

# 新型支持向量机在风速预测模型中的应用研究

刘忠宝

(中北大学计算机与控制工程学院 太原 030051)

**【摘要】**在短期风速预测方面支持向量机已被广泛应用并取得较好的效果。然而，随着应用的深入，其逐渐暴露出两大问题：一，对噪声较为敏感；二，未能充分利用样本已有信息。为进一步提高支持向量机的泛化能力，该文提出模糊流形支持向量机FMSVM。该方法引入模糊技术，保证不同样本区别对待，减少或消除噪声的影响；充分利用流形判别分析的性质，进一步改进支持向量机，在分类决策时同时考虑样本的边界信息、分布特征以及局部流形结构。通过某风场风速数据集上的比较实验验证该方法的有效性。

**关键词** 模糊隶属度；流形判别分析；支持向量机；风速预测

中图分类号 TP391

文献标志码 A

doi:10.3969/j.issn.1001-0548.2014.05.021

## Research on Wind Speed Forecasting Model Based on Novel Support Vector Machine

LIU Zhong-bao

(School of Computer and Control Engineering, North University of China Taiyuan 030051)

**Abstract** Support vector machine (SVM) is widely used in wind speed forecasting and the forecasted results are verified well. With the applications get more intensive, there exist two problems in SVM. One is it is too sensitive to noises and the other is it can not fully use the information included in the samples. In view of this, a fuzzy manifold-based support vector machine (FMSVM) is proposed in this paper to solve the above problems and further improve the generalization capability of SVM. FMSVM introduces the fuzzy techniques to decrease the influence of the noises. Meanwhile, FMSVM takes boundary data between classes, data distributions and manifold seriously. The comparative experiments show that FMSVM performs better than SVM on the wind datasets of a certain wind farm.

**Key words** fuzzy membership function; manifold discriminant analysis (MDA); SVM; wind speed forecasting

风能是一种清洁型、可再生能源，已被世界各国高度重视并将其作为新能源发电的首选<sup>[1-2]</sup>。文献[3]指出，对风电场风速的准确预测有利于发电系统效率的提高。支持向量机(SVM)<sup>[4-6]</sup>是一种经典的模式分类方法，它建立在最小化风险结构原则基础上，在保证最大分类间隔和最小分类错误的前提下构造最优分类超平面。SVM具有优良的鲁棒性和分类能力，因而被广泛应用于风速预测领域。但随着应用的深入，SVM逐渐暴露出其弊端，限制了SVM泛化能力的进一步提升。鉴于此，本文提出模糊流形支持向量机(FMSVM)。

### 1 背景知识

对于包含 $N$ 个模式的二分类问题，设定样本集

$X = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_N, y_N)\}$ 。其中， $\mathbf{x}_i \in R^d (1 \leq i \leq N_1 + N_2 = N)$  为样本； $y_i \in \{1, -1\}$  为类别标签。当  $1 \leq i \leq N_1$  时， $y_i = 1$ ；当  $N_1 + 1 \leq i \leq N$  时， $y_i = -1$ 。第一类含有  $N_1$  个模式  $\{\mathbf{x}_i, y_i\}_{i=1}^{N_1}$ ，第二类含有  $N_2$  个模式  $\{\mathbf{x}_j, y_j\}_{j=N_1+1}^{N_2}$ 。 $\bar{\mathbf{x}}$  表示所有样本均值， $\bar{\mathbf{x}}_1$  和  $\bar{\mathbf{x}}_2$  分别表示第一类和第二类样本均值。

#### 1.1 SVM

将超平面方程表示为  $\mathbf{W}^T \mathbf{x} + b = 0$ ，SVM的最优化问题可描述为：

$$\begin{aligned} \min_{\mathbf{W}, b, \xi_i} & \left( \frac{1}{2} \mathbf{W}^T \mathbf{W} + C \sum_{i=1}^N \xi_i \right) \\ \text{s.t. } & y_i (\mathbf{W}^T \mathbf{x}_i + b) \geq 1 - \xi_i \\ & \xi_i \geq 0 \quad i=1, 2, \dots, N \end{aligned} \quad (1)$$

式中,  $C$ 为惩罚因子; 松弛因子  $\xi_i$  允许错分样本的存在。

上述优化问题可转化为如下对偶形式:

$$\begin{aligned} \max_{\alpha} & \left( \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \right) \\ \text{s.t.} & \sum_{i=1}^N \alpha_i y_i = 0 \\ & \alpha_i \geq 0 \quad i = 1, 2, \dots, N \end{aligned} \quad (2)$$

### 1.2 MDA

文献[7]提出了流形判别分析方法(MDA)。该方法引入基于流形的类内离散度 (manifold-based within-class scatter, MWCS)  $\mathbf{M}_w$  和基于流形的类间离散度 (manifold-based between-class scatter, MBCS)  $\mathbf{M}_b$  两个概念。  $\mathbf{M}_w$  和  $\mathbf{M}_b$  可定义为:

$$\mathbf{M}_w = \mu \mathbf{S}_w + (1 - \mu) \mathbf{S}_s \quad (3)$$

$$\mathbf{M}_b = \lambda \mathbf{S}_b + (1 - \lambda) \mathbf{S}_d \quad (4)$$

式中,  $\mu$ 和 $\lambda$ 为常数;  $\mathbf{S}_w$  称为类内离散度;  $\mathbf{S}_b$  称为类间离散度;  $\mathbf{S}_s$  保持同类样本的局部结构;  $\mathbf{S}_d$  保持异类样本的局部结构。  $\mathbf{S}_w$ ,  $\mathbf{S}_b$ ,  $\mathbf{S}_s$ ,  $\mathbf{S}_d$  可定义为:

$$\begin{aligned} \mathbf{S}_w &= \sum_{i=1}^{N_1} (\mathbf{x}_i - \bar{\mathbf{x}}_1)(\mathbf{x}_i - \bar{\mathbf{x}}_1)^T + \\ & \sum_{j=1}^{N_2} (\mathbf{x}_j - \bar{\mathbf{x}}_2)(\mathbf{x}_j - \bar{\mathbf{x}}_2)^T \end{aligned} \quad (5)$$

$$\mathbf{S}_b = N_1 (\bar{\mathbf{x}}_1 - \bar{\mathbf{x}})(\bar{\mathbf{x}}_1 - \bar{\mathbf{x}})^T + N_2 (\bar{\mathbf{x}}_2 - \bar{\mathbf{x}})(\bar{\mathbf{x}}_2 - \bar{\mathbf{x}})^T \quad (6)$$

$$\mathbf{S}_s = X(\mathbf{S}' - \mathbf{S})X^T \quad (7)$$

式中,  $\mathbf{S}'$  为对角阵且  $\mathbf{S}' = \sum_j \mathbf{S}'_{ij}$ , 其中  $\mathbf{S}'_{ij}$  为同类权重函数:

$$\mathbf{S}'_{ij} = \begin{cases} \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2) & y_i = y_j \\ 0 & y_i \neq y_j \end{cases} \quad (8)$$

$$\mathbf{S}_d = X(\mathbf{D}' - \mathbf{D})X^T \quad (9)$$

式中,  $\mathbf{D}'$  为对角阵且  $\mathbf{D}' = \sum_j \mathbf{D}'_{ij}$ , 其中  $\mathbf{D}'_{ij}$  为异类权重函数:

$$\mathbf{D}'_{ij} = \begin{cases} \exp(-1/\|\mathbf{x}_i - \mathbf{x}_j\|^2) & y_i \neq y_j \\ 0, & y_i = y_j \end{cases} \quad (10)$$

MDA 利用 Fisher 准则通过最大化 MBCS 与 MWCS 之比实现特征提取。MDA 的最优化表达式如下:

$$J = \max_w \frac{\mathbf{W}^T \mathbf{M}_b \mathbf{W}}{\mathbf{W}^T \mathbf{M}_w \mathbf{W}} = \max_w \frac{\mathbf{W}^T (\lambda \mathbf{S}_b + (1 - \lambda) \mathbf{S}_d) \mathbf{W}}{\mathbf{W}^T (\mu \mathbf{S}_w + (1 - \mu) \mathbf{S}_s) \mathbf{W}} \quad (11)$$

## 2 模糊流形支持向量机

### 2.1 最优化问题

鉴于SVM在实际应用中面临抗噪能力差、泛化能力有限等问题, 本文提出模糊流形支持向量机 FMSVM。该方法通过降低噪声的权重减少其对分类结果的影响。流形判别分析的引入保证了分类决策对样本的分布特征、边界信息、局部信息的考虑。FMSVM的最优化问题可表示如下:

线性形式:

$$\begin{aligned} \min_{\mathbf{W}, b, \xi} & \left( \mathbf{W}^T \mathbf{M}_w \mathbf{W} + C \sum_{i=1}^N s_i \xi_i \right) \\ \text{s.t.} & y_i (\mathbf{W}^T \mathbf{x}_i + b) \geq 1 - \xi_i \\ & \xi_i \geq 0 \quad i = 1, 2, \dots, N \end{aligned} \quad (12)$$

由Lagrangian定理可得:

$$\begin{aligned} L(\mathbf{W}, b, \alpha, \beta, \xi) &= \mathbf{W}^T \mathbf{M}_w \mathbf{W} + C \sum_{i=1}^N s_i \xi_i - \\ & \sum_{i=1}^N \alpha_i [y_i (\mathbf{W}^T \mathbf{x}_i + b) - 1 + \xi_i] - \sum_{i=1}^N \beta_i \xi_i \end{aligned} \quad (13)$$

L分别对  $\mathbf{W}, b, \xi$  求导, 并令导数为零, 可得:

$$\frac{\partial L}{\partial \mathbf{W}} = 0 \Leftrightarrow \mathbf{M}_w \mathbf{W} = \frac{1}{2} \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i \quad (14)$$

当  $\mathbf{M}_w$  非奇异时, 有:

$$\mathbf{W} = \frac{1}{2} \mathbf{M}_w^{-1} \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i \quad (15)$$

$$\frac{\partial L}{\partial b} = 0 \Leftrightarrow \sum_{i=1}^N \alpha_i y_i = 0 \quad (16)$$

$$\frac{\partial L}{\partial \xi_i} = 0 \Leftrightarrow \alpha_i + \beta_i = s_i C \Leftrightarrow 0 \leq \alpha_i \leq s_i C \quad (17)$$

将式(15)~(17)带入式(13)可得FMSVM最优化问题的对偶形式:

$$\max_{\alpha} \left( \sum_{i=1}^N \alpha_i - \frac{1}{4} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{M}_w^{-1} \mathbf{x}_j \right) \quad (18)$$

$$\text{s.t.} \quad \sum_{i=1}^N \alpha_i y_i = 0$$

$$0 \leq \alpha_i \leq s_i C$$

当  $\mathbf{M}_w$  奇异时, 本文在  $\mathbf{M}_w$  的主对角线增加一个很小的常数  $\Delta$ , 使得  $\mathbf{M}_w$  变得非奇异。

### 2.2 决策函数

FMSVM的决策函数定义为:

$$\begin{aligned} f(\mathbf{x}) &= \text{sgn}(\mathbf{W}^T \mathbf{x} + b) = \\ & \text{sgn} \left( \frac{1}{2} \mathbf{M}_w^{-1} \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i^T \mathbf{x} + b \right) \end{aligned} \quad (19)$$

选择最优解  $\alpha^*$  的一个正分量  $0 < \alpha_j^* < C$ , 计算

分类阈值:

$$b^* = y_j - \sum_{i=1}^N y_i \alpha_i^* \mathbf{x}_i^T \mathbf{x}_j \quad (20)$$

FMSVM的非线性形式为:

$$\begin{aligned} \min_{\mathbf{w}, b, \xi_i} & \left( \mathbf{W}^T \mathbf{M}_w \mathbf{W} + C \sum_{i=1}^N s_i \xi_i \right) \\ \text{s.t.} & y_i (\mathbf{W}^T \phi(\mathbf{x}_i) + b) \geq 1 - \xi_i \\ & \xi_i \geq 0 \quad i = 1, 2, \dots, N \end{aligned} \quad (21)$$

由Lagrangian定理可得上述最优化问题的对偶形式为:

$$\begin{aligned} \max_{\alpha} & \left( \sum_{i=1}^N \alpha_i - \frac{1}{4} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \phi(\mathbf{x}_i)^T \mathbf{M}_w^{-1} \phi(\mathbf{x}_j) \right) \\ \text{s.t.} & \sum_{i=1}^N \alpha_i y_i = 0 \\ & 0 \leq \alpha_i \leq s_i C \end{aligned} \quad (22)$$

令  $\phi(\gamma_i) = \mathbf{M}_w^{-1/2} \phi(\mathbf{x}_i)$ , 则式(22)可转化为如下形式:

$$\max_{\alpha} \left( \sum_{i=1}^N \alpha_i - \frac{1}{4} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j k(\gamma_i, \gamma_j) \right) \quad (23)$$

式中,  $k(\gamma_i, \gamma_j) = \phi(\gamma_i)^T \phi(\gamma_j)$ 。

### 2.3 常用的核函数

1) Gaussian核函数  $k(\mathbf{x}, \mathbf{y}) = \exp(-\|\mathbf{x} - \mathbf{y}\|^2 / 2\delta^2)$ , 其中, 参数  $\delta > 0$ 。

2) 多项式核函数  $k(\mathbf{x}, \mathbf{y}) = (\mathbf{x}^T \mathbf{y} + c)^d$ , 其中,  $c$  和  $d$  为参数。

3) Sigmoid核函数  $k(\mathbf{x}, \mathbf{y}) = \tanh(b(\mathbf{x}^T \mathbf{y}) + c)^d$ , 其中,  $b(\mathbf{x}^T \mathbf{y}) > 0$ ;  $c < 0$ 。

4) Epanechnikov核函数  $k(\mathbf{x}) = \frac{3}{4d} \left( 1 - \frac{\|\mathbf{x}\|^2}{d^2} \right)$ , 其

中,  $\|\mathbf{x}\|^2 / d^2 \leq 1$ ;  $d$  为参数。

### 2.4 模糊技术

模式技术一般用于处理不确定性问题, 常常用0与1之间的隶属度函数描述。当前主流的模糊隶属度主要包括基于距离的隶属度与基于紧密度的隶属度两类:

#### 2.4.1 基于距离的隶属度<sup>[8]</sup>

设类中心、样本、类半径分别为  $\bar{\mathbf{x}}$ 、 $\mathbf{x}_i$ 、 $R$ , 则基于距离的隶属度为:

$$s(\mathbf{x}_i) = 1 - \frac{\|\mathbf{x}_i - \bar{\mathbf{x}}\|}{R} + \delta \quad (24)$$

式中,  $R = \max_i \|\mathbf{x}_i - \bar{\mathbf{x}}\|$ ;  $\delta$  为很小的正数, 它保证  $s(\mathbf{x}_i) > 0$ 。

#### 2.4.2 基于紧密度的隶属度<sup>[9]</sup>

设正、负类中心分别为  $\bar{\mathbf{x}}_+$ 、 $\bar{\mathbf{x}}_-$ , 正、负类半径分别为  $R_+ = \max_i \|\mathbf{x}_i - \bar{\mathbf{x}}_+\|$ ,  $R_- = \max_i \|\mathbf{x}_i - \bar{\mathbf{x}}_-\|$ , 两类中心的距离为  $T = \|\bar{\mathbf{x}}_+ - \bar{\mathbf{x}}_-\|$ , 正、负类样本到相应正、负类中心的距离为  $d_i^+ = \|\mathbf{x}_i - \bar{\mathbf{x}}_+\|$ 、 $d_i^- = \|\mathbf{x}_i - \bar{\mathbf{x}}_-\|$ 。基于紧密度的隶属度定义为:

$$s_i^+ = \begin{cases} \frac{\delta + D_i^+}{R_+} & D_i^+ \leq T\varepsilon \\ \delta & D_i^+ > T\varepsilon \end{cases} \quad (25)$$

$$s_i^- = \begin{cases} \frac{\delta + D_i^-}{R_-} & D_i^- \leq T\varepsilon \\ \delta & D_i^- > T\varepsilon \end{cases} \quad (26)$$

式中,  $\delta$  为很小的正数, 它保证  $s_i > 0$ ;  $\varepsilon$  为半径控制因子, 满足  $\varepsilon > 0$ , 有  $T\varepsilon < R_+$  和  $T\varepsilon < R_-$ 。

## 3 实验分析

将某风场2013年1月3日~2013年1月6日期间共4×24个(采样间隔1 h)实测风速作为训练样本, 对1月7日的24个风速进行预测。实验采用基于距离的隶属度函数, 其中参数  $\delta$  设定为0.001, 保证隶属度数值为正数且对结果影响尽可能小。实验选用的核函数为高斯核函数。

### 3.1 预测模型评价标准

实验对预测效果的评价指标有相对误差(RE)、平均绝对百分比(MAPE)和均方根误差(RMSE), 其定义如下:

$$RE = \frac{a - \tilde{a}}{a} \times 100\% \quad (27)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|a - \tilde{a}|}{|a|} \times 100\% \quad (28)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (|RE_i| - MAPE)^2}{N}} \times 100\% \quad (29)$$

式中,  $a$  表示实际风速;  $\tilde{a}$  表示预测风速;  $RE_i$  表示第  $i$  次预测风速的相对误差。

### 3.2 实验参数设置

利用5倍交叉验证法选取实验参数, 通过网格搜索策略<sup>[10]</sup>获得最优参数。高斯核函数的方差在网格  $\{\bar{a}/2\sqrt{2}, \bar{a}/2, \bar{a}/\sqrt{2}, \bar{a}, \sqrt{2}\bar{a}, 2\bar{a}, 2\sqrt{2}\bar{a}\}$  中搜索选取, 其中  $\bar{a}$  为训练样本平均范数的平方根; 在SVM、

LS-SVM(least squares support vector machine)和FMSVM中, 惩罚因子 $C$ 在网格{0.01, 0.05, 0.1, 0.5, 1, 5, 10}中搜索选取; FMSVM中, 参数 $\mu$ 在网格{0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9}中搜索选取。

### 3.3 FMSVM风速预测模型结果分析

通过与SVM、LS-SVM的比较实验验证FMSVM在风速预测方面的有效性。风速预测结果如表1所示, 从表中可看出, 与SVM、LS-SVM相比, FMSVM对1月7日的风速预测值大多较为理想, 只有少部分预测值误差较大。从平均绝对误差百分比看, SVM的MAPE值为10.25%, LS-SVM的MAPE值为8.22%, 而FMSVM的MAPE值仅为6.27%。从均方根误差看, SVM的RMSE值为5.27%, LS-SVM的RMSE值为4.59, FMSVM的RMSE值为3.91, FMSVM的RMSE值最小, 表明FMSVM的性能最稳定。以上分析表明, 与SVM和LS-SVM相比, FMSVM整体风速预测能力有了较大幅度的提升。FMSVM在风速预测方面的优势与其工作原理密切相关, 即FMSVM既克服了SVM对噪声数据敏感的问题, 又在分类决策时考虑样本的分布特征、边界信息、局部结构, 有效地提高了SVM的分类效率。

表1 风速预测结果

| 实验批次   | 实际风速 /m·s <sup>-1</sup> | SVM                     |         | LS-SVM                  |         | FMSVM                   |         |
|--------|-------------------------|-------------------------|---------|-------------------------|---------|-------------------------|---------|
|        |                         | 预测风速 /m·s <sup>-1</sup> | 相对误差 /% | 预测风速 /m·s <sup>-1</sup> | 相对误差 /% | 预测风速 /m·s <sup>-1</sup> | 相对误差 /% |
| 1      | 6.8                     | 6.954                   | -2.26   | 6.778                   | 2.59    | 6.590                   | 3.09    |
| 2      | 8.1                     | 8.414                   | -3.88   | 8.323                   | -2.75   | 8.212                   | -1.38   |
| 3      | 7.3                     | 6.071                   | 16.84   | 7.220                   | 1.10    | 7.023                   | 3.79    |
| 4      | 5.8                     | 5.003                   | 13.74   | 4.898                   | 15.56   | 4.978                   | 14.17   |
| 5      | 8.4                     | 7.127                   | 15.15   | 7.211                   | 14.20   | 7.371                   | 12.25   |
| 6      | 7.2                     | 6.623                   | 8.01    | 7.993                   | -11.01  | 7.856                   | -9.11   |
| 7      | 5.9                     | 5.559                   | 5.78    | 5.732                   | 2.85    | 5.843                   | 0.96    |
| 8      | 6.1                     | 5.152                   | 15.54   | 5.737                   | 5.95    | 5.854                   | 4.03    |
| 9      | 6.3                     | 5.287                   | 16.08   | 5.564                   | 11.68   | 6.057                   | 3.86    |
| 10     | 5.4                     | 5.496                   | -1.78   | 5.205                   | 3.61    | 5.921                   | -9.65   |
| 11     | 7                       | 7.903                   | -12.9   | 7.836                   | -11.94  | 7.892                   | -12.74  |
| 12     | 7.4                     | 6.621                   | 10.53   | 6.669                   | 9.88    | 6.803                   | 8.07    |
| 13     | 6.5                     | 5.578                   | 14.18   | 5.661                   | 12.91   | 6.044                   | 7.02    |
| 14     | 8.9                     | 8.054                   | 9.51    | 8.201                   | 7.85    | 8.702                   | 2.22    |
| 15     | 6                       | 5.033                   | 16.11   | 5.120                   | 14.67   | 5.24                    | 12.67   |
| 16     | 5.9                     | 4.998                   | 15.29   | 5.008                   | 15.12   | 5.239                   | 11.2    |
| 17     | 7.7                     | 8.205                   | -6.56   | 8.105                   | -5.26   | 8.001                   | -3.91   |
| 18     | 6.2                     | 6.003                   | 3.18    | 5.802                   | 6.42    | 5.821                   | 6.11    |
| 19     | 6.5                     | 5.289                   | 18.63   | 5.644                   | 13.17   | 5.924                   | 8.86    |
| 20     | 6.9                     | 7.505                   | -8.77   | 7.520                   | -8.99   | 7.418                   | -7.51   |
| 21     | 7.1                     | 6.459                   | 9.03    | 6.789                   | 4.38    | 6.825                   | 3.87    |
| 22     | 6.8                     | 7.416                   | -9.06   | 7.215                   | -6.10   | 7.071                   | -3.99   |
| 23     | 5.7                     | 5.728                   | 0.49    | 5.600                   | 1.75    | 5.54                    | 2.81    |
| 24     | 7.2                     | 8.111                   | -12.65  | 7.898                   | -9.69   | 7.473                   | -3.79   |
| MAPE/% |                         | 10.25                   |         | 8.22                    |         | 6.37                    |         |
| RMSE/% |                         | 5.27                    |         | 4.59                    |         | 3.91                    |         |

## 4 结论

本文提出的模糊流形支持向量机, 该方法利用

模糊技术尽量减小噪声对分类决策的影响, 同时将各类的边界信息、分布性状以及局部流形结构作为分类的重要参考。

### 参考文献

- [1] FAN Shu, LIAO J R, YOKOYAMA R, et al. Forecasting the wind generation using a two-stage based on meteorological information[J]. IEEE Transactions On Energy Conversion, 2009, 24(2): 474-482.
- [2] 孙斌, 姚海涛, 刘婷. 基于高斯过程回归的短期风速预测[J]. 中国电机工程学报, 2012, 32(29): 104-109.  
SUN Bin, YAO Hai-tao, LIU Ting. Short-term wind speed forecasting based on Gaussian process regression model [J]. Proceedings of the Chinese Society for Electrical Engineering, 2012, 32(29): 104-109.
- [3] 罗文, 王莉娜. 风场短期风速预测研究[J]. 电工技术学报, 2011, 26(7): 68-74.  
LUO Wen, WANG Li-na. Short-term wind speed forecasting for wind farm[J]. Transactions of China Electrotechnical society, 2011, 26(7): 68-74.
- [4] TIAN X, GASSO G, CAHU S. A multiple kernel framework for inductive semi-supervised SVM learning[J]. Neurocomputing, 2012, 90(1): 46-58.
- [5] VAPNIK V. The nature of statistical learning theory[M]. New York: Springer-Verlag, 1995.
- [6] 刘忠宝, 王士同. 基于光束角思想的最大间隔学习机[J]. 控制与决策, 2012, 27(12): 1870-1875.  
LIU Zhong-bao, WANG Shi-tong. Maximum margin learning machine based on beam angle[J]. Control and Decision, 2012, 27(12): 1870-1875.
- [7] 刘忠宝, 潘广贞, 赵文娟. 流形判别分析[J]. 电子与信息学报, 2013, 35(9): 2047-2053.  
LIU Zhong-bao, PAN Guang-zhen, ZHAO Wen-juan. Manifold-based discriminant analysis[J]. Journal of Electronics and Information Technology, 2013, 35(9): 2047-2053.
- [8] LIN C F, WAN S D. Fuzzy support vector machines[J]. IEEE Transactions on Neural Networks, 2002, 13(2): 464-471.
- [9] 孙名松, 高庆国, 王宣丹. 基于双隶属度模糊支持向量机的邮件过滤[J]. 计算机工程与应用, 2010, 46(2): 93-95.  
SUN Ming-song, GAO Qing-guo, WANG Xuan-dan. Mail filtering by dual membership fuzzy support vector machine[J]. Computer Engineering and Applications, 2010, 46(2): 93-95.
- [10] MULLER K R, MIKA S, RATSCH G, et al. An introduction to kernel-based learning algorithms[J]. IEEE Transactions on Neural Networks, 2001, 12(2): 181-202.

编辑 叶芳