

DOI: 10.7667/PSPC170302

# 基于优化 DDAGSVM 多类分类策略的电能质量扰动识别

任子晖, 王琦

(中国矿业大学信息与控制工程学院, 江苏 徐州 221008)

**摘要:** 针对电能质量扰动类型多样且识别率不高的问题, 该研究的目的是如何将多类分类问题应用于支持向量机。首先通过 S 变换和 FFT 变换提取扰动信号特征量进行模型训练。其次将广义 KKT 判定条件与样本空间分布序列相结合引入类间识别度, 将类间识别度最高的超平面函数作为分类器根节点, 以此克服传统决策导向非循环图支持向量机分类器(DDAGSVM)在分类生成顺序上随机化的缺点, 并将改进的 DDAGSVM 应用于电能扰动信号的识别分类。实验结果表明, 所提算法较传统 DDAGSVM 算法有良好效果和更好的鲁棒性。

**关键词:** 支持向量机; 决策导向非循环图; 类间识别度; 广义 KKT 条件; 空间分布序列

## Power quality disturbance recognition based on improved DDAGSVM multi-class classification strategy

REN Zihui, WANG Qi

(School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221008, China)

**Abstract:** In order to solve the problem that the power quality disturbance is diverse and the recognition rate is not high, the purpose of this paper is how to apply the multi-class classification problem to the support vector machine. Firstly, the disturbance signal eigenvalue is extracted to train model by S transform and FFT transform. Secondly, the generalized KKT decision condition is combined with the sample space distribution sequence to introduce interclass recognition degree. The hyperplane function with the highest interclass degree is used as the root node of the classifier to overcome the shortcomings of traditional Decision-oriented Non-cyclic Graph Support Vector Machine Classifier (DDAGSVM) randomization in the order of classification generation, and the improved DDAGSVM is applied to the classification of the energy disturbance signal. The experimental results show that the proposed algorithm has better effect and better robustness than the traditional DDAGSVM algorithm.

**Key words:** support vector machine; decision-oriented non-cyclic graph; interclass cognition; generalized KKT condition; spatial distribution sequence

## 0 引言

工业发展导致电网存在多种复杂的电能质量扰动问题, 因此高效快速地检测扰动并准确识别分类已成为当今电能质量扰动分析的热点话题<sup>[1-2]</sup>。

电能质量扰动识别包括对扰动样本特征值的提取及模式识别分类器的设计<sup>[3]</sup>。特征值提取通过对扰动信号的处理变换提取可代表原始信号的有效成分, 常规方法包括短时傅立叶变换、小波变换和 S 变换等。其中短时傅立叶变换采用固定窗函数且对

非平稳信号与低频信号无法自适应, 导致窗函数时间与频率分辨率无法同时最优; 小波变换改进短时傅立叶变换并可自适应分辨率, 但易受噪声干扰, 且小波基选择困难; S 变换继承以上两种变换, 采用高斯窗函数且窗宽与频率倒数成正比, 免去窗函数的选择, 改善了窗宽固定缺陷, 且时频分析中各频率分量相位谱与原信号直接关联, 同时特征量对噪声不敏感。本文采用 S 变换和 FFT 变换提取特征量<sup>[4-10]</sup>作为模式识别分类器输入量, 目前广泛应用的智能监测方法主要有神经网络、模糊技术和支持向量机。神经网络存在算法局部最优问题、训练时间长且易过拟合的缺点; 模糊技术由于“IF-THEN”准则不适合谐波、闪变、振荡而影响

**基金项目:** 江苏省重点研发计划项目 (BE2016046); 江苏省煤矿电气与自动化工程实验室建设项目 (2014KJZX05)

推广<sup>[11]</sup>; 支持向量机是基于 VC 维理论与结构经验风险最小化理论, 使特征空间间隔最大化的线性分类器, 并转换为凸二次规划问题, 主要解决小样本、高维数、非线性等问题, 不仅克服人工神经网络局部最优解等缺点, 同时强化训练模型鲁棒性。因此本文采用支持向量机并结合改进 DDAGSVM 算法<sup>[12-15]</sup>策略设计新型多类分类识别器。

## 1 电能质量扰动信号特征的提取

### 1.1 电能质量扰动信号模型

本文主要研究电压暂升、暂降、谐波、脉冲、中断、闪变、谐波+暂降以及谐波+暂升、震荡 9 种电能扰动, 根据 IEEE 标准建立标准扰动信号模型

如表 1 所示<sup>[5]</sup>。模型电压幅值  $A$  归一化为 1, 信号基频为 50 Hz, 并加入  $SNR=20/30/40/50$  dB 的高斯白噪声,  $\mu(t)$  为阶跃信号,  $t_1$ 、 $t_2$ 、 $T$  分别是扰动起始、终止时刻与信号周期, 信号采样频率  $F_s = 3200$ , 采样点数  $N=3200$ , 即每周波采样 64 个点。

### 1.2 S 变换基本原理

通过 S 变换, 我们可从时频域同时观察信号能量分布, 其分辨率随信号频率变换, 免去窗函数的选择, 改善了窗宽固定的缺陷; 同时与小波变换保持密切联系, 但高频部分比小波变换分解更细腻; S 变换所采用高斯窗函数的窗宽与频率倒数成正比, 造成低频信号的频域分辨率比时域分辨率更佳, 而高频信号相反, 所以 S 变换更适合处理低频信号<sup>[4,6-8,10]</sup>。

表 1 电能质量扰动信号标准模型

Table 1 Standard model of power quality disturbance signal

类型	标识	模型	参数
暂升 暂降	C1 C2	$A\{1 \pm k[\mu(t_1) - \mu(t_2)]\} \sin(\omega t)$	$k = 0.1 \sim 0.9$ $t_1 - t_2 = (1 \sim 8)T$
谐波	C3	$A \sin(\omega t) + A_1(\mu(t_1) - \mu(t_2)) \sin(3\omega t) +$ $A_3(\mu(t_3) - \mu(t_4)) \sin(5\omega t) +$ $A_5(\mu(t_5) - \mu(t_6)) \sin(7\omega t)$	$0.1 \leq A_i \leq 0.2$ $t_i - t_{i+1} = (1 \sim 8)T$ $i = 1, 3, 5$
脉冲	C4	$A \sin(\omega t) + A_1[\mu(t_1) - \mu(t_2)] +$ $A_3[\mu(t_3) - \mu(t_4)] + A_5[\mu(t_5) - \mu(t_6)]$	$1 \leq A_i \leq 3$ $t_i - t_{i+1} = (1 \sim 8)T$ $i = 1, 3, 5$
中断	C5	$A\{1 - k[\mu(t_1) - \mu(t_2)]\} \sin(\omega t)$	$k = 0.9 \sim 1$ $t_1 - t_2 = (1 \sim 8)T$
闪变	C6	$A\{1 + k \sin(\sigma \omega t)\} \sin(\omega t)$	$k = 0.1 \sim 0.2$ $\sigma = 0.1 \sim 0.5$
谐波+暂升 谐波+暂降	C7 C8	$A\{1 \pm k[\mu(t_1) - \mu(t_2)]\}$ $[\sin(\omega t) + A_1 \sin(3\omega t) + A_2 \sin(5\omega t)]$	$k = 0.1 \sim 0.9$ $0.1 \leq A_1, A_2 \leq 0.2$ $t_1 - t_2 = (1 \sim 8)T$
振荡	C9	$\sin(\omega t) + A_1 \exp(-(t - t_1))$ $\sin(\omega_n(t - t_1))[\mu(t_1) - \mu(t_2)]$	$\omega_n = (10 \sim 16)\omega$ $A_1 = 0.1 \sim 0.8$ $t_1 - t_2 = (1 \sim 8)T$

给定输入信号  $w(t)$ , 其 S 变换为  $S(\tau, f)$ :

$$S(\tau, f) = \int_{-\infty}^{\infty} w(t)g(\tau - t, f)e^{-i2\pi ft} dt \quad (1)$$

$$g(\tau, f) = \frac{|f|}{\sqrt{2\pi}} e^{-\frac{|f|^2 \tau^2}{2}} \quad (2)$$

式中,  $g(\tau, f)$  为时域上高斯窗函数, 其在时间轴上的位置随  $\tau$  改变, 由于 S 变换保留了信号的有效信息, 所以通过 S 逆变换可以重构原始信号, 并且通过改进 S 逆变换缩小重构误差, 信号  $w(t)$  的逆变换为

$$w(t) = \int_{-\infty}^{\infty} [\int_{-\infty}^{\infty} S(\tau, f) d\tau] e^{i2\pi ft} df \quad (3)$$

利用离散 FFT 变换对信号  $w(t)$  处理得到离散信号  $X(f)$ , 将其带入频谱表达式中可得其离散形式:

$$w(kt) = \frac{1}{N} \sum_{n=0}^{N-1} \left\{ \sum_{j=0}^{N-1} S\left[\frac{n}{NT}, jT\right] \right\} e^{i2\pi nk} \quad (4)$$

其中,  $N$  代表采样点数。对扰动信号进行离散采样获取  $N$  个离散点  $S(i)(i=1, 2, 3, \dots, N)$ , 并应用式(1)与式(2)进行 S 变换得到复矩阵, 其列向量对应采样点时间  $t$ , 行向量对应采样点频率  $f$ , 矩阵包含采样点的幅值与相位信息, 其模矩阵  $S[f, t]$  的行向量表示信号某一频率的时频分布, 列向量表示某一采样点的幅频特性<sup>[7]</sup>, 对采样频域为  $F_s$ , 采样点为  $N$  的离散信号, 其采样点  $n$  实际频率  $F_r$  与所对应的采样时间  $T_r$  如式(5)、式(6)。

$$F_r = (n \cdot F_s) / N \quad (5)$$

$$T_r = n/F_s \quad (6)$$

### 1.3 扰动信号 S 变换分析

本文对 9 种扰动信号均设定  $SNR=20$  dB 的信噪比, 通过小波去噪并进行 S 变换, 对 S 矩阵元素求模得到  $1601 \times 3200$  的 S 模矩阵, 其中第一行向量为直流分量, 信号各个频段的时域变化都可经 S 变换反映出来。本文以电压脉冲、电压暂升、电压闪变以及电压谐波暂升复合信号 4 种分析为代表说明, 图 1 是 4 种扰动信号基频采样点对应幅值的特征曲线, S 模矩阵行向量是信号某一频率的时频分布, 由式(5)可知, 选取 S 模矩阵 51 行行向量作为分析对象, 可看出电压脉冲的扰动发生时刻以及时间跨度, 可看到共有三个比较大的幅值波动, 表明有 3 个脉冲尖峰, 电压闪变幅值均在 0.45 附近上下波动, 分布相对稳定, 电压谐波暂升除了保持谐波的特点外, 其采样点对应幅值在发生电压暂升时有明显波动, 可以看到共有 4 个较大的波动点, 并且表明其扰动发生时刻以及持续时间; 图 2 是频率对应幅值标准差曲线, 可看出从 200 Hz 开始, 电压闪变在高频部

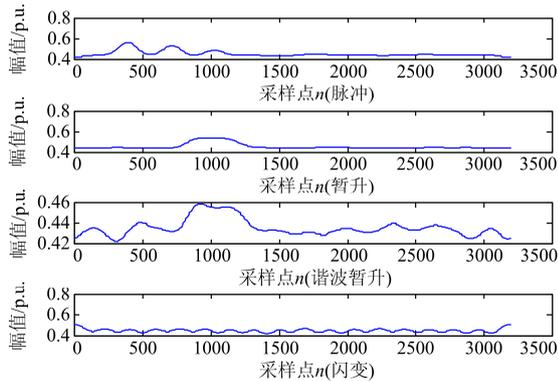


图 1 基频采样点幅值曲线

Fig. 1 Fundamental sampling point amplitude curve

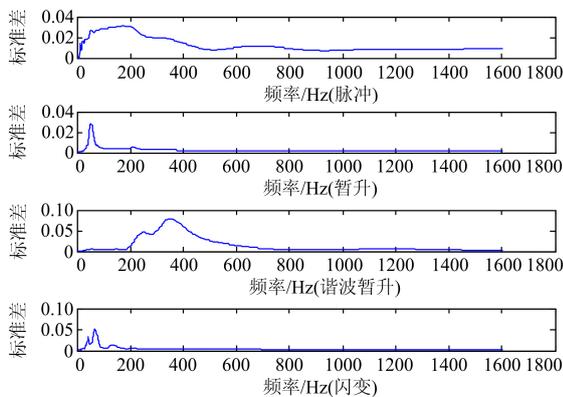


图 2 频率对应幅值标准差曲线

Fig. 2 Frequency response amplitude standard deviation curve

分分布很均匀, 尖峰部分表明在此处发生了信号扰动, 并且也可观察到扰动发生的频率范围, 谐波暂升在整个频域内有多个高频, 因此 200 Hz 以上的中高频段可以将 4 种扰动区分开。

### 1.4 扰动信号特征值提取与分析

#### 1) 基频幅值变换峭度 $F_B$

基频峭度  $F_B$  反映基频采样点对应幅值最大值  $F_{\max_b}$  与最小值  $F_{\min_b}$  的分离程度, 可反映扰动信号基频的波动情况, 据式(5)提取 S 模矩阵第 51 行行向量, 其表达式为

$$F_B = |F_{\max_b} - 1| - |F_{\min_b} - 1| \cdot 10 \quad (7)$$

#### 2) 基频幅值标准差 $STD_B$

标准差  $STD_B$  反映了基频采样点幅值在时域的离散度, 可从侧面反映扰动信号分布及其对信号的影响程度, 同理提取 S 模矩阵第 51 行行向量, 其表达式为

$$STD_B = \sqrt{\frac{1}{N} \sum (S[51, :] - \frac{1}{N} \sum S[51, :])^2} \quad (8)$$

式中:  $S[51, :]$  代表 S 模矩阵第 51 行所有元素;  $N$  代表采样点数。

#### 3) 高频幅值变化峭度 $F_H$

高频峭度  $F_H$  反映了高频部分对应的最大幅值与最小幅值的离散情况, 同样反应扰动信号高频区域的波动情况, 设定高频部分为 S 模矩阵 201 Hz~1601 Hz 的  $1401 \times 3200$  矩阵高频区域, 表达式为

$$F_H = |\max(S[n:m, :]) - 1| - |\min(S[n:m, :]) - 1| \cdot 10 \quad (9)$$

式中:  $n=201$ , 为高频区域频率下限值;  $m=1601$ , 为高频区域频率上限值; “:” 代表该行所有元素。

#### 4) 频率与幅值标准差曲线的标准差 $STD_{std}$

先研究幅值 S 模矩阵各个频段的时域离散情况, 再研究各频段标准差的频域离散情况, 以此作为扰动信号幅值的 S 变换标准差, 其表达式为

$$STD_{std} = \sqrt{\frac{1}{f} \sum_{f=1}^F [STD_f(f) - \frac{1}{F} \sum_{f=1}^F STD_f(f)]^2} \quad (10)$$

$$STD_f(f) = \sqrt{\frac{1}{N} \sum (S[f, :] - \frac{1}{N} \sum S[f, :])^2} \quad (11)$$

式中:  $N=3200$ , 为采样点数;  $F=1601$ ;  $f=1 \sim F$ ; “:” 含义同上;  $STD_f$  是各个频段的时域离散情况;

$STD_{std}$  为各频段标准差的频域离散情况。

### 1.5 基于傅里叶变换的特征值提取

傅里叶变换将连续时序信号分解为不同频率正弦信号的叠加, 将信号由时域分析转换为频域分

析, 通过 FFT 可以得出信号各个频段幅值与能量的大小, 本文将 9 种扰动信号分别进行 3200 点的 FFT 变换并提取特征值总谐波畸变率  $THD$ , 其表达式为

$$THD = \sqrt{\sum_2^N \text{Real}(V_i)^2 + \sum_2^N \text{Imag}(V_i)^2} / V_j \quad (12)$$

式中:  $V_i$  为 FFT 采样点复变量,  $i=1 \sim N$ ,  $N$  为采样点数;  $V_j$  为基频分量, 由式(5)得知为第 51 个采样点;  $\text{Real}(V_i)$  为采样点实部;  $\text{Imag}(V_i)$  为采样点虚部。

### 1.6 特征量在电能分类方面的验证

为验证上述 5 种特征量在电能质量分类的作用及其鲁棒性, 本文对每种扰动信号分别就  $SNR=20/30/40/50$  dB 高斯白噪声生成 100 个样本信号, 即总共 3600 个样本信号, 将所有样本通过 S 变换与 FFT 变换提取 5 种特征量。图 3—图 6 分别为 4 种白噪声的 5 种特征值的辨识能力灰度散点图, 0~100 为电压谐波样本, 101~200 为电压谐波暂升样本, 201~300 为电压谐波暂降样本, 301~400 为电压脉

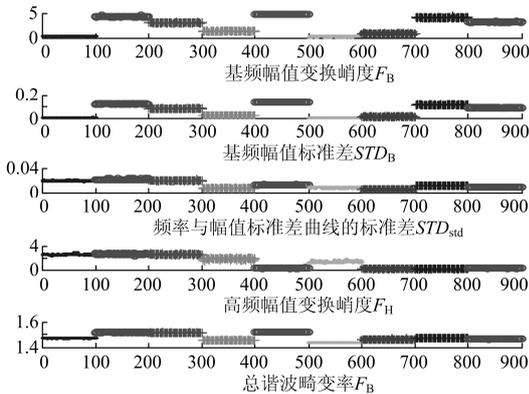


图 3  $SNR=20$  dB 的特征辨识散点图

Fig. 3  $SNR=20$  dB feature identification scatter plot

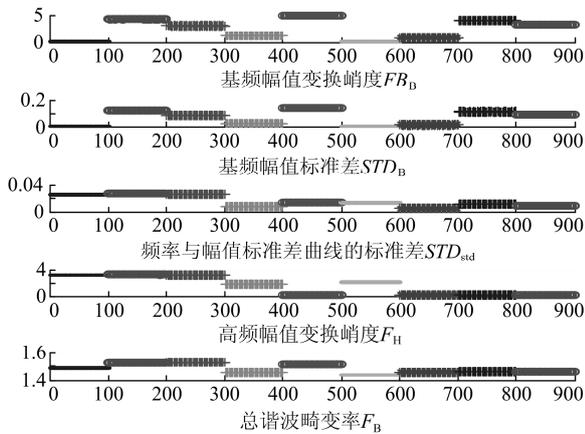


图 4  $SNR=30$  dB 的特征辨识散点图

Fig. 4  $SNR=30$  dB feature identification scatter plot

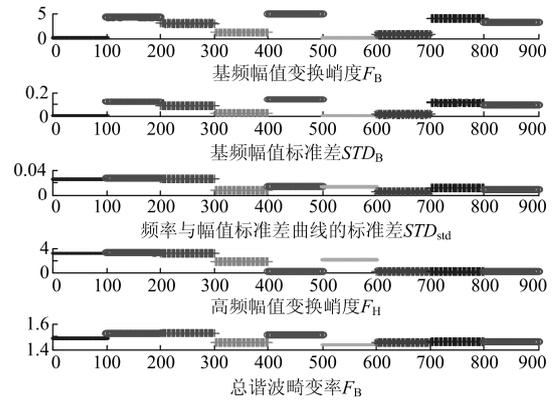


图 5  $SNR=40$  dB 的特征辨识散点图

Fig. 5  $SNR=40$  dB feature identification scatter plot

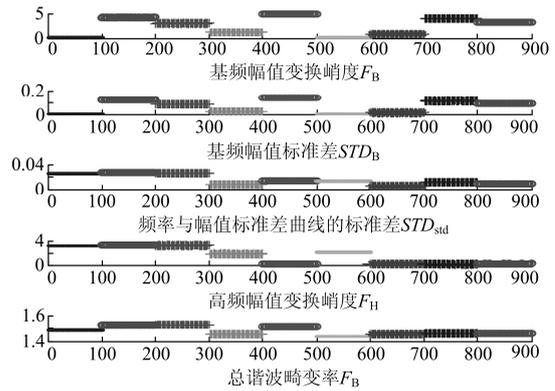


图 6  $SNR=50$  dB 的特征辨识散点图

Fig. 6  $SNR=50$  dB feature identification scatter plot

冲样本, 400~500 为电压中断样本, 501~600 为电压震荡样本, 601~700 为电压闪变样本, 701~800 为电压暂升样本, 801~900 为电压暂降样本。

从图 3—图 6 散点图可以看出, 在 4 种噪声环境下, 基频幅值变换峭度  $F_B$ 、高频幅值变化峭度  $F_H$ 、总谐波畸变率  $THD$  可将 9 种扰动彼此分开, 统计结果如表 2 所示, 其中, C1—C9 为表 1 所示的 9 种扰动信号标识。

表 2 三种特征量辨识扰动信号效果

Table 2 Identification of disturbance signal effect by three characteristic quantities

	C2	C3	C4	C5	C6	C7	C8	C9
C1	$F_B$	$F_B$	$F_B$	$THD$	$F_B$	$F_H$	$F_H$	$F_B$
C2		$F_B$	$F_B$	$THD$	$F_B$	$F_H$	$F_H$	$F_B$
C3			$F_B$	$F_B$	$F_H$	$F_B$	$F_B$	$F_H$
C4				$F_H$	$F_H$	$F_H$	$F_B$	$THD$
C5					$THD$	$F_H$	$F_H$	$F_H$
C6						$F_B$	$F_B$	$THD$
C7							$F_B$	$F_B$

## 2 DDAGSVM 分类树的构建

常规 DDAGSVM 分类器根节点的选择与决策走向是随机的, 当某个节点分类错误或其分类误差大时, 其误差会一直累积到叶子节点, 造成正确率低, 因此将类间辨识度由高到低依次由根节点向子节点构建分类器是改善 DDAGSVM 的有效途径。

### 2.1 广义 KKT 条件

KKT 条件广泛应用于求解不等式条件约束最优化问题, 由于支持向量机是多条件下使得分类间隔最大化, 最终转换为凸二次规划问题最优解, 因此间隔最大化最优解必定满足 KKT 判定条件, 定义如下分类超平面

$$\vec{\mu} = w * x - b \quad (13)$$

式中:  $w$  为其法向量;  $b$  为其常数项; 为使得分类间隔最大化, 将上式转化为

$$\begin{cases} \min_{w,b} \|\vec{w}\|^2 / 2 \\ \text{s:t } y_i(\vec{w} * \vec{x}) \geq 1 \quad 1 \leq i \leq N \end{cases} \quad (14)$$

式中:  $N$  为数据量;  $x$  是数据点;  $y_i$  为数据类别。

通过引入 Lagrange 乘子  $\alpha$  与松弛变量  $\zeta$  将上述问题转化为如下对偶问题

$$\begin{cases} \min_{\alpha} \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j K(x_i, x_j) \alpha_i \alpha_j - \sum_{i=1}^N \alpha_i \\ \text{s:t } 0 \leq \alpha_i \leq C \quad 1 \leq i \leq N \\ \sum_{i=1}^N \alpha_i y_i = 0 \end{cases} \quad (15)$$

式中,  $C$  为惩罚因子常量, 通过 SMO 算法与 KKT 判定条件, 便可求出所有  $\alpha_i$ , 通过该乘子便可判断样本点  $(x_i, y_i)$  是否被正确分类。

1)  $\alpha_i = 0 \Leftrightarrow y_i \mu_i > 1$ , 表明数据点  $x_i$  被正确分类, 位于各自最优分类面内部。

2)  $\alpha_i = C \Leftrightarrow y_i \mu_i \leq 1$ , 表明数据点  $x_i$  被错误分类, 位于两类最优分类面之间。

3)  $0 < \alpha_i < C \Leftrightarrow y_i \mu_i = 1$ , 表明数据点  $x_i$  是支持向量, 位于最优分类面上。

综上, 定义正确率  $SK_{ij}$  来标定类间易分度:

$$SK_{ij} = N_{ij}^{\text{co}} / N_{ij}^{\text{all}} \quad (16)$$

式中:  $N_{ij}^{\text{co}}$  表示类  $K_i$  与类  $K_j$  中正确分类的样本数, 这些样本均满足 KKT 条件,  $K_j$  越大, 说明类  $K_i$  与类  $K_j$  更容易被分开;  $N_{ij}^{\text{all}}$  为样本总数。

### 2.2 样本类间空间分离程度的分析

扰动信号采样点  $P$  的特征量, 即  $P(x_i, y_i, z_i)$ , 分别表示相应的基频幅值变换峭度  $F_B$ 、高频幅值变

化峭度  $F_H$ 、总谐波畸变率  $THD$ , 因此通过采样点形成的三维矩阵空间分布耦合程度判断各类间的易分度, 定义如下变量。

1) 类的样本标准差  $\alpha_i(x_\alpha, y_\alpha, z_\alpha)$

$$x_\sigma = \sqrt{\sum_{i=1}^N (x_i - \frac{1}{N} \sum_{i=1}^N x_i)^2} / N \quad (17)$$

其中:  $N$  为采样点数;  $x_i$  为第  $i$  个采样点行坐标。

2) 类  $K_i$  与类  $K_j$  样本中心距离  $D_{ij}(x_d, y_d, z_d)$

$$x_d = \frac{1}{N} \left\| \sum_{i=1}^N x_i - \sum_{j=1}^N x_j \right\| \quad (18)$$

3) 类  $K_i$  与类  $K_j$  不可分离程度  $S_{ij}(x_{ij}, y_{ij}, z_{ij})$

$$x_{ij} = (x_{\alpha_i} + x_{\alpha_j} - x_d) / x_d \quad (19)$$

4) 类  $K_i$  与类  $K_j$  辨识度  $R_{ij}$

同理分别计算 Y 轴与 Z 轴的不可分离程度  $y_{ij}$ 、 $z_{ij}$ , 选取最大值作为分辨率  $R_{ij}$ 。

$$R_{ij} = \max(\{x_{ij}, y_{ij}, z_{ij}\}) \quad (20)$$

若  $R_{ij} \leq 0$ , 说明类  $i$  与类  $j$  空间分布完全分离, 否则至少有某一维空间分布是相交的,  $R_{ij}$  越小, 分离程度越高。

### 2.3 优化的 DDAGSVM 分类器算法描述

其算法流程图如表 3 所示, 详细说明如下。

1) 现有  $K$  类样本数据需要分类, 其数据集为  $D_i \sim D_j (1 \leq i, j \leq K)$ , 将其两两交叉训练生成  $K(K-1)/2$  个超平面分类函数  $F_{ij}$ , 其表达式为

$$F_{ij}(x) = \sum_{p=1}^N \alpha_p y_p K(x_p, x) + b \quad (i \neq j) \quad (21)$$

式中:  $N$  是两类样本的所有数据总量;  $p$  是支持向量;  $\alpha$  是支持向量对应的 Lagrange 乘子; 若  $F_{ij}(x) < 0$ , 则数据  $x$  属于类  $i$ , 否则属于类  $j$ 。

2) 利用式(16)计算两类的辨识度  $SK_{ij}$ , 组成  $K \times K$  维对称矩阵  $V_{kkt}$ , 其中  $S_{ij} = S_{ji}$ 。

$$V_{kkt} = \begin{pmatrix} 0 & SK_{12} & \dots & SK_{1k} \\ SK_{21} & 0 & \dots & SK_{2k} \\ \vdots & \vdots & 0 & \vdots \\ SK_{k1} & SK_{k2} & \dots & 0 \end{pmatrix} \quad (22)$$

3) 将样本集  $D_i - D_j$  所构成的三维空间矩阵利用式(17)~式(20)计算分辨率  $R_{ij}$ , 同样构建  $K \times K$  维对称矩阵  $V_R$ , 其中  $F_{ij}(x) > 0$ , 并将  $V_R$  做归一化处理。

$$V_R = \begin{pmatrix} 0 & R_{12} & \dots & R_{1k} \\ R_{21} & 0 & \dots & R_{2k} \\ \vdots & \vdots & 0 & \vdots \\ R_{k1} & R_{k2} & \dots & 0 \end{pmatrix} \quad (23)$$

表 3 优化 DDAGSVM 算法

Table 3 Optimized DDAGSVM algorithm

1	将 $K$ 类样本集 $D_1 \sim D_j$ 训练生成 $K(K-1)/2$ 个超平面分类函数 $F_{ij}(1 \leq i, j \leq K)$
2	利用式 2.4 计算每个分类函数 $F_{ij}$ 的正确率 $SK_{ij}$ , 并构建矩阵 $V_{kkt}$
3	利用式 2.5—2.9 计算样本集 $D_1 \sim D_j$ 的分辨率 $R_{ij}$ , 构建矩阵 $V_R$
4	构建判决矩阵 $V_T = V_{kkt} - V_R$ , 并选取最大元素对应超平面函数作为分类器根节点
5	while( $t < k-1$ ) <ul style="list-style-type: none"> <li>if(<math>F_{mn}(X_0) &gt; 0</math>)                         <ul style="list-style-type: none"> <li><math>V_T(n,:) = 0</math> &amp; <math>V_T(:,n) = 0</math></li> <li><math>V_T(m,j) = \max(V_T(m,:))</math></li> <li><math>F_{mn} = F_{mi}</math></li> </ul> </li> <li>else                         <ul style="list-style-type: none"> <li><math>V_T(m,:) = 0</math> &amp; <math>V_T(:,m) = 0</math></li> <li><math>V_T(n,j) = \max(V_T(n,:))</math></li> <li><math>F_{mn} = F_{ni}</math></li> </ul> </li> <li><math>t = t + 1</math></li> </ul> end if( $F_{mn}(X_0) < 0$ ) <ul style="list-style-type: none"> <li><math>X_0 \in</math> 类 <math>m</math></li> </ul> else <ul style="list-style-type: none"> <li><math>X_0 \in</math> 类 <math>n</math></li> </ul> end

4) 构建判决矩阵  $V_T = V_{kkt} - V_R$ , 若  $SK_{ij}$  越大, 说明分类率越高, 则  $V_R[i, j]$  越小, 说明该两类类间分离度越高,  $V_T$  中相应的  $V_T[i, j]$  越大, 因此选取  $V_T$  中值最大的元素, 其所代表的两类数据类间分类度最高, 如此会降低此后分类的累计误差, 假设  $V_T[i, j]$  为最大值, 则将对应的分类函数  $F_{ij}$  作为分类器根节点。

5) 对于数据点  $X_0$  的分类, 将其带入第 4 步所求的最优根节点分类函数, 若  $F_{ij}(X_0) > 0$ , 表明  $X_0$  不属于类  $j$ , 将第 3 步所得矩阵  $V_T$  的第  $j$  行与第  $j$  列置 0, 然后在  $V_R$  的第  $i$  行选取最大元素, 并将其对应的分类函数作为新的节点参与分类, 循环上述步骤直至确定唯一分类函数  $F_{mn}$ , 若  $F_{mn}(X_0) > 0$ , 则  $X_0$  属于类  $m$ , 否则属于类  $n$ , 至此算法结束, 分类完毕。

### 3 DDAGSVM 算法验证仿真分析

为了验证该算法的鲁棒性, 本实验依照表 1 标

准对 9 种扰动信号分别在  $SNR=20/30/40/50$  dB 高斯白噪声环境下生成  $4 \times 300$  个实验样本, 总共 10800 个样本数据。根据前面分析对每个样本提取基频幅值变换峭度  $F_B$ , 高频幅值变化峭度  $F_H$ , 总谐波畸变率  $THD$  三个特征量, 作为训练支持向量机的输入量, 训练样本与测试样本数量按 2:1 划分, 表 4 为  $SNR=20/30/40/50$  dB 时传统 DDAGSVM 算法与改进 DDAGSVM 算法分类精确率比较, 这里 SVM 训练核函数采用 RBF 决策函数,  $\gamma$  函数取 0.1, 损失函数参数  $C=1$ 。

### 4 结论

从表 4 可以看出, 改进后的 DDAGSVM 算法在电能质量扰动信号识别方面准确率要优于文献 [12], 且具有较强的鲁棒性, 本文首先利用 FFT 变换和 S 变换对电能扰动信号进行时频域分析, 再结合 SVM 的决策能力, 同时将 KKT 判定和类空间分布结合起来减少分类时的累计误差, 为分类器根节点的选择制定了标准, 同时 DDAGSVM 分类器的构造简单, 算法易于实现, 具有较强的普适性和应用价值。

表 4 算法鲁棒性及分类准确率对比

Table 4 Algorithm robustness and classification accuracy

扰动类型	分类准确率/%							
	SNR=20 dB		SNR=30 dB		SNR=40 dB		SNR=50 dB	
	传统	改进	传统	改进	传统	改进	传统	改进
C1	91.2	95.3	92.1	98.8	93.1	98.6	95.1	99.4
C2	92.3	99.6	93.1	98.8	94.6	99.6	95.1	100
C3	89.6	100	90.1	99.6	90	99.3	92.1	100
C4	94.5	100	95.1	100	95.6	100	96.2	100
C5	93.1	95.8	93.3	98.3	95.2	100	96.3	100
C6	95.1	98.6	95.6	100	98.6	100	99.2	100
C7	94.5	98.7	95.1	99.3	97.2	100	98.3	100
C8	95	99.1	96.2	99.6	96.8	100	97.6	100
C9	87.2	96.4	90.1	97.4	95	98.2	96.2	99.2

### 参考文献

[1] 程浩忠, 艾芊, 张志刚. 电能质量[M]. 北京: 清华大学出版社, 2006.

[2] 张逸, 林焱, 吴丹岳. 电能质量监测系统研究现状及发展趋势[J]. 电力系统保护与控制, 2015, 43(2): 138-147.

ZHANG Yi, LIN Yan, WU Danyue. Current status and development trend of power quality monitoring system[J]. Power System Protection and Control, 2015, 43(2): 138-147.

[3] 黄南天, 徐殿国, 刘晓胜. 基于 S 变换与 SVM 的电能

- 质量复合扰动识别[J]. 电工技术学报, 2011, 26(10): 24-28.  
HUANG Nantian, XU Dianguo, LIU Xiaosheng. Recognition of power quality complex disturbance based on S-transform and SVM[J]. Transactions of China Electrotechnical Society, 2011, 26(10): 24-28.
- [4] 覃星福, 龚仁喜. 基于广义 S 变换与 PSO-PNN 的电能质量扰动识别[J]. 电力系统保护与控制, 2016, 44(5): 10-17.  
QIN Xingfu, GONG Renxi. Power quality disturbances classification based on generalized S-transform and PSO-PNN[J]. Power System Protection and Control, 2016, 44(5): 10-17.
- [5] 陈华丰, 张葛祥. 基于决策树和支持向量机的电能质量扰动识别[J]. 电网技术, 2013, 37(5): 1273-1276.  
CHEN Huafeng, ZHANG Gexiang. Power quality disturbance identification based on decision tree and support vector machine[J]. Power System Technology, 2013, 37(5): 1273-1276.
- [6] 肖助力, 龚仁喜, 陈双, 等. 基于改进 S 变换的电力系统谐波监测方法[J]. 电力系统保护与控制, 2015, 43(3): 84-90.  
XIAO Zhuli, GONG Renxi, CHEN Shuang, et al. Detection of harmonics in power system based on modified S-transform[J]. Power System Protection and Control, 2015, 43(3): 84-90.
- [7] 殷少戈, 余南华, 李传健, 等. 基于 S 变换的电能质量扰动特征提取[J]. 电源技术, 2014, 38(12): 2412-2414.  
YIN Shaoge, YU Nanhua, LI Chuanjian, et al. Feature extraction of power quality disturbance based on S transform[J]. Chinese Journal of Power Sources, 2014, 38(12): 2412-2414.
- [8] 张志禹, 满蔚仕, 郝垒, 等. 快速 S 变换在电能质量分析中的应用[J]. 电网技术, 2013, 37(5): 1286-1288.  
ZHANG Zhiyu, MAN Weishi, XI Lei, et al. Application of fast S-Transform in power quality analysis[J]. Power System Technology, 2013, 37(5): 1286-1288.
- [9] 唐求. 电能质量智能监测算法及其应用研究[D]. 长沙: 湖南大学, 2010: 85-89.  
TANG Qiu. Research on power quality intelligent monitoring algorithm and its application[D]. Changsha: Hunan University, 2010: 85-89.
- [10] 付娟, 周汉勇, 姜勤. 基于 S 变换的暂态电能质量扰动检测与仿真[J]. 电力系统保护与控制, 2009, 37(21): 86-89.  
FU Juan, ZHOU Hanyong, JIANG Qin. Power quality detection and simulation using S-transform[J]. Power System Protection and Control, 2009, 37(21): 86-89.
- [11] 陈春玲, 许童羽, 郑伟, 等. 多类分类 SVM 在电能质量扰动识别中的应用[J]. 电力系统保护与控制, 2010, 38(13): 74-78.  
CHEN Chunling, XU Tongyu, ZHENG Wei, et al. Application of multi-class classification SVM in power quality disturbance recognition[J]. Power System Protection and Control, 2010, 38(13): 74-78.
- [12] 史朝辉, 王坚, 华继学, 等. 一种改进的 DDAGSVM 决策算法[J]. 空军工程大学学报(自然科学版), 2015, 16(2): 53-54.  
SHI Chaohui, WANG Jian, HUA Jixue, et al. An improved DDAGSVM decision algorithm[J]. Journal of Air Force Engineering University (Natural Science Edition), 2015, 16(2): 53-54.
- [13] 孟媛媛, 刘希玉. 一种新的基于二叉树的 SVM 多类分类方法[J]. 计算机应用, 2005, 25(11): 2653-2654.  
MENG Yuanyuan, LIU Xiyu. A new SVM multi-class classification method based on binary tree[J]. Journal of Computer Applications, 2005, 25(11): 2653-2654.
- [14] LI J, TENG Z, TANG Q, et al. Detection and classification of power quality disturbances using double resolution S-Transform and DAG-SVMs[J]. IEEE Transactions on Instrumentation and Measurement, 2016, 65(10): 2307-2310.
- [15] SHILPA R, PRABHU S, PUTTASWAMY P S. Power quality disturbances monitoring using Hilbert-Huang transform and SVM classifier[C]// International Conference on Emerging Research in Electronics, Computer Science and Technology, 2015, Mandya, India: 6-10.

收稿日期: 2017-03-04; 修回日期: 2017-05-09

作者简介:

任子晖(1962—), 男, 教授, 博士生导师, 研究方向为电网谐波治理、通风机监测研究工作; E-mail: ren\_zicumt@126.com

王琦(1991—), 男, 通信作者, 硕士研究生, 研究方向为电能质量监测与控制。E-mail: 18361242518@163.com

(编辑 葛艳娜)