

基于小波变换和 FRVM 的电能质量扰动分类

马苹苹 黄文清

(湖南大学电气与信息工程学院 长沙 410006)

摘 要 针对相关向量机(RVM)计算复杂度大、训练时间长的问题,提出一种基于快速相关向量机(FRVM)的优化算法,其大大减少了相关向量机的训练时间,提高了分类的精度。将它应用于电能质量扰动分类中,首先对电能质量扰动信号进行基于小波变换的时频分析,提取小波变换各层信号的能量与标准信号的能量之差组成特征向量;然后用 FRVM 对特征量进行分类,进而实现基于小波变换和 FRVM 的电能质量扰动分类新方法。实验仿真验证了该方法能够对各类电能质量扰动信号进行分类,并且其分类效率和准确率均优于传统的相关向量机分类方法。

关键词 电能质量,快速相关向量机,扰动分类

中图分类号 TP274.3 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.5.047

Classification of Power Quality Disturbances Based on Wavelet Transform and FRVM

MA Ping-ping HUANG Wen-qing

(School of Electrical and Information Engineering, Hunan University, Changsha 410006, China)

Abstract To reduce the computational complexity and long training time in relevance vector machine(RVM), this paper proposed an optimized algorithm based on fast relevance vector machine(FRVM), which not only greatly reduces the training time of relevance vector machine, but also improves its classification accuracy. This method is applied to the classification of power quality disturbances. Firstly, the wavelet transform is applied to analysis the time-frequency features of the power quality disturbances, and the difference of the energy of the wavelet transform signal in each layer and the standard signal energy is used as feature vector. Secondly, FRVM is used to classify the feature vector to realize power quality disturbances classification based on wavelet transform and FRVM. The simulation verifies that this method can classify all kinds of power quality disturbances, and has higher classification efficiency and accuracy than the classical RVM.

Keywords Power quality, FRVM, Disturbance classification

1 引言

为了有效解决电能质量扰动问题,我们通常会在电网中安装大量的电能质量监测装置,这样无疑会导致数据量增加。传统的人工分类方法显得不适合,所以实现电能质量扰动信号自动分类是电能质量治理亟待解决的问题之一。分类问题分为两步执行:首先建立分类模型,再把所建立的分类模型应用到目标数据库,对其进行分类。在建立分类模型时,又可分为两步:特征提取和分类器构造。

特征量可以从时域、频域或者时频域出发来提取,常用的有快速傅里叶变换^[1]、短时傅里叶变换^[2]、小波变换^[3]、S 变换^[4]等。电能质量扰动分类方法主要有专家系统^[5]、高阶累积量^[6]、支持向量机(Support Vector Machine, SVM)^[7]、人工神经网络^[8]和相关向量机(Relevance Vector Machine, RVM)^[9]等。其中较为常用的是基于 SVM 的电能质量扰动分类方法,该方法所需训练样本少,但是也有一定的缺点:无法获得概率信息,也无法获取预测中的不确定性;核函数必须

满足 Mercer 条件;惩罚因子的设置对实验结果影响很大,设置不当会引起过学习等问题;解相对而言是稀疏的,但所需核函数的个数随着训练样本的增大成线性增长。针对以上不足,Michael. E. Tipping 提出了相关向量机(Relevance Vector Machine, RVM)的概念。

RVM 是在贝叶斯框架的基础上提出的,与支持向量机(Support Vector Machine, SVM)相比, RVM 不仅可以获得二值输出,而且可以得到概率输出;选择核函数时不受梅西定理的限制,可以构建任意的核函数;不需要对惩罚因子做出设置;具有更好的泛化能力并且解也更为稀疏。所以本文提出了一种基于快速相关向量机(FRVM)的电能质量扰动分类方法。首先,通过小波算法对电能质量扰动信号进行时频分析提取扰动特征量;然后,用 FRVM 对特征量进行分类。

2 小波变换特征提取

2.1 电能质量扰动信号模型

本文考虑的电能质量扰动有:电压暂降、电压暂升、电压

到稿日期:2014-06-30 返修日期:2014-09-05

马苹苹(1989—),女,硕士生,主要研究方向为电能质量监测与分析、人工智能、信号处理等, E-mail: 313991640@qq.com; 黄文清(1968—),男,副教授,主要研究方向为电能质量监测与分析、信号检测与智能信息处理等。

中断、谐波、振荡暂态和瞬时脉冲。采样频率为 6.4kHz,电压基波频率为 50Hz,扰动信号长度为 15 个周波,利用 MATLAB 随机生成扰动信号样本。电能质量扰动信号模型如表 1 所列,其中, A 为扰动幅值; ω_0 为基波角频率; $u(t)$ 为单位阶跃函数; t_1 为扰动开始时刻; t_2 为扰动结束时刻; β 为基频倍数; T 为周期。

表 1 电能质量扰动信号模型

扰动类型	表达式
电压暂降	$x(t) = (1 - A[u(t-t_1) - u(t-t_2)]) \sin \omega_0 t$ $0.1 \leq A \leq 0.9, 5T \leq t_2 - t_1 \leq 10T$
电压暂升	$x(t) = (1 + A[u(t-t_1) - u(t-t_2)]) \sin \omega_0 t$ $0.1 \leq A \leq 0.8, 5T \leq t_2 - t_1 \leq 10T$
电压中断	$x(t) = (1 - A[u(t-t_1) - u(t-t_2)]) \sin \omega_0 t$ $0.9 \leq A \leq 1, 5T \leq t_2 - t_1 \leq 10T$
谐波	$x(t) = \sin \omega_0 t + A_3 \sin(3\omega_0 t) + A_5 \sin(5\omega_0 t) + A_7 \sin(7\omega_0 t)$ $0.05 \leq A_3, A_5, A_7 \leq 0.3$
振荡暂态	$x(t) = \sin \omega_0 t + Ae^{-100t} \sin 20\omega_0 t [u(t-t_1) - u(t-t_2)]$ $0.1 \leq A \leq 0.8, T \leq t_2 - t_1 \leq 3T$
瞬时脉冲	$x(t) = \{1 + A[u(t-t_1) - u(t-t_2)]\} \sin \omega_0 t$ $0.1 \leq A \leq 0.8, 5T \leq t_2 - t_1 \leq 5.1T$

2.2 扰动特征提取

采用小波变换对电能质量扰动信号进行 J 层分解,得到的小波变换细节系数为 $d_j(n)$, 其中, $j=1, 2, \dots, J$, 则其能量分布为 $E_{d_j} = \sum_n [d_j(n)]^2$, 这样经过 J 层小波分解得到信号在每一层的能量,再减去标准信号(正弦信号)能量 E_{mf} , 以得到的能量差元素 $E_j = E_{d_j} - E_{mf}$ 构造一组特征向量,即:

$$\mathbf{E} = [E_1, E_2, \dots, E_j] \quad (1)$$

本文采用 db4 小波对扰动信号进行 6 层分解,将得到的特征向量作为下述相关向量机的输入。6 种电能质量扰动的能量差分布如图 1 所示,图中横坐标代表分解层数,纵坐标代表能量差。




图 1 6 种电能质量扰动的能量差分布

3 快速相关向量机分类原理

3.1 相关向量机分类

给定训练样本的输入向量集为 $\{x_i, t_i\}_{i=1}^N$, 并且这些训练样本点的目标值 t_i 是相互独立的,根据标准概率方程式,假设目标值是 t_n , 并且附加有误差 ϵ_n , 则目标函数为:

$$t_i = y(x_i; \mathbf{w}) + \epsilon_n \quad (2)$$

其中, $y(x_i; \mathbf{w}) = \sum_{k=0}^N w_k K(x_i, x_k)$, $K(x_i, x_k)$ 为核函数, w_k 为基函数 $\phi = [K(x_1, x_1), K(x_2, x_1), \dots, K(x_N, x_1)]^T$ 对应的权重, $\mathbf{w} = [w_0, w_1, \dots, w_N]^T$ 为权值向量, N 为样本个数。假设误差变量 ϵ_i 服从期望为 0、方差为 σ^2 的高斯概率分布, 则相

关向量机的概率公式为:

$$p(t_i | \mathbf{x}) = N(t_i | y(x_i, \mathbf{w}), \sigma^2) \quad (3)$$

其中, $N(t_i | y(x_i, \mathbf{w}), \sigma^2)$ 表示 t_i 服从期望为 $y(x_i, \mathbf{w})$ 、方差为 σ^2 的高斯概率分布。由于目标值 t_i 是相互独立的, 因此整个训练样本数据集的似然函数为:

$$p(\mathbf{t} | \mathbf{w}, \sigma^2) = \prod_{i=1}^N N(t_i | y(x_i, \mathbf{w}), \sigma^2) = (2\pi\sigma^2)^{-N/2} \exp\left\{-\frac{1}{2\sigma^2} \|\mathbf{t} - \Phi\mathbf{w}\|^2\right\} \quad (4)$$

其中, $\mathbf{t} = [t_1, t_2, \dots, t_N]^T$, $\Phi = [\phi(x_1), \phi(x_2), \dots, \phi(x_N)]^T$, $\phi(x_i) = [1, K(x_i, x_1), K(x_i, x_2), \dots, K(x_i, x_N)]$ 。

为了提高模型的泛化能力,防止过拟合现象的发生, RVM 定义权值 \mathbf{w} 为依赖于超参数 α 的高斯先验分布, 即:

$$p(\mathbf{w} | \alpha) = \prod_{i=1}^N N(w_i | 0, \alpha_i^{-1}) = \prod_{i=1}^N \frac{\alpha_i}{\sqrt{2\pi}} \exp\left(-\frac{\alpha_i w_i^2}{2}\right) \quad (5)$$

根据贝叶斯理论,所有参数在给定的训练样本数据集上的后验分布为:

$$p(\mathbf{w}, \alpha, \sigma^2 | \mathbf{t}) = \frac{p(\mathbf{t} | \mathbf{w}, \alpha, \sigma^2) p(\mathbf{w}, \alpha, \sigma^2)}{p(\mathbf{t})} \quad (6)$$

又由贝叶斯理论可得:

$$p(\mathbf{w}, \alpha, \sigma^2 | \mathbf{t}) = p(\mathbf{w} | \mathbf{t}, \alpha, \sigma^2) p(\alpha, \sigma^2 | \mathbf{t}) \quad (7)$$

对式(7)进行近似处理,则相关向量机的学习过程就成为最大化 $p(\alpha, \sigma^2 | \mathbf{t}) \propto p(\mathbf{t} | \alpha, \sigma^2) p(\alpha) p(\sigma^2)$ 的过程, 即找到 α_{MP} 和 σ_{MP}^2 , 满足:

$$(\alpha_{MP}, \sigma_{MP}^2) = \arg \max_{\alpha, \sigma^2} p(\mathbf{t} | \alpha, \sigma^2) \quad (8)$$

其中, $p(\mathbf{t} | \alpha, \sigma^2)$ 称为边界似然度。

对于二分类问题,对输出引入 logistic sigmoid 函数 $\sigma(y) = 1/(1+e^{-y})$, 进而将线性模型泛化。假设把每次获得的观察样本看做一个独立事件, 则由 Bernoulli 分布可得目标值 t 的概率为:

$$p(\mathbf{t} | \mathbf{w}) = \prod_{i=1}^N [\sigma(y(x_i; \mathbf{w}))]^{t_i} [1 - \sigma(y(x_i; \mathbf{w}))]^{1-t_i} \quad (9)$$

其中, $t_i \in \{0, 1\}$, $\mathbf{t} = (t_1, \dots, t_N)^T$, 并且分类问题不需要考虑噪声 σ^2 。

由于式(9)不服从正态分布, 不能通过求定积分来确定权重值的大小, 因此 Michael E. Tipping 提出应用拉普拉斯方法逼近(Laplace approximation procedure)^[10]:

假设已知超参数 α , 通过迭代求出概率最大时对应的权重 w_{MP} 。根据贝叶斯理论, 可得 $p(\mathbf{w} | \mathbf{t}, \alpha) \propto p(\mathbf{t} | \mathbf{w}) p(\mathbf{w} | \alpha)$, 则:

$$\begin{aligned} w_{MP} &= \arg \max_{\mathbf{w}} p(\mathbf{w} | \mathbf{t}, \alpha) \\ &= \arg \max_{\mathbf{w}} \frac{p(\mathbf{t} | \mathbf{w}) p(\mathbf{w} | \alpha) p(\alpha)}{p(\alpha | \mathbf{t})} \\ &= \arg \max_{\mathbf{w}} \log p(\mathbf{t} | \mathbf{w}) p(\mathbf{w} | \alpha) \end{aligned} \quad (10)$$

根据逻辑对数似然有:

$$\log p(\mathbf{t} | \mathbf{w}) p(\mathbf{w} | \alpha) = \sum_{i=1}^N [t_i \log y_i + (1-t_i) \log(1-y_i)] - \frac{1}{2} \mathbf{w}^T \mathbf{A} \mathbf{w} \quad (11)$$

其中, $\mathbf{A} = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$, $y_i = \sigma(y(x_i; \mathbf{w}))$ 。

一般采用牛顿方法(Newton's Method)来快速寻找 w_{MP} , 即:

$$\begin{aligned}
\mathbf{g} &= \nabla_w \log[p(t|\mathbf{w})p(\mathbf{w}|\boldsymbol{\alpha})] = \Phi^T(t - \mathbf{y}) - \mathbf{A}\mathbf{w} \\
\mathbf{H} &= \nabla_w \nabla_w \log[p(t|\mathbf{w})p(\mathbf{w}|\boldsymbol{\alpha})] = (-\Phi^T \mathbf{B} \Phi - \mathbf{A})^{-1} \\
\Delta \mathbf{w} &= -\mathbf{H}^{-1} \mathbf{g} \\
\mathbf{w}_{MP}^{n+1} &= \mathbf{w}_{MP} + \Delta \mathbf{w}
\end{aligned}$$

其中, $\mathbf{y} = [y_1, y_2, \dots, y_N]^T$, $\mathbf{B} = \text{diag}(\beta_1, \beta_2, \dots, \beta_N)$, $\beta_n = \sigma[y(x_n)]\{1 - \sigma[y(x_n)]\}$, \mathbf{H} 为海森(Hessian)矩阵。

2) 由海森(Hessian)矩阵 \mathbf{H} 可得权重的协方差矩阵 $\boldsymbol{\Sigma}$:

$$\boldsymbol{\Sigma} = -\mathbf{H} = (\Phi^T \mathbf{B} \Phi + \mathbf{A})^{-1} \quad (12)$$

利用式(12)及 $\mathbf{g}|_{\mathbf{w}_{MP}} = 0$ 得:

$$\mathbf{w}_{MP} = \boldsymbol{\Sigma} \Phi^T \mathbf{B} \mathbf{t} \quad (13)$$

3) 利用 $\boldsymbol{\Sigma}$ 和 \mathbf{w}_{MP} 更新超参数 $\alpha_i^{new} = \frac{\gamma_i}{(\mathbf{w}_{MP})_i^2} = \frac{1 - \alpha_i}{(\mathbf{w}_{MP})_i^2}$, 进行循环得到最优的权重值。

利用最终得到的权重进行分类预测, 表达式为:

$$y_*(x_*, \mathbf{w}_{MP}) = \Phi(x_*) \mathbf{w}_{MP} \quad (14)$$

将表达式代入 logistic sigmoid 函数, 即可得到概率预测值 $p(t_* = 0|x_*)$ 和 $p(t_* = 1|x_*)$, 然后根据这两个值的大小确定 x_* 最有可能属于哪一类。

对于多分类问题, 与 SVM 类似, RVM 也可以将多分类问题转化为多个二分类问题的组合来进行求解。常用的多类分类方法主要有^[11]: 一对一法(One-against-One)、一对余法(One-against-the rest)等。本文采用一对余方法对 6 种电能质量扰动进行分类。

3.2 快速相关向量机(FRVM)

在 3.1 节讲述的相关向量机确定 α_{MP} 和 σ_{MP}^2 是通过最大化似然函数 $p(t|\boldsymbol{\alpha}, \sigma^2)$ 的方法, 由于这个过程等价于最大化其对数, 因此通过对其对数形式如式(15)求最大值, 从而得到式(8)的解:

$$\begin{aligned}
L(\boldsymbol{\alpha}) &= \log[p(t|\boldsymbol{\alpha}, \sigma^2)] \\
&= \log\left[\int_{-\infty}^{+\infty} p(t|\mathbf{w}, \sigma^2) p(\mathbf{w}|\boldsymbol{\alpha}) d\mathbf{w}\right] \\
&= -\frac{1}{2} [N \log 2\pi + \log |\mathbf{C}| + \mathbf{t}^T \mathbf{C}^{-1} \mathbf{t}] \quad (15)
\end{aligned}$$

其中, $\mathbf{C} = \sigma^2 \mathbf{I} + \Phi \mathbf{A}^{-1} \Phi^T$, 在求解式(15)时, 由于在每次的迭代过程中都要重新计算 Φ , 这样就会导致计算时间随着样本数量的增加而急剧增加。所以 Michael. E. Tipping 又提出了快速相关向量机(FRVM)算法, 该算法是通过在计算过程中对 Φ 进行合理的稀疏化, 进而提高计算速度^[12]。

为了便于最大化 $L(\boldsymbol{\alpha})$, 针对每一个 α_i , 对矩阵 \mathbf{C} 进行分析和重组得:

$$\begin{aligned}
\mathbf{C} &= \sigma^2 \mathbf{I} + \sum_{m \neq i} \alpha_m^{-1} \phi_m \phi_m^T + \alpha_i^{-1} \phi_i \phi_i^T \\
&= \mathbf{C}_{-i} + \alpha_i^{-1} \phi_i \phi_i^T \quad (16)
\end{aligned}$$

将式(16)代入式(15)可得:

$$\begin{aligned}
L(\boldsymbol{\alpha}) &= -\frac{1}{2} [N \log 2\pi + \log |\mathbf{C}_{-i}| + \mathbf{t}^T \mathbf{C}_{-i}^{-1} \mathbf{t} - \log(\alpha_i) + \\
&\quad \log(\alpha_i + \phi_i^T \mathbf{C}_{-i}^{-1} \phi_i) - \frac{(\phi_i^T \mathbf{C}_{-i}^{-1} \mathbf{t})^2}{\alpha_i + \phi_i^T \mathbf{C}_{-i}^{-1} \phi_i}] \\
&= L(\alpha_{-i}) + \frac{1}{2} [\log \alpha_i - \log(\alpha_i + s_i) + \frac{(q_i)^2}{\alpha_i + s_i}] \quad (17)
\end{aligned}$$

定义 $s_i = \phi_i^T \mathbf{C}_{-i}^{-1} \phi_i$ 为稀疏因子, $q_i = \phi_i^T \mathbf{C}_{-i}^{-1} \mathbf{t}$ 为质量因子, 则, $L(\boldsymbol{\alpha})$ 有唯一最大值点为:

$$\alpha_i = \begin{cases} \frac{s_i^2}{q_i^2 - s_i}, & q_i^2 > s_i \\ \infty, & q_i^2 \leq s_i \end{cases} \quad (18)$$

则可按照以下步骤最大化贝叶斯 $L(\boldsymbol{\alpha})$:

- 1) 若 $q_i^2 > s_i$ 且 $\alpha_i < \infty$ (ϕ_i 在模型中), 则重新估计 α_i ;
 - 2) 若 $q_i^2 > s_i$ 且 $\alpha_i = \infty$, 则添加 ϕ_i 到模型中并重新估计 α_i ;
 - 3) 若 $q_i^2 \leq s_i$ 且 $\alpha_i < \infty$, 则剔除 ϕ_i 并更新 $\alpha_i = \infty$ 。
- 这样, 每次迭代, Φ 中只有少量的 ϕ_i , 提高了计算效率。

3.3 选取核函数

常用的核函数有高斯核函数、线性核函数、多项式核函数等。本文选择最常用的高斯核函数, 即:

$$K(x_i, x_k) = \exp\left[-\frac{\|x_i - x_k\|^2}{l^2}\right] \quad (19)$$

其中, l 是带宽参数, $\|x_i - x_k\|$ 是距离方程。

3.4 FRVM 与传统的 RVM 性能比较

为了验证 FRVM 的性能, 利用函数 $\text{sinc}(x) = \sin(|x|)/|x|$ 对其进行回归测试, 选取带宽参数 $l=5$, $N=500$, 并向信号中添加标准差为 0.1 的高斯白噪声, 二者的对比结果如表 2 所列, 回归预测图形如图 2 和图 3 所示。

表 2 传统的 RVM 和 FRVM 性能比较

	相关向量个数	回归测试误差率/%
传统的 RVM	17	1.47%
FRVM	7	1.29%

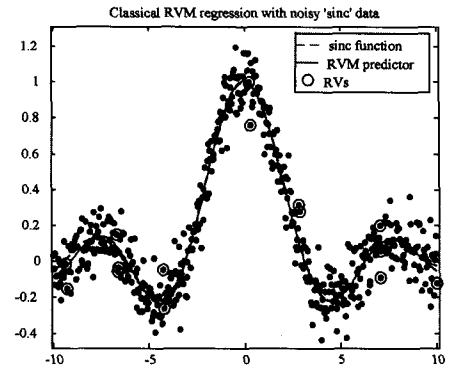


图 2 传统 RVM 的回归预测

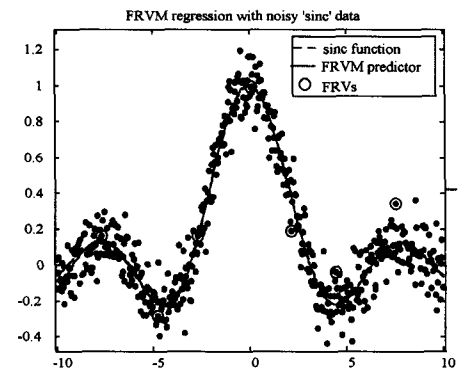


图 3 FRVM 的回归预测

由表 2 以及图 2 和图 3 可以看出, FRVM 与传统的 RVM 相比, 具有更少的相关向量的个数, 而且回归测试曲线与原测试函数曲线更接近, 回归测试的误差率也明显降低了。

4 实验仿真

为了验证本文所提分类方法的有效性, 利用此方法对表 1 中所列出的 6 种电能质量扰动信号进行分类, 并与传统的

(下转第 244 页)

on the Method of Artificial Potentials[C]//Proc. of IEEE Conf. on Robotics and Automation, Nice, France, 1990:566-571

[10] Ge S S, Cui Y J. New potential functions for mobile robot path planning[J]. IEEE Trans. on Robotics and Automation, 2000, 16(5):615-620

[11] Jia Q, Wang X. An improved potential field method for path planning[C]//Control and Decision Conference (CCDC), 2010 Chinese. IEEE, 2010;2265-2270

[12] L Qian-you, Zhang H, Heng W, et al. Application of improved artificial potential field approach in local path planning for mobile robot[J]. Computer Engineering and Design, 2011, 32(4): 1411-1418

[13] Ge S S, Cui Y J. Dynamic motion planning for mobile robots using potential field method[J]. Autonomous Robots, 2002, 13

(3);207-222

[14] Huang L. Velocity planning for a mobile robot to track a moving target—a potential field approach[J]. Robotics and Autonomous Systems, 2009, 57(1):55-63

[15] 韩永, 刘国栋. 动态环境下基于人工势场的移动机器人运动规划[J]. 机器人, 2006, 28(1):45-49

[16] 潘炼, 严文, 陶辉, 等. 基于改进人工势场的移动机器人路径规划[J]. 计算机测量与控制, 2011, 19(4):969-974

[17] 谢宏健, 王华忠. 基于速度分解的移动机器人动态避碰规划[J]. 华东理工大学自然科学报, 2011, 37(2):234-238

[18] Zhang Qi, Yue Shi-guang, Yin Quan-jun, et al. Dynamic obstacle-avoiding path planning for robots based on modified potential field method[C]// Intelligent Computing Theories and Technology. Springer Berlin Heidelberg, 2013:332-342

(上接第 236 页)

RVM 分类法进行比较。采用的参数设置为： $l=0.5, \alpha=\frac{1}{N^2}$ ，其中 N 为样本个数。表 3 给出了在无噪声的情况下，两种方法在不同训练/测试样本下获得的分类准确率的平均值及训练时间平均值，其中，若训练/测试样本为 100/1000，则代表每种扰动生成 100/1000 个训练/测试样本，6 种扰动共 600/6000 个训练/测试样本，训练时间也为 600 个训练样本的训练时间。硬件环境：实验选用微机的 CPU 主频为 2.53GHz，内存为 2.00GB，仿真软件为 Matlab7.0。

表 3 传统的 RVM 和 FRVM 的分类结果比较

训练/测试 样本	平均分类准确率/%		平均训练时间/s	
	RVM	FRVM	RVM	FRVM
100/1000	94.14%	96.00%	25.547	14.887
200/1000	96.46%	98.39%	177.263	77.899
300/1000	97.33%	98.88%	529.720	196.301
400/1000	98.01%	99.21%	1266.809	307.760

从表 3 的仿真数据中可以看出，FRVM 算法的准确率比传统的 RVM 算法的准确率高，从训练时间分析，FRVM 通过对矩阵 Φ 进行合理的稀疏化，从而可以极大地减少训练时间，使相关向量机更具有实用性。

由于实际的信号中通常叠加有噪声，因此本文为对各扰动信号分别叠加信噪比为 20dB、30dB、40dB 的高斯白噪声，表 4 是在训练/测试样本为 400/1000 的情况下，采用本文所提出的分类方法对叠加有噪声的扰动信号的分类结果。

表 4 FRVM 在不同信噪比下的分类结果

扰动类型	分类准确率/%		
	40dB	30dB	20dB
电压暂降	99.63%	99.27%	96.32%
电压暂升	100%	99.75%	97.48%
电压中断	99.78%	99.20%	97.12%
谐波	97.15%	95.46%	94.26%
振荡暂态	98.82%	97.47%	96.30%
瞬时脉冲	98.80%	96.92%	95.23%
平均准确率%	99.03%	98.01%	96.12%

从表 4 中可以看出，在训练/测试样本为 400/1000 的情况下，当叠加到信号中的噪声的信噪比分别为 40dB、30dB、20dB 时，本文所提方法的分类准确率可分别达到 99.03%、98.01%、96.12%，可见本文提出的基于小波变换和 FRVM

的电能质量扰动分类方法在不同的信噪比下也能获得高精度的分类结果，由此验证了此方法具备良好的抗噪声能力。

结束语 通过小波变换提取各层信号的能量与标准信号的能量之差组成的特征向量能够很好地反应出扰动的特性，有利于提高分类的准确率；并且采用 FRVM 算法能够极大地缩短训练时间，提高分类器的效率和分类准确率，增加算法的实用性。

参 考 文 献

[1] Santoso S, Grady W M, Powers E J, et al. Characterization of distribution power quality events with Fourier and wavelet transforms[J]. IEEE Trans. Power Del, 2000, 15(1):247-254

[2] 覃思师, 刘前进. 基于 STFT 变换和 DAGSVMs 的电能质量扰动识别[J]. 电力系统保护与控制, 2011, 39(1):83-86

[3] 胡为兵, 李开成, 张明, 等. 基于小波变换和分形理论的电能质量扰动监控系统[J]. 电网技术, 2008, 32(12):51-55

[4] 赵凤展, 杨仁刚. 基于 s 变换和时域分析的电能质量扰动识别[J]. 电网技术, 2006, 30(8):90-94

[5] Reaz M, Choong F, Sulaiman M. Expert system for power quality disturbance classifier[J]. IEEE Transactions on Power Delivery, 2007, 22(3):1979-1988

[6] 赵静, 何正友, 贾勇, 等. 基于高阶累积量的暂态电能质量扰动分类研究[J]. 电网技术, 2011, 35(5):103-109

[7] 赵立权, 谢妮娜. 基于小波变换和改进的 RVM 的电能质量扰动分类[J]. 电工电能新技术, 2013, 32(4):74-78

[8] 姚建刚, 郭知非, 陈锦攀. 基于小波和 BP 神经网络的电能扰动分类新方法[J]. 电网技术, 2012, 36(5):139-144

[9] 沈跃, 刘国海, 刘慧. 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[J]. 控制与决策, 2011, 26(4):587-591

[10] Bishop C M, Tipping M E. Variational Relevance Vector Machines[R]. Uncertainty in Artificial Intelligence Proceedings, 2000

[11] 刘志刚, 李德仁, 秦前清, 等. 支持向量机在多类分类问题中的推广[J]. 计算机工程与应用, 2004(7):10-13

[12] Tipping M E, Faul A C. Fast marginal likelihood maximisation for sparse Bayesian models[C]// Bishop C M, Frey B J. eds., Proceedings of the Ninth International Workshop on Artificial Intelligence and Statistics, Key West, FL, 2003