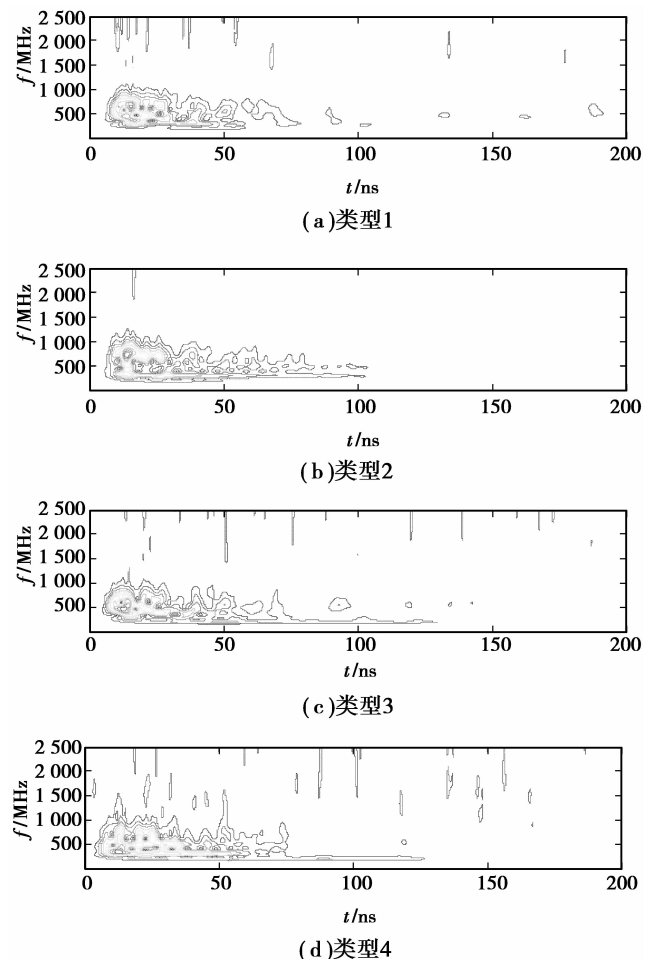


图 5 不同缺陷类型局部放电信号的 S 变换

由图可知,4 种类型的 PD 信号经 ST 后时频

分布存在一定的差异,表明 STA 矩阵中包含足够的能够识别不同放电类型的信息量。但是, STA 矩阵维数为 $500 \times 1\,000$, 直接用于模式识别不仅计算负担很重,而且其中包含较多的冗余信息和噪声干扰,无法得到较好的识别效果,因此需要进一步对 STA 矩阵进行降维处理。

由 2.3 节可知,任一 $p \times q$ 维矩阵经 $(2D)^2$ PCA 处理后可以得到一个 $d_2 \times d_1$ 维特征矩阵,笔者从每类放电的每个电压等级下的 50 组 STA 矩阵中选取 5 个样本(共 $5 \times 3 \times 4 = 60$ 个)用于构造协方差矩阵,即 $M=60$ 。为了找出不同的 d_1 、 d_2 取值对后续分类效果的影响规律,笔者选取了(5,5)、(5,10)、(10,5)和(10,10)4种(d_1, d_2)组合方式,分别得到大小为 5×5 、 10×5 、 5×10 和 10×10 的样本特征矩阵各 600 个。

4.4 分类识别结果与讨论

将每种(d_1, d_2)组合下的 $d_2 \times d_1$ 维样本特征矩阵在水平方向拉直为 $1 \times (d_2 \times d_1)$ 维行向量,依次处理每种放电类型下的 150 个样本特征矩阵,由上而下排列,形成 4 个 $600 \times (d_2 \times d_1)$ 维分类样本矩阵。对每个分类样本矩阵,随机从每类放电的 150 个样本中抽取 75 个作为训练样本,另外 75 个作为测试样本,由此形成 $300 \times (d_2 \times d_1)$ 维训练样本集和测试样本集。此外,每种(d_1, d_2)组合下的样本均随机选取 10 次,取 10 次的平均识别率来表征分类器的整体识别性能。分别采用 LIBSVM 和 PSO-LIBSVM 对 4 种(d_1, d_2)组合下的样本集进行分类识别的结果见表 2 所示。

表 2 分类器模式识别效果 %

(d_1, d_2)	(5,5)	(5,10)	(10,5)	(10,10)
LIBSVM	86.93	88.13	93.77	89.57
PSO-LIBSVM	94.43	94.97	97.67	95.03

从上表可以看出,2 种分类算法都取得了较好的识别效果,表明基于 ST 和 $(2D)^2$ PCA 的特征提取方法用于识别不同缺陷类型 PD 信号是可行的。另一方面,4 种(d_1, d_2)组合下 PSO-LIBSVM 的平均识别率都在 94.43% 以上,最高达到 97.67%,分类效果明显优于 LIBSVM,这是因为在 PSO-LIBSVM 算法中,每个粒子表征一组 LIBSVM 模型参数,而粒子的适应度值反映该组参数下 LIBSVM 算法的识别性能,粒子初始化后将会搜索当前最优粒子(即当前适应度值最大的粒子)的轨迹,根据自身和种群

的进化情况不断更新自己,直到输出最优解,此时粒子的指标参数满足全局最优,对应的 SVM 分类效果最佳。此外,同一种分类算法下 4 种不同(d_1, d_2)组合的样本特征集的识别效果各不相同,但都是(10,5)组合的样本集平均识别率最高,(10,10)、(5,10)组合次之,(5,5)组合识别效果最差。由此可知,在进行 PD 模式识别时,并不是特征维数越低越好。(5,5)组合虽然特征维数显著减少,但也丢失了较多重要的原始数据特征,导致分类识别率较低;(10,10)组合虽然保留了相对较多的原始数据特征,但同时也掺杂了部分冗余信息和噪声干扰,影响了分类器的识别率;(5,10)组合单从分类样本矩阵的维数来看与(10,5)组合完全相同,但两者在 STA 矩阵的基础上进行的行、列压缩运算并不等效,包含的原始数据信息也就不同,导致识别率存在一定的差异。

5 结 论

1) 4 种不同(d_1, d_2)压缩组合下,(10,5)组合平均识别率最高,(5,5)组合最低。由此可知,在进行 PD 模式识别时,要兼顾特征维数与特征包含的原始信息量这两方面的因素。

2) PSO-LIBSVM 分类算法能够通过自适应进化过程优选出识别率最高的 LIBSVM 模型参数,因而能够获得比 LIBSVM 更好的分类效果,其平均识别率均在 94.43% 以上,最高可达到 97.67%。

3) 由分类结果可知,基于 ST 和 $(2D)^2$ PCA 的特征提取方法在显著约减特征维数的同时,仍然保留了原始信号的主要信息量,可以很好地应用于不同缺陷类型 PD 信号的模式识别中。

参考文献:

- [1] Venkatesh S, Gopal S. Robust heteroscedastic probabilistic neural network for multiple source partial discharge pattern recognition-significance of outliers on classification capability [J]. Expert Systems with Applications, 2011, 38(9): 11501-11514.
- [2] 谈文刚,陈祥训,郑健超. 采用小波分析与神经网络技术的局部放电统计识别方法[J]. 中国电机工程学报, 2002, 22(9): 1-5.
DAN Wengang, CHEN Xiangxun, ZHENG Jianchao. Classification of partial discharge distribution patterns using wavelet transform and neural network [J]. Proceedings of the CSEE, 2002, 22(9): 1-5.
- [3] 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, 17(2): 76-79.

- WANG Meng, Tan Kexiong, GAO Wensheng, et al. Time-frequency distribution method for extracting features of partial discharge pulse shape [J]. Transactions of China Electrotechnical Society, 2002, 17(2):76-79.
- [4] Sarikhani A, Reihani E, Nabizadeh N, et al. Analysis of partial discharge by Wavelet-Hilbert transform [J]. European Transactions on Electrical Power, 2009, 19(8):1140-1152.
- [5] Uyar M, Yildirim S, Gencoglu M T. An expert system based on S-transform and neural network for automatic classification of power quality disturbances[J]. Expert Systems with Applications, 2009, 36(3):5962-5975.
- [6] 郑生华, 徐大专, 靳学明, 等. 基于时频分析的雷达侦察信号处理技术[J]. 重庆大学学报:自然科学版, 2006, 29(11):96-100.
ZHENG Shenghua, XU Dazhuan, JIN Xueming, et al. Signal processing techniques for radar reconnaissance system based on time-frequency analysis[J]. Journal of Chongqing University: Natural Science Edition, 2006, 29(11):96-100.
- [7] Wu J D, Huang C K. An engine fault diagnosis system using intake manifold pressure signal and Wigner-Ville distribution technique [J]. Expert Systems with Applications, 2011, 38(1):536-544.
- [8] 王丽婕, 冬雷, 廖晓钟, 等. 基于小波分析的风电场短期发电功率预测[J]. 中国电机工程学报, 2009, 29(28):30-33.
WANG Lijie, DONG Lei, LIAO Xiaozhong, et al. Short-term power prediction of a wind farm based on wavelet analysis[J]. Proceedings of the CSEE, 2009, 29(28):30-33.
- [9] 郭灿新, 勇明, 徐敏骅, 等. S变换在电力电缆局部放电信号时频分析中的应用[J]. 电工技术学报, 2010, 25(11):9-14.
GUO Canxin, YONG Ming, XU Minhua, et al. Application of S transform for time-frequency analysis of partial discharge signals in power cables [J]. Transactions of China Electrotechnical Society, 2010, 25(11):9-14.
- [10] 吕干云, 方奇品. 利用关联向量机和 S变换识别电能质量扰动[J]. 高电压技术, 2010, 36(10):2565-2569.
Lü Ganyun, FANG Qipin. Classification of power quality disturbances using RVM and S-transform[J]. High Voltage Engineering, 2010, 36(10):2565-2569.
- [11] Li B, Zhang P L, Liu D S, et al. Feature extraction for rolling element bearing fault diagnosis utilizing generalized S transform and two-dimensional non-negative matrix factorization[J]. Journal of Sound and Vibration, 2011, 330(10):2388-2399.
- [12] Pinnegar C R, Khosravani H, Federico P. Time-frequency phase analysis of ictal EEG recordings with the S-transform[J]. IEEE Transactions on Bio-medical Engineering, 2009, 56(11), Part 1:2583-2593.
- [13] 彭光金, 俞集辉, 韦俊涛, 等. 特征提取和小样本学习的电力工程造价预测模型[J]. 重庆大学学报, 2009, 32(9):1104-1110.
PENG Guangjin, YU Jihui, WEI Juntao, et al. Cost forecast model for power engineering based on feature extraction and small-sample learning [J]. Journal of Chongqing University, 2009, 32(9):1104-1110.
- [14] 梁胜杰, 张志华, 崔立林. 主成分分析法与核主成分分析法在机械噪声数据降维中的应用比较[J]. 中国机械工程, 2011, 22(1):80-83.
LIANG Shengjie, ZHANG Zhihua, CUI Lilin. Comparison between PCA and KPCA method in dimensional reduction of mechanical noise data [J]. China Mechanical Engineering, 2011, 22(1):80-83.
- [15] 潘梅森, 汤井田, 杨晓利. 采用 PCA 和 PSNR 的医学图像配准[J]. 红外与激光工程, 2011, 40(2):355-364.
PAN Meisen, TANG Jingtian, YANG Xiaoli. Medical image registration based on PCA and PSNR [J]. Infrared and Laser Engineering, 2011, 40(2):355-364.
- [16] 李娟, 何伟, 张玲, 等. 双向压缩的 2DPCA 与 PCA 相结合的人脸识别算法[J]. 计算机应用, 2009, 29:245-246, 268.
LI Juan, HE Wei, ZHANG Ling, et al. Face recognition combined bidirectional 2DPCA with PCA [J]. Journal of Computer Applications, 2009, 29:245-246, 268.
- [17] 秦娜, 金炜东, 刘景波. 基于双向二维主成分分析的掌纹识别[J]. 微计算机信息, 2009, 25(4):238-239, 266.
QIN Na, JIN Weidong, LIU Jingbo. Palmprint recognition based on two-directional two-dimensional principal component analysis [J]. Control & Automation, 2009, 25(4):238-239, 266.
- [18] Stockwell R G, Mansinha L, Lowe R P. Localization of the complex spectrum: the S transform [J]. IEEE Transactions on Signal Processing, 1996, 44(4):998-1001.
- [19] Salem M E, Mohamed A, Samad S A. Rule based system for power quality disturbance classification incorporating S-transform features[J]. Expert Systems with Applications, 2010, 37(4):3229-3235.
- [20] Zhang D Q, Zhou Z H. (2D)²PCA: two-directional two-dimensional PCA for efficient face representation and recognition [J]. Neurocomputing, 2005, 69(1/2/3):224-231.
- [21] Cortes C, Vapnik V. Support-vector networks [J].

- Machine Learning, 1995, 20(3): 273-297.
- [22] 占勇,程浩忠,丁屹峰,等. 基于S变换的电能质量扰动支持向量机分类识别[J]. 中国电机工程学报, 2005, 25(4): 51-56.
- ZHAN Yong, CHENG Haozhong, DING Yifeng, et al. S-transform-based classification of power quality disturbance signal by support vector machines [J]. Proceedings of the CSEE, 2005, 25(4): 51-56.
- [23] 雷肖,陈清泉,刘开培,等. 电动车蓄电池荷电状态估计的支持向量机方法[J]. 中国电机工程学报, 2008, 28(18): 114-118.
- LEI Xiao, CHEN Qingquan, LIU Kaipei, et al. Support vector machine based SOC estimation for electric vehicles [J]. Proceedings of the CSEE, 2008, 28(18): 114-118.
- [24] Kennedy J, Eberhart R. Particle swarm optimization [C] // Proceedings of the 1995 IEEE International Conference on Neural Networks, November 27-December 1, 1995, Perth, WA. Piscataway: IEEE Press, 1995, 4: 1942-1948.
- [25] 袁荣湘,陈彧,吴昊. 采用 PSO 算法的反时限过流保护配合方法[J]. 高电压技术, 2009, 35(7): 1730-1735.
- YUAN Rongxiang, CHEN Yu, WU Hao. Method of inverse-time overcurrent protection coordination using PSO algorithm [J]. High Voltage Engineering, 2009, 35(7): 1730-1735.
- [26] 李元诚,刘克文. 面向大规模样本的核心向量回归电力负荷快速预测方法[J]. 中国电机工程学报, 2010, 30(28): 33-38.
- LI Yuancheng, LIU Kewen. A rapid electric load forecasting method using core vector regression for large scale data set [J]. Proceedings of the CSEE, 2010, 30(28): 33-38.

(编辑 王维朗)

~~~~~

(上接第 55 页)

- LI Youqi, KE Changming, GAN Lin, et al. Development and application of refining desulfurizing agent based on Panzhihua Iron and Steel Co. blast furnace slag extracted titanium [J]. Iron Steel Vanadium Titanium, 2008, 29(4): 26-31.
- [13] 杨宝斌,宋波,何为,等. 含钒含钛精炼渣硫容量研究[J]. 中国稀土学报, 2010, 28: 376-380.
- YANG Baobin, SONG Bo, HE Wei, et al. Sulfur capacity of refining slag containing vanadium and titanium [J]. Journal of the Chinese Rare Earth Society, 2010, 28: 376-380.
- [14] Pelton A D. Thermodynamic database development: modeling and phase diagram calculations in oxide systems [J]. Rare Metals, 2006, 25(5): 473-480.
- [15] 金利玲,王海涛,许中波,等. CaO-SiO<sub>2</sub>-Al<sub>2</sub>O<sub>3</sub>-MnO 系低熔点区域控制[J]. 北京科技大学学报, 2007, 29(6): 574-577.
- JIN Liling, WANG Haitao, XU Zhongbo, et al. Control on low melting point area in a CaO-SiO<sub>2</sub>-Al<sub>2</sub>O<sub>3</sub>-MnO system [J]. Journal of University of Science and Technology Beijing, 2007, 29(6): 574-577.
- [16] 董凌燕,陈登福,白晨光,等. Al<sub>2</sub>O<sub>3</sub>-CaO-SiO<sub>2</sub> 系截面图的计算与验[J]. 重庆大学学报: 自然科学版, 2004, 27(1): 96-100.
- DONG Lingyan, CHEN Dengfu, BAI Chenguang, et al. The calculation of section of Al<sub>2</sub>O<sub>3</sub>-CaO-SiO<sub>2</sub> system and its verification [J]. Journal of Chongqing University: Natural Science Edition, 2004, 27(1): 96-100.

(编辑 王维朗)