

# 基于自适应双向加权最小二乘支持向量机的超短期负荷预测

王岗<sup>1</sup>, 姜杰<sup>1</sup>, 唐昆明<sup>1</sup>, 张太勤<sup>2</sup>

(1. 输配电装备及系统安全与新技术国家重点实验室(重庆大学), 重庆 400044; 2. 重庆新世纪电气有限公司, 重庆 400039)

**摘要:** 应用模糊加权最小二乘支持向量机对超短期负荷进行预测, 为了体现离预测点越远的历史负荷数据对预测点负荷值的影响越不明显的特点, 即“近大远小”的原则, 在双向, 即横向(输入样本)与纵向(训练样本集)引入时间域的隶属分布。并用快速留一法在线优化模型的参数, 实现了相关参数的自适应选择, 克服了应用固定系数进行预测的缺点。应用某地区的负荷数据进行了仿真预测, 并应用不同的方法进行了对比。结果表明, 所提出的方法与传统方法相比提高了超短期负荷的预测精度。

**关键词:** 最小二乘支持向量机; 双向加权; 快速留一法; 超短期负荷预测; 自适应参数选择

## Ultra-short-term load forecasting based on adaptive bidirectional weighted least squares support vector machines

WANG Gang<sup>1</sup>, JIANG Jie<sup>1</sup>, TANG Kun-ming<sup>1</sup>, ZHANG Tai-qin<sup>2</sup>

(1. State Key Laboratory of Power Transmission Equipment & System Security and New Technology, Chongqing University, Chongqing 400044, China; 2. Chongqing New Century Electrical Co. LTD, Chongqing 400039, China)

**Abstract:** Weighted least squares fuzzy support vector machines method is proposed for ultra-short-term load forecasting. In order to reflect the characteristic that the nearer data have a greater impact on the predicting value, the membership distribution of time domain is introduced in bi-direction, namely, transverse (output samples) and longitudinal (training samples). To overcome the disadvantage of predicting with a fixed coefficient, fast leave-one-out method is used to adaptively optimize the parameters on-line. The load data from a substation is used for simulating and the applications of different methods are compared. The results show that the proposed method can improve the forecasting accuracy compared with traditional methods.

**Key words:** LS-SVM; bidirectional weighted; fast leave-one-out; ultra-short-term load forecasting; adaptive parameter selection

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2010)19-0142-05

## 0 引言

超短期负荷预测是对未来 1 h 以内的负荷进行预测, 其主要用于实时安全分析、实时经济调度、自动发电控制<sup>[1]</sup>。长期以来, 国内外学者对超短期负荷预测的理论和方法做出了大量的研究, 提出了许多预测方法, 如线性外推法<sup>[2-3]</sup>、神经网络法<sup>[4-5]</sup>等, 线性外推法为线性模型难以反映电力负荷的非线性特性; 而神经网络法存在容易陷入局部最优、“过拟合”、泛化性能力不强等缺点。以上方法的缺点对预测的精度都存在一定的影响。

近年来, Vapnik等<sup>[6-7]</sup>提出了标准的支持向量机(SVM)方法已在许多领域取得了成功的应用, 显示出巨大的优越性, 文献[8-9]利用SVM进行负荷预测, 收到了一定的效果。但SVM存在计算速度较

慢、鲁棒性不强等局限性。为解决速度问题, Suykens等<sup>[10-11]</sup>提出最小二乘SVM算法(LS-SVM)。目前, 最小二乘支持向量机在预测方面已有不少应用<sup>[12-13]</sup>, 都取得了一定的效果, 也有相应的改进, 如文献[14]中考虑了影响预测精度的主要为近期样本, 故赋予各组样本一定的隶属度, 使得训练中近期样本的误差相对较小, 远期样本的误差相对较大。但该方法的LS-SVM相关参数为定值, 其未随着样本的更新而变动, 在一定程度上降低了预测的准确性。超短期负荷预测在不考虑气象因素的条件下, 预测样本的输入需考虑与预测时刻之前若干时段的负荷值和相同类型日同一时刻的负荷值, 这些信息在时间上是纵向分布的, 对所预测负荷的影响不同。鉴于以上原因, 本文提出了基于自适应双向加权最小二乘支持向量机的超短期负荷预测, 即对训练样

本赋予纵向隶属度的同时, 给各训练样本输入向量的元素赋予横向隶属度, 充分体现训练样本各个方位“近大远小”的原则。同时为了能够根据新样本不断更新模型相关参数, 应用快速留一 (fast leave-one-out, FLOO) 交叉验证法<sup>[15]</sup>对模型参数进行优化, 实现每次预测前模型参数的自适应选择。

## 1 双向加权最小二乘支持向量机

### 1.1 LS-SVM

LS-SVM 是标准 SVM 的一种扩展。假设训练样本集为  $T = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_N, y_N)\}$ ,  $N$  为训练样本对的数目, 其中输入  $\mathbf{x}_k \in \mathbf{R}^n$ , 输出值  $y_k \in \mathbf{R}$ , 回归模型可以表示为

$$y(\mathbf{x}) = \mathbf{w}^T \cdot \varphi(\mathbf{x}) + b \quad (1)$$

其中:  $\varphi(*)$  是把训练数据映射到一个高维特征空间;  $\mathbf{w}$  是加权向量;  $b$  是常值偏差。则目标函数定义为

$$\min_{\mathbf{w}, b, e} J(\mathbf{w}, e) = \frac{\gamma}{2} \sum_{k=1}^N e_k^2 + \frac{1}{2} \|\mathbf{w}\|^2 \quad (2)$$

约束条件为

$$y_k = \mathbf{w}^T \varphi(\mathbf{x}_k) + b + e_k, \quad k=1, 2, \dots, N \quad (3)$$

其中:  $\gamma > 0$  为惩罚系数, 用来平衡模型的复杂度和精度的;  $e_k$  为估计误差。

### 1.2 输入向量的横向加权

本文是多输入单输出模式, 输入  $\mathbf{x}_i$  向量中的值是随时间纵向分布的, 通过加权处理体现不同时刻的负荷值对预测值影响的差异。输入向量按式  $\theta_i = \delta(1-\delta)^{n-i}$  加权, 则加权后输入样本变为

$$\dot{\mathbf{x}}_i = \mathbf{x}_{ki} \cdot \theta_i, \quad k=1, 2, \dots, l \quad (4)$$

式中,  $l$  为输入向量维数。

### 1.3 训练样本集的纵向加权

预测值不仅与输入向量中各元素的值相关, 同时也与训练的样本组有一定的相关性。近期样本对预测值的影响相对较大, 而远期的影响则相对较小, 所以根据历史样本对当前负荷影响程度赋予不同的隶属度, 减小早期样本对预测模型的影响, 同时增大近期样本对预测模型的影响。应用线性隶属度  $\mu_i$  予以赋值,  $\mu_i = \beta + i(1-\beta)/N$ , 且  $0 \leq \mu_i \leq 1$ , 则输入样本集变为

$$T = \{(\mathbf{x}_1, y_1, \mu_1), (\mathbf{x}_2, y_2, \mu_2), \dots, (\mathbf{x}_N, y_N, \mu_N)\}$$

### 1.4 双向加权 LS-SVM

将 1.2 节和 1.3 节加权理论相结合便构成

LS-SVM 的双向加权, 此时目标函数 (2) 变为

$$\min_{\mathbf{w}, b, e} J^*(\mathbf{w}, e) = \frac{\gamma}{2} \sum_{k=1}^N \mu_k e_k^2 + \frac{1}{2} \|\mathbf{w}\|^2 \quad (5)$$

约束条件同式 (3), 通过建立 Lagrange 方程求解该问题:

$$L(\mathbf{w}, b, e, \mathbf{a}) = J^*(\mathbf{w}, e) - \sum_{k=1}^N a_k [\mathbf{w}^T \varphi(\mathbf{x}_k) + b + e_k - y_k] \quad (6)$$

其中,  $a_k$  为 Lagrange 乘子, 根据 KKT 最优条件<sup>[6-7]</sup> 可得

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0 \rightarrow \mathbf{w} = \sum_{k=1}^N a_k \varphi(\xi_k) \\ \frac{\partial L}{\partial e_k} = 0 \rightarrow a_k = \gamma \mu_k e_k \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{k=1}^N a_k = 0 \\ \frac{\partial L}{\partial a_k} = 0 \rightarrow \mathbf{w}^T \varphi(\mathbf{x}_k) + b + e_k - y_k = 0 \end{cases} \quad (7)$$

其中,  $k=1, 2, \dots, N$ 。消去  $e_k$  与  $\mathbf{w}$ , 则得到如下线性方程组:

$$\Phi_N \begin{bmatrix} \mathbf{a} \\ b \end{bmatrix} = \begin{bmatrix} \mathbf{Y} \\ 0 \end{bmatrix} \quad (8)$$

$$\Phi_N = \begin{bmatrix} \Omega + V_C & \vec{\mathbf{1}} \\ \vec{\mathbf{1}}^T & 0 \end{bmatrix} \quad (9)$$

式中:  $V_C = \text{diag} \left\{ \frac{1}{\gamma \mu_1}, \dots, \frac{1}{\gamma \mu_N} \right\}$  ;

$\mathbf{Y} = [y_1; y_2; \dots; y_N]$ ;  $\vec{\mathbf{1}} = [1; 1; \dots; 1]$ ,  $\mathbf{a} = [a_1; a_2; \dots; a_N]$   
 $\Omega$  是满足 Mercer 条件的对称函数。

$$\Omega_{ij} = K(\mathbf{x}_i, \mathbf{x}_j) = \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}_j) \quad (10)$$

本文选择高斯径向基 RBF 核

$K(\mathbf{x}, \mathbf{x}^*) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}^*\|^2}{2\sigma^2}\right)$ 。 $\Omega_{ij}$  表示矩阵  $\Omega$  第  $i$  行第  $j$  列对应的值。则最终的非线性回归函数可以表示为:

$$y(\mathbf{x}) = \sum_{k=1}^N a_k K(\mathbf{x}_k, \mathbf{x}) + b \quad (11)$$

## 2 快速留一法

### 2.1 快速留一法策略

为了利用生成的新样本来不断更新双向加权 LS-SVM 的相关参数, 实现预测模型相关参数的自

适应选择,则需要快速有效的优化算法。传统的 LOO<sup>[11]</sup>法计算量大, FLOO<sup>[15]</sup>则使得模型参数的在线选择成为可能。本文预测算法的横向加权参数  $\delta$  取定值,则需要优化选择模型局部参数有  $\gamma, \sigma$  和  $\beta$ 。

记  $\mathbf{Q} = \mathbf{Q} + \mathbf{V}_c$ , 将式 (9) 重新分块为

$$\begin{bmatrix} \mathbf{Q} & \vec{\mathbf{I}} \\ \vec{\mathbf{I}}^T & \mathbf{0} \end{bmatrix} = \begin{bmatrix} \mathbf{c}_{11} & \mathbf{c}_1^T \\ \mathbf{c}_1 & \mathbf{C}_1 \end{bmatrix} = \mathbf{C} \quad (12)$$

对式 (12) 的分块矩阵进行求逆并用 FLOO 处理后发现

$$y_1 - y_1^{\wedge} = \frac{a_1}{C_{11}^{-1}} \quad (13)$$

由式 (8) 可知, 改变各方程的顺序不影响各解, 各个样本的误差可以表示为

$$y_i - y_i^{\wedge} = \frac{a_i}{C_{ii}^{-1}} \quad (14)$$

接下来就是如何确定  $C_{ii}^{-1}$  的值, 对式 (12) 求逆有

$$\mathbf{C}^{-1} = \begin{bmatrix} \mathbf{Q} & \vec{\mathbf{I}} \\ \vec{\mathbf{I}}^T & \mathbf{0} \end{bmatrix}^{-1} = \begin{bmatrix} \mathbf{Q}^{-1} + \mathbf{Q}^{-1} \vec{\mathbf{I}} L_Q^{-1} \vec{\mathbf{I}}^T \mathbf{Q}^{-1} & -\mathbf{Q}^{-1} \vec{\mathbf{I}} L_Q^{-1} \\ -L_Q^{-1} \vec{\mathbf{I}}^T \mathbf{Q}^{-1} & L_Q \end{bmatrix} \quad (15)$$

这里  $L_Q = -\vec{\mathbf{I}}^T \mathbf{Q}^{-1} \vec{\mathbf{I}} = -\vec{\mathbf{I}}^T \boldsymbol{\xi}$ , 对于正定矩阵  $\mathbf{Q}$ , 将其分解为三角矩阵。设  $\mathbf{R} = [r_{ij}]_{i,j=1}^l$  为  $\mathbf{Q}$  的下三角矩阵, 且  $\mathbf{Q} = \mathbf{R}\mathbf{R}^T$ , 设  $\mathbf{S} = [s_{ij}]_{i,j=1}^l = \mathbf{R}^{-1}$ , 则  $\mathbf{Q}^{-1} = \mathbf{S}^T \mathbf{S}$ , 求解各样本的误差时只关心  $\mathbf{Q}^{-1}$  的对角阵元素

$$Q_{ii}^{-1} = \sum_{j=1}^i s_{ij}^2 \Rightarrow C_{ii}^{-1} = \sum_{j=1}^i s_{ij}^2 + \frac{\zeta_i^2}{L_Q} \quad \forall i \in \{1, 2, \dots, N\}$$

将上式求出的  $C_{ii}^{-1}$  代入式 (14), 则预测误差可以表示为

$$y_i - y_i^{\wedge} = \frac{a_i}{\sum_{j=1}^i s_{ij}^2 + \frac{\zeta_i^2}{L_Q}} \quad (16)$$

由于  $\zeta_i$  与  $L_Q$  的计算量很小, 所以计算训练样本预测总误差的复杂度仅约  $\mathcal{O}(N)$ 。

### 2.2 负荷数据的选择与应用

采集数据生成最新样本, 输入量  $\mathbf{x}(k) = [P_{d-L}(k), \dots, P_{d-2}(k), P_{d-1}(k), P_d(k-m), \dots,$

$P_d(k-2), P_d(k-1)]$  样本输出量为  $y(k) = P_d(k)$ ,  $P_{d-L}(k)$  指与预测当天相同类型日最近的前  $L$  天时刻的负荷值,  $P_d(k-m)$  指预测时刻前  $m$  个步长点的负荷值, 本文  $L$  取 3,  $m$  取 5。取与预测时刻最近的  $N$  组样本, 并对样本按 1.2、1.3 节中的方法进行横向、纵向加权, 利用加权后的样本进行训练, 选择相应的最优参数来建立模型, 利用建立的模型进行预测。每次预测前要实现训练样本的更新, 建模过程见下节。

### 2.3 在线建模过程

本文对于横向加权参数  $\delta$  取 0.85, 对于  $\gamma, \sigma$  以及纵向加权参数  $\beta$  采用实时优化处理, 利用 FLOO 对预测模型的参数进行在线选择, 具体步骤如下:

Step1. 基于已有的训练样本离线选择最优参数  $\mathbf{P} = [\gamma_{\text{opt}}, \sigma_{\text{opt}}, \beta_{\text{opt}}]$ 。

Step2. 参考历史相应时刻的  $\mathbf{P}$ , 设定  $\mathbf{P}$  的范围, 基于 FLOO 对参数进行优化, 选择使训练样本误差最小的一组最优参数  $[\gamma_{s,\text{opt}}, \sigma_{s,\text{opt}}, \beta_{s,\text{opt}}]$ , 利用确定的模型预测下一时刻的负荷值  $y(k)$ 。

Step3. 当前预测结束后, 保存当前的  $[\gamma_{s,\text{opt}}, \sigma_{s,\text{opt}}, \beta_{s,\text{opt}}]$ , 将新生成的样本作为下次训练样本的最近样本, 同时删除离预测点时间分布最远的样本, 利用新训练样本离线选择最优参数  $[\gamma_{\text{opt}}, \sigma_{\text{opt}}, \beta_{\text{opt}}]$ 。为预测  $y(k+1)$  做准备, 回到 step 2。

### 3 预测结果分析对比

本文应用的平台是 Matlab7.1, 硬件基础为主频 1.60 GHz, 内存 256 MB 的计算机上, 在工具箱 toolbox LS-SVM lab 的基础上编制相应的程序完成预测。以 15 min 为步长, 预测一天 24 h 的负荷值, 每次预测一个时段, 然后将该点加入历史序列, 并将预测结果与其他方法预测结果进行对比。

在文献[14]的基础上引入横向加权是为了体现不同时刻输入数据对输出数据的影响程度不同, 用图 1 对比文献[14]中的方法与引入双向加权方法的预测效果进行对比(模型相关参数都为定值), 为直观, 只对预测曲线的局部放大进行对比。

由图 1 可以看出在考虑双向加权后的预测结果比只考虑纵向加权的预测曲线更接近实际的负荷值, 可见在考虑了横向“近大远小”的原则后, 预测效果比单单考虑纵向加权的预测效果更佳。另外, 由于横向加权后, 参与预测的数据大大减小, 所以

在预测耗时由原来未进行横向加权的 0.234 s 减小为现在的 0.141 s。

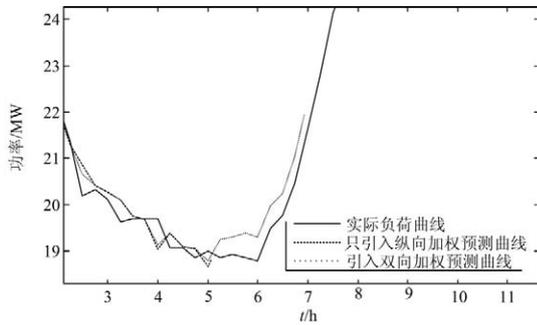


图 1 局部放大的纵向加权预测曲线、双向加权预测曲线和实际负荷曲线

Fig.1 Local magnified of vertical weighted prediction curve, bidirectional weighted prediction curve and the actual load curve

用 BP 神经网络法、双向加权固定系数支持向量法、本文所提出的变系数支持向量法和文献[2]中曲线外推法分别进行了预测。预测结果及相关处理见图 2、图 3 与表 1、表 2。

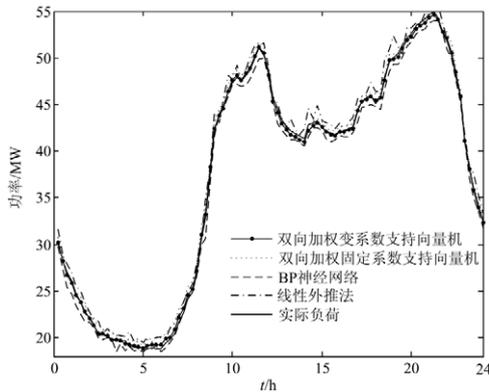


图 2 实际值与不同预测曲线对比  
Fig.2 Actual values and prediction curves

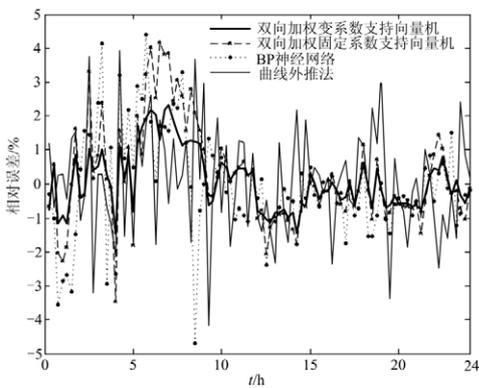


图 3 不同预测方法相对误差曲线

Fig.3 Relative error curves of different prediction methods

表 1 几种模型的预测结果比较

Tab.1 Comparison of the result of different models

Method	t/s	平均绝对百分比误差 / %	归一化方差
1	可略	1.227 5	0.048 0
2	8.672	1.157 9	0.038 0
3	0.141	1.000 5	0.034 3
4	0.435	0.809 4	0.022 1

方法 1 文献 [2] 中应用的方法; 2 表示一般线性自适应神经网络法; 3 表示双向加权固定系数支持向量机模型; 4 表示采用本文的变系数方法。

表 2 误差范围个数对比

Tab.2 Comparing the numbers of error ranges

Method	A	B	C	D	E
1	46	34	9	6	1
2	56	22	11	4	3
3	59	21	9	5	2
4	71	20	5	0	0

A 表示: 绝对百分比误差<1 的个数; B 表示: 1≤绝对百分比误差<2 的个数; C 表示: 2≤绝对百分比误差<3 的个数; D 表示: 3≤绝对百分比误差<4 的个数; E 表示: 绝对百分比误差≥4 的个数

由图 3 可见变系数的预测效果明显比固定系数的效果要好。因为变系数预测模型根据训练样本的变化不断调整模型参数, 充分体现近期数据对预测值影响的情况, 并使训练样本误差在模型相关参数选择的范围内达到最小。

预测时间对比与分析。文献[2]中所述的方法简单, 只由若干历史同一时刻的负荷值计算负荷增量而来, 所以预测用时极少, 神经网络耗时最多。固定加权最小二乘支持向量机将传统支持向量法中的不等式约束用等式约束代替, 减小了运算复杂性, 耗时较少。变系数预测法则由于对相关系数的自适应选择, 所以 CPU 耗时比固定系数预测多。

预测精度比较。由表 1 可见, 本文所提出的预测方法的平均绝对百分比误差和归一化方差比所对比的方法效果更满意。这是因为, 文献[2]中的方法难以反映负荷预测非线性的特点, 且过分依赖历史样本与当前预测值的相似性, 而没有考虑到预测日当天负荷变化的特点; 神经网络法则易陷入局部最优, 难以保证解的最优性。本文所提出的方法则充分考虑了近期数据对预测值的影响, 赋予近期数据较大的比重, 同时, 选择使训练样本误差最小的相关参数来确定预测模型, 所以预测精度相对较高。另外由表 2 可见, 本文提出方法的稳定性较好, 预

测值的绝对百分比误差未超过 3%。

### 4 结论

考虑到负荷预测“近大远小”的原则，本文应用了时间隶属度分布的双向加权支持向量机的预测模型，即输入向量横向加权与训练样本纵向加权。为克服固定权重最小二乘支持向量机对预测精度的影响，同时考虑到在线建模时间问题，用 FLOO 法自适应优化模型参数，在解决固定权重方法预测的同时也保证了较小的计算复杂度。应用本文提出的方法，以 15 min 为步长，对一天 24 h 负荷进行了预测，结果表明，该方法与传统方法相比，提高了超短期负荷预测的精度。

### 参考文献

[1] 康重庆, 夏清, 刘梅. 电力系统负荷预测[M]. 北京: 中国电力出版社, 2007: 7-8.

[2] 丁恰, 卢建刚, 钱玉妹, 等. 一种实用的超短期负荷预测曲线外推方法[J]. 电力系统自动化, 2004, 28 (16): 83-85.

DING Qia, LU Jian-gang, QIAN Yu-mei, et al. A practical method for ultra-short term load forecasting[J]. Automation of Electric Power Systems, 2004, 28 (16): 83-85.

[3] 路轶, 王民昆. 基于短期负荷预测的超短期负荷预测曲线外推法[J]. 电力系统自动化, 2006, 30 (16): 102-104.

LU Zhi, WANG Min-kun. Ultra-short term load forecasting based on short term load forecasting[J]. Automation of Electric Power Systems, 2006, 30 (16): 102-104.

[4] Wiktor C, Mo-Shing Chen. Very short-term load forecasting using artificial neural networks[J]. IEEE Trans on Power Systems, 2000, 15 (1): 263-268.

[5] Chen Dingguo, York M. Neural network based very short term load prediction[C]. // transmission and distribution conference and exposition. Latin(America): 2008: 1-9.

[6] Vapnik V. An overview of statistical learning theory[J]. IEEE Trans on Neural Networks, 1999, 10(5): 988-999.

[7] Platt J. Fast training of support vector machines using sequential minimum optimization[C]. //Advance in Kernel Methods-support Vector Learning. Cambridge: 1999: 185-208.

[8] 李元诚, 方廷健, 于尔铿. 短期负荷预测的支持向量机方法研究[J]. 中国电机工程学报, 2003, 23 (6): 55-59.

LI Yuan-cheng, FANG Ting-jian, YU Er-keng. Study of support vector machine for short-term load forecasting[J].

Proceedings of the CSEE, 2003, 23 (6): 55-59.

[9] 谢宏, 魏江平, 刘鹤立. 短期负荷预测中支持向量机模型的参数选取和优化方法[J]. 中国电机工程学报, 2006, 26 (22): 17-22.

XIE Hong, WEI Jiang-ping, LIU He-li. Parameter selection and optimization method of SVM model for short-term load forecasting[J]. Proceedings of the CSEE, 2006, 26 (22): 17-22.

[10] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers[J]. Neural Network Letters, 1999, 9 (3): 293-300.

[11] Suykens J A K, van Gestel T, de Brabanter J. Least squares support vector machines[M]. Singapore: World Scientific, 2002.

[12] 吴琼, 杨以涵, 刘方颖. 基于最小二乘支持向量机的电力系统暂态稳定在线预测[J]. 中国电机工程学报, 2007, 27 (25): 38-43.

WU Qiong, YANG Yi-han, LIU Fang-ying. Electric power system transient on-line prediction based on least squares support vector machine[J]. Proceedings of the CSEE, 2007, 27 (25): 38-43.

[13] 杜颖, 卢继平, 李青, 等. 基于最小二乘支持向量机的风电场短期风速预测[J]. 电网技术, 2008, 32 (15): 62-66.

DU Ying, LU Ji-ping, LI Qing, et al. Short-term wind speed forecasting of wind farm based on least square-support vector machine[J]. Power System Technology, 2008, 32 (15): 62-66.

[14] 孙林, 杨世元, 吴德会. 基于隶属度模糊最小二乘支持向量机的工序能力预测[J]. 中国机械工程, 2008, 19 (13): 1561-1564.

SUN Lin, YANG Shi-yuan, WU De-hui. Intelligent prediction for process capability based on FLS-SVM[J]. China Mechanical Engineering, 2008, 19 (13): 1561-1564.

[15] Cawley G C, Talbot N L C. Preventing over-fitting during model selection via Bayesian regularization of the hyper-parameters[J]. Machine Learning Research, 2007, 8 (5): 841-861.

收稿日期: 2009-10-09; 修回日期: 2009-11-16

### 作者简介:

王 岗 (1984-), 男, 硕士研究生, 研究方向为负荷预测与电力自动化; E-mail: wggg1011@163.com

姜 杰 (1958-), 男, 副教授, 从事电力系统保护与综合自动的研究;

唐昆明 (1959-), 男, 副研究员, 从事电力系统保护与自动化的研究。