

文章编号: 1001-0920(2011)04-0587-05

基于改进S变换和贝叶斯相关向量机的电能质量扰动识别

沈跃, 刘国海, 刘慧

(江苏大学电气信息工程学院, 江苏镇江 212013)

摘要: 提出一种改进S变换和相关向量机相结合的电能质量扰动分类法. 首先通过引入调节因子构建时频分辨率可控的改进S变换, 从而提取各类扰动信号的时频特性; 然后利用层次分类法与最小输出编码法构建贝叶斯相关向量机多级分类树模型, 实现电能质量扰动信号的分类与识别. 研究表明, 该方法能在强噪声背景下获得高精度的扰动分类识别率, 具备比S变换更高的时频分析能力, 较支持向量机需要更少的相关向量数目, 测试时间更短.

关键词: 电能质量; 扰动识别; 改进S变换; 相关向量机; 支持向量机

中图分类号: TN911

文献标识码: A

Classification identification of power quality disturbances based on modified S-transform and Bayes relevance vector machine

SHEN Yue, LIU Guo-hai, LIU Hui

(School of Electrical and Information Engineering, Jiangsu University, Zhenjiang 212013, China. Correspondent: SHEN Yue, E-mail: shen@ujs.edu.cn)

Abstract: A method classifying power quality disturbances(PQD) based on modified S-transform and relevance vector machine(RVM) is presented. The modified S-transform(MST) is achieved by adding three adjustable factors to the Gaussian window function of the normal S-Transform. The adjustable factors change the velocity in which the width of the window function varies with the frequency. The PQD sample eigenvectors can be extracted accurately by using the modified S-transform with better time-frequency analysis performance than the S-Transform. Then the disturbance types are identified through the multi-lay RVM pattern recognition classifier on hierarchical categorization and minimum output coding. Numerical results show that the proposed MST-based RVM method can achieve higher classification accuracy quickly, and requires substantially fewer relevance vectors and shorter test time than the SVM classifier.

Key words: power quality; disturbance identification; modified S-transform; relevance vector machine; support vector machine

1 引言

电能质量扰动类型众多且复杂, 如何从电能质量扰动信号中提取特征并进行正确分类是电能质量治理迫切需要解决的问题之一. 短时傅里叶变换^[1]用于非平稳信号处理时, 其时-频窗口固定不变, 不具备自适应性. 小波变换强大的多尺度分析特性可以提供电能质量扰动信号不同尺度的特征^[2], 但反映高频信号的尺度往往因噪声而无法正确提取某些电能质量扰动. 文献[3]将dq变换和小波变换相结合, 利用dq变换有效值的特征和小波变换对突变信号的敏感性, 对多种电能质量扰动进行检测与识别, 但对于单相系统

必须将其构造成三相或多相. [4]将S变换用于电能质量扰动特征的提取, 采用神经网络进行扰动分类. [5]提出了基于S变换的电能质量扰动支持向量机(SVM)分类识别方法. [6]将S变换用于不同原因产生的电压凹陷类型识别. [7]提出一种基于S变换的概率神经网络电能质量扰动分类器, 比小波变换特征提取方法所需的特征量少. 对于分类方法, 神经网络^[2,4,7]具有简单的结构和强大的问题求解能力, 可较好地处理噪声数据, 但存在收敛性差、训练时间较长、所需样本数较大等问题. 支持向量机分类方法^[5]所需训练样本少, 但缺乏必要的预测概率信息,

收稿日期: 2009-12-28; 修回日期: 2010-11-13.

基金项目: 国家自然科学基金项目(60874014); 江苏省高校自然科学基金项目(10KJB470003); 镇江市科技培育项目(SH2008005); 江苏大学高级人才启动基金项目(10JDG136).

作者简介: 沈跃(1978—), 男, 讲师, 博士生, 从事电力电子与电能质量、机器人控制等研究; 刘国海(1964—), 男, 教授, 博士生导师, 从事电力电子与电能质量、电气传动及自动化控制等研究.

需要估计正规化参数,所需核函数的数量会随着训练集的增大而显著增加。

针对上述问题,本文提出一种改进的广义S变换特征提取方法,以期根据扰动信号的特性来加快或减慢时频窗宽度随频率变化的速度,更好地提取各类扰动信号的时频特征;同时将相关向量机(RVM)分类器^[8-9]应用于电能质量扰动分类研究。RVM利用贝叶斯框架构建学习机,与SVM相比泛化能力更好、解更为稀疏。仿真分析表明了改进S变换和RVM分类器相结合的电能质量扰动分类方法的有效性。

2 改进S变换的相关定义

标准S变换^[6,10]高斯窗函数的标准差可表示为

$$\sigma(f) = 1/|f|. \quad (1)$$

对S变换的高斯窗函数进行改造,引入3个调节因子 λ , a 和 b ,其标准差表达式为

$$\sigma(f) = \lambda/(a + b|f|). \quad (2)$$

式中: λ 为正整数, a 和 b 为非负整数。于是改进的高斯窗函数表达式为

$$w(\tau - t, f) = \frac{a + b|f|}{\lambda\sqrt{2\pi}} e^{-\frac{(\tau-t)^2(a+b|f|)^2}{2\lambda^2}}. \quad (3)$$

经过改进,窗函数的S变换表达式为

$$S(\tau, f) = \int_{-\infty}^{+\infty} x(t) \left[\frac{a + b|f|}{\lambda\sqrt{2\pi}} e^{-\frac{(\tau-t)^2(a+b|f|)^2}{2\lambda^2}} \right] e^{-i2\pi ft} dt. \quad (4)$$

改进的S变换窗函数具有以下性质:

1) 当 $b = 0$ 且 $a(a > 0)$ 和 λ 为常数时, $\sigma(f) = \lambda/a$,则时-频窗口大小固定不变,与频率 f 无关,即为短时傅里叶变换窗函数。

2) 当 $a = 0$ 且 $b = 1$, $\lambda = 1$ 时, $\sigma(f) = 1/|f|$,则时-频窗口大小具有自适应性,时窗宽与频率 f 呈反比,频窗宽与频率 f 呈正比。低频时采用大时窗、小频窗;高频时采用小时窗、大频窗,即为S变换。

3) 当 $a = 0$ 且 $b(b > 0)$ 和 λ 为常数时, $\sigma(f) = \lambda/(b|f|)$,则时-频窗口大小与频率 f , λ 和 b 有关。若 $b/\lambda > 1$,则时窗宽随频率 f 呈反比的速度加快;反之,则减慢。若 $b/\lambda = 1$,则相当于上述性质2)所阐述的S变换。

4) 当 $a(a > 0)$, $b(b > 0)$ 和 λ 为常数时, $\sigma(f) = \lambda/(a + b|f|)$,则时-频窗口大小与频率 f , λ , a 和 b 有关。若 $\sigma(f)$ 值增大,则时窗变宽,时域分辨率降低,频窗变窄,频域分辨率升高;反之,若 $\sigma(f)$ 值减小,则时窗变窄,时域分辨率升高,频窗变宽,频域分辨率降低。通过调整调节因子参数 a , b 和 λ ,可获取高精度的时频分辨率。因此改进的S变换实际上是一种广义S变换,短时傅里叶变换和S变换均可视为其特例。根据

实际信号的特点调整调节因子以控制时频分辨率。

改进S变换的离散表达式为

$$S\left[jT, \frac{n}{NT}\right] = \sum_{m=0}^{N-1} X\left[\frac{m+n}{NT}\right] e^{-\frac{2\pi^2 m^2 \lambda^2}{(aN T + bn)^2}} e^{i\frac{2\pi m j}{N}}. \quad (5)$$

式中: $j, m, n = 0, 1, \dots, N-1$; i 为虚数单位; $X\left[\frac{n}{NT}\right]$ 为信号 $x(t)$ 的离散傅里叶变换,其表达式为

$$X\left[\frac{n}{NT}\right] = \frac{1}{N} \sum_{k=0}^{N-1} x[kT] e^{-i\frac{2\pi n k}{N}}, \quad n = 0, 1, \dots, N-1. \quad (6)$$

其中: $x[kT](k = 0, 1, \dots, N-1)$ 为 $x(t)$ 的离散时间序列,采样间隔为 T ,总采样数为 N 。

改进S变换的计算步骤如下:

1) 计算 $x(t)$ 离散序列 $x[kT]$ 的快速傅里叶变换 $X\left[\frac{m}{NT}\right]$,将 $X\left[\frac{m}{NT}\right]$ 扩充维数到 $X\left[\frac{m+n}{NT}\right]$;

2) 计算改进S变换窗函数的快速傅里叶变换

$$G(m, n) = e^{-\frac{2\pi^2 m^2 \lambda^2}{(aN T + bn)^2}};$$

3) 按照频率采样点计算 $X\left[\frac{m+n}{NT}\right]G(m, n)$;

4) 计算 $X\left[\frac{m+n}{NT}\right]G(m, n)$ 的快速傅里叶变换逆变换,得到S变换谱 $S\left[jT, \frac{n}{NT}\right]$ 。

显然,采样序列 $x[kT]$ 的改进S变换结果是一个复时频矩阵,记为改进S矩阵。对各个元素求模后得到的矩阵记为改进S模矩阵,其列向量为某一时刻随频率变化的分布,行向量为某一频率随时间变化的分布。因此,改进S模矩阵某位置上元素的大小即为相应频率和时间处信号改进S变换的幅值。

3 相关向量机原理

3.1 相关向量机分类模型

给定训练数据集 $\{x_i, t_i\}_{i=1}^N$ 。相关向量机的模型预测函数为

$$y(x; w) = \sum_{i=1}^N \omega_i K(x, x_i) + \omega_0. \quad (7)$$

式中: $K(x, x_i)$ 为核函数, $w = (\omega_0, \omega_1, \dots, \omega_N)^T$ 为权值向量。在二分类情况下,对输出 $y(x; w)$ 应用logistic sigmoid函数 $\sigma(y) = 1/(1 + e^{-y})$ 泛化线性模型。设 $p(t|x)$ 服从贝努利分布,则整个数据集的似然函数可表示为

$$p(t|w) = \prod_{i=1}^N \sigma[y(x_i; w)]^{t_i} \{1 - \sigma[y(x_i; w)]\}^{1-t_i}. \quad (8)$$

式中: $t_i \in \{0, 1\}$, $t = (t_1, \dots, t_N)^T$ 。

3.2 贝叶斯参数推理和超参数优化

为避免过学习现象,稀疏贝叶斯方法给权值参数加上条件概率分布的限制,定义权重 w 的先验分布为

依赖于超参数 α 的高斯分布, 即

$$p(w|\alpha) = \prod_{i=0}^N N(\omega_i|0, \alpha_i^{-1}), \quad (9)$$

式中 $\alpha = (\alpha_0, \alpha_1, \dots, \alpha_n)^T$ 是决定权值 w 先验分布的超参数. 采用拉普拉斯法估计超参数 α 和权重 w .

1) 对于当前固定 α 值, 求“最可能”权重 w_{MP} . 由 $p(w|t, \alpha) \propto p(t|w)p(w|\alpha)$ 可知, 求解转化为寻找下式取最大值之处的 w_{MP} :

$$\log\{p(t|w)p(w|\alpha)\} = \sum_{i=1}^N \left[t_i \log y_i + (1 - t_i) \log(1 - y_i) - \frac{1}{2} w^T A w \right]. \quad (10)$$

式中: $y_i = \sigma[y(x_i; w)]$, $A = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$. 式(10)是一个正则化的 logistic 对数似然函数.

2) 使用拉普拉斯法求对数后验在其峰值附近的二次逼近, 即

$$g = \nabla_w \log\{p(t|w)p(w|\alpha)\} = \Phi^T(t - y) - A w, \quad (11)$$

$$H = \nabla_w \nabla_w \log\{p(t|w)p(w|\alpha)\} = (-\Phi^T B \Phi - A). \quad (12)$$

式中

$$y = [y_1, y_2, \dots, y_N]^T, \quad B = \text{diag}(\beta_1, \beta_2, \dots, \beta_N),$$

$$\beta_n = y_n(1 - y_n), \quad \Phi = [\Phi(x_1), \Phi(x_2), \dots, \Phi(x_N)],$$

$$\Phi(x_n) = [1, K(x_n, x_1), K(x_n, x_2), \dots, K(x_n, x_N)].$$

对式(12)取负号求逆, 得权值后验协方差矩阵

$$\Sigma = (-H|_{w_{MP}})^{-1} = (\Phi^T B \Phi + A)^{-1}. \quad (13)$$

利用式(13)和 $g|_{w_{MP}} = 0$, 得到权值后验均值

$$w_{MP} = \sum \Phi^T B t. \quad (14)$$

3) 利用统计量 Σ 和 w_{MP} 更新超参数

$$\alpha_i^{\text{new}} = \frac{\gamma_i}{(w_{MP})_i^2}, \quad i = 0, 1, \dots, N, \quad (15)$$

式中: $\gamma_i = 1 - \alpha_i \Sigma_{ii}$, Σ_{ii} 是 Σ 中的第 i 项对角线元素.

获得参数 α_i^{new} 后, 重新估计权重的后验均值和方差. 在迭代估计过程中, 大部分 α_i 值会越来越接近于无穷大, 即对应的 ω_i 为 0, 其相应的基函数可以删除, 从而达到稀疏性. 其余的 α_i 会稳定趋近有限值, 与之对应的 x_i 即称为相关向量.

4 电能质量扰动分类

4.1 电能质量扰动分类

电力系统最常见的电能质量扰动有电压暂降、电压暂升、电压中断、暂态振荡、暂态脉冲、电压尖峰、电压缺口、电压闪变以及谐波等. 本文采用 Matlab 生成扰动信号样本. 采样频率为 5000 Hz, 电压基波频率为 50 Hz, 扰动信号长度为 10 个周波, 每种扰动随机生成 300 个测试样本.

4.2 改进S变换的扰动特征分析

根据不同扰动信号的特性对改进 S 变换参数 λ , a 和 b 进行调整以获取合适的时频分辨率. 分析可知, 大部分扰动类型的频率特性非常明显, 需要较高的频率分辨率, 同时兼顾时间分辨率, 这里取参数 $\lambda = 4, a = 1, b = 2$.

限于篇幅, 图 1 只给出了电压尖峰扰动的改进 S 变换检测结果. 其中: 图 1(a) 为信噪比 40 dB 的扰动信号波形; 图 1(b) 为改进 S 变换时频等值线图; 图 1(c) 为模矩阵基波额定频率幅值曲线; 图 1(d) 为模矩阵各行向量最大值频谱曲线, 反映了扰动信号中包含的主要频率成分及其频谱幅值.

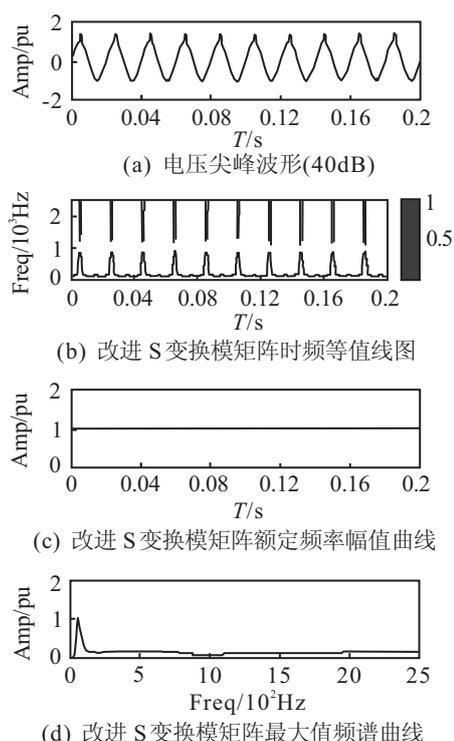


图 1 电压尖峰的改进 S 变换检测

为了有效提取各类扰动特性, 采用以下几种改进 S 变换特征量:

特征 1 模矩阵各列向量最大值数据集的标准差, 记为 F_1 . 分析可知, 暂升、暂降、中断等暂态扰动的 F_1 特征标准差值较大, 而正常电压、谐波、闪变以及尖峰和缺口等稳态性能显著的扰动标准差值较低. 脉冲和振荡等虽然属于高频特性扰动, 但反映基频波动情况的 F_1 特征值变化并不明显.

特征 2 模矩阵各行向量最大值数据集的标准差, 记为 F_2 . 该特征量反映了扰动的主要频率成分及频谱幅值的差异. 利用该特征量可有效区分正常电压、谐波、尖峰、缺口, 也可将暂升、暂降、中断、脉冲和振荡等暂态扰动区分为具有高频的脉冲、振荡组别

和低频的暂升、暂降、中断组别。

特征3 模矩阵各列向量最大值数据集的能量, 记为 F_3 . 该特征量反映了扰动基频成分的能量, 可有效区分暂升、暂降和中断。

特征4 暂态扰动的持续时间, 记为 F_4 . 由于暂态脉冲和振荡发生持续的时间不同, 该特征可有效区分这两种高频暂态扰动. 另外, 对于尖峰和缺口等兼备暂稳态特性的扰动信号类型, 可将特征 F_4 与特征 F_2 等结合, 并与其他稳态扰动类型相区分. 对于谐波等稳态扰动, 可将特征量 F_4 取为一大值常数以便于后续识别。

通过分析可知, 以上任意一种特征量只具备对部分扰动类型的区别能力, 而4种特征相互交织构成特征向量 $\{F_1, F_2, F_3, F_4\}$ 共同作用, 才能有效地提取出各类电能质量扰动特性。

4.3 相关向量机多分类树模型

针对扰动及正常信号的特点, 首先应用层次分类法(HC)将扰动分为两大类: 一类为正常电压、尖峰、缺口、振荡、脉冲、谐波, 另一类为暂升、暂降、中断、闪变; 然后使用聚类思想进一步划分, 直到每个子类的扰动类型为2~4个; 最后利用最小输出编码法(MOC)完成终节点的分类. 最小输出编码法对于 k 个类别的样本只需建立 $\log_2 k$ 个分类器, 计算量小、容易实现. 例如对于3种或4种扰动分类问题只需2个二类分类器. 因此层次分类法和最小输出编码法相结合, 在应用聚类思想的同时有效减少了分类器总数. 基于以上方法便可构建电能质量扰动RVM多分类树模型。

5 仿真研究

通过下面仿真例子验证本文基于改进S变换的电能质量扰动RVM多分类法的有效性, 并与SVM进行比较. RVM选择RBF核函数, 核宽 $\delta = 0.5$, 超参数 α 的各元素初值为0.1. SVM容错系数 C 取值0.9, 其他参数与RVM相同。

5.1 两种扰动类型的RVM二分类研究

为了直观地比较RVM与SVM的分类性能, 以信噪比为20 dB的暂态振荡和暂态脉冲扰动二分类问题为例, 考察其训练和测试结果. 训练和测试样本数均为400个. 图2显示了暂态振荡和暂态脉冲扰动的SVM训练结果三维图. 坐标参数 $F_1 \sim F_3$ 为改进S变换提取的特征分量(受图形显示局限, F_4 未画出), 图2中标示出训练样本的特征值、支持向量以及SVM三维分类面. SVM的支持向量个数(Svs)为230, 测试分类准确率为97.0%, 测试时间为0.2256 s. 由数据和图2可知, SVM能较好地将暂态

振荡与脉冲两类分离开, 但Svs数目较大, 占训练样本总数的57.5%。

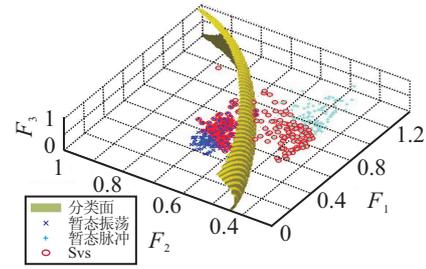


图2 暂态振荡和暂态脉冲的SVM分类训练三维图

图3为暂态振荡与暂态脉冲扰动的RVM训练结果三维图. 其中: 标出了训练样本特征值和相关向量, 画出了RVM的三维分类面. RVM的相关向量个数(Rvs)为3, 测试分类准确率为99.0%, 样本集测试时间为0.0008 s. 可见RVM能高效地将暂态振荡与暂态脉冲分离, 分类准确率略高于SVM, Rvs则远远少于Svs, 测试时间也小于后者。

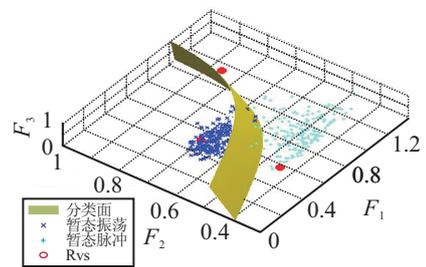


图3 暂态振荡和暂态脉冲的RVM分类训练三维图

5.2 多种扰动类型的RVM多分类研究

5.2.1 电能质量扰动

表1给出了在不同训练/测试样本数目下, 两种分类方法获得的平均分类准确率、平均支持向量数(mSvs)/平均相关向量数(mRvs)以及测试时间结果。

表1 RVM和SVM分类结果比较

训练/测试样本数	平均准确率/%		mSvs/mRvs		测试时间/s	
	SVM	RVM	mSvs	mRvs	SVM	RVM
100/1 000	89.2	92.5	42	2	0.182 0	0.067 8
200/1 000	93.1	95.8	69	3	0.365 3	0.085 9
400/1 000	94.9	97.4	231	5	0.835 8	0.094 5
600/1 000	96.3	99.2	265	9	1.594 3	0.123 0
800/1 000	96.5	99.7	349	10	3.057 8	0.169 8
1 000/1 000	97.9	99.8	418	15	5.667 1	0.253 8

以训练/测试样本数100/1 000为例, RVM的分类准确率为92.5%, 明显高于SVM的分类准确率89.2%; RVM的平均相关向量数为2, 远少于SVM的平均支持向量数42; RVM测试时间为0.0678 s, 约为SVM测试时间0.1820 s的1/3. 随着训练集数目的

渐增, 两种分类方法获得的分类准确率也相应增大, RVM分类准确率仍略高于SVM. 当训练/测试样本数目为1000/1000时, RVM的分类准确率为99.8%, 高于SVM的分类准确率97.9%; RVM的平均相关向量数为15, 远远少于SVM的平均支持向量数418; SVM测试时间增至5.6671s, 而RVM测试时间仍保持较低值0.2538s.

5.2.2 不同信噪比下各种电能扰动

各类扰动的训练和测试样本均为1000个. 分类结果如表2所示. 信噪比分别为40dB, 30dB, 20dB时RVM平均分类准确率分别达到99.80%, 98.69%和96.36%. 可见本文提出的基于改进S变换的RVM分类方法具备良好的抗噪能力, 在不同信噪比下能有效地提取扰动信号特征, 并获取高精度的分类结果.

表2 不同信噪比下RVM分类结果

扰动类型	平均准确率/%		
	40dB	30dB	20dB
电压正常	100	99.8	97.8
电压暂升	100	99.8	97.8
电压暂降	98.5	96.9	94.4
电压中断	99.6	97.4	92.8
电压闪变	100	99.6	96.9
暂态振荡	100	98.3	95.4
暂态脉冲	99.9	98.2	97.1
电压尖峰	100	99.8	97.5
电压缺口	100	99.1	96.3
谐波	100	98.5	96.8
平均准确率/%	99.80	98.69	96.36

6 结 论

本文提出了一种基于改进S变换和相关向量机的电能质量扰动识别方法. 引入调节因子对S变换高斯窗进行改造以构成改进S变换, 其本质上是一种广义S变换, 可以根据实际信号的特点通过调节因子控制时频率分辨能力, 具有强抗噪声鲁棒性. RVM分类法无需估计容错惩罚系数, 与SVM相比模型结构更简单, 解更稀疏, 对于小数据集测试样本具备更好的泛化能力. 研究表明, RVM多分类器与改进S变换特征提取相结合的识别法, 在强噪声背景下能高效快速地获取高分类准确率, 测试时间短, 更适合于在线测试.

参考文献(References)

- [1] Heydt G T, Fjeld P S, Liu C C, et al. Application of the windowed FFT to electric power quality assessment[J]. IEEE Trans on Power Delivery, 1999, 14(4): 1411-1416.
- [2] 林涛, 樊正伟. 利用小波变换及神经网络识别电能扰动[J]. 高电压技术, 2007, 33(7): 151-154. (Lin T, Fan Z W. Application of wavelet transform and artificial neural network to power disturbance identification[J]. High Voltage Engineering, 2007, 33(7): 151-154.)
- [3] Oscar C M, Prasad N E. A fast detection algorithm suitable for mitigation of numerous power quality disturbances[J]. IEEE Trans on Industry Applications, 2005, 41(6): 1684-1690.
- [4] Lee I W C, Dash P K. S-transform-based intelligent system for classification of power quality disturbance signals[J]. IEEE Trans on Power Delivery, 2003, 18(3): 800-805.
- [5] 吕干云, 程浩忠, 郑金菊, 等. 基于S变换和多级SVM的电能质量扰动检测识别[J]. 电工技术学报, 2006, 21(1): 121-126. (Lv G Y, Cheng H Z, Zheng J J, et al. Power quality disturbances detection and identification based on S transform and multi-layer SVMs[J]. Trans of China Electrotechnical Society, 2006, 21(1): 121-126.)
- [6] 杨洪耕, 刘守亮, 肖先勇, 等. 基于S变换的电压凹陷分类专家系统[J]. 中国电机工程学报, 2007, 27(1): 98-104. (Yang H G, Liu S L, Xiao X Y, et al. S-transform-based expert system for classification of voltage dips[J]. Proc of the CSEE, 2007, 27(1): 98-104.)
- [7] Mishra S, Bhende C N, Panigrahi B K. Detection and classification of power quality disturbances using S-transform and probabilistic neural network[J]. IEEE Trans on Power Delivery, 2008, 23(1): 280-287.
- [8] Tipping M E. Sparse Bayesian learning and the relevance vector machine[J]. J of Machine Learning Research, 2001, 1(3): 211-244.
- [9] Tipping M E. The relevance vector machine[J]. Advances in Neural Information Processing Systems, 2000(12): 652-658.
- [10] Stockwell R G, Mansinha L, Lowe R P. Localization of the complex spectrum: The S transform[J]. IEEE Trans on Signal Processing, 1996, 44(4): 998-1001.