

基于偏最小二乘支持向量机的短期电力负荷预测方法研究

吉训生^{1,2}

(1. 东南大学自动化学院, 江苏 南京 210096; 2. 江南大学通信与控制工程学院, 江苏 无锡 214122)

摘要: 偏最小二乘 (PLS) 运算降低电力负荷数据之间的相关性, 最小二乘支持向量机 (LS-SVM) 可以获得模型的全局最优预测效果, 减少预测过程的运算量。介绍了 PLS 和 LS-SVM 的基本原理, 给出了 PLS-LS-SVM 建立短期日电力负荷预测模型的过程, 并用于某地区 2008 年的用电日负荷预测, 预测的平均相对误差和最大相对误差分别为 0.685% 和 8.8599%。与基于 AR(1) 模型的预测结果相比, PLS-LS-SVM 模型更高的预测准确性可为短期电力负荷预测提供有效依据。

关键词: 偏最小二乘; 最小二乘支持向量机; 电力负荷预测; AR(1) 模型; 预测误差

Short-term power load forecasting on partial least square support vector machine

Ji Xun-sheng^{1,2}

(1. School of Automation, Southeast University, Nanjing 210096, China; 2. School of Communication and Control Engineering, Jiangnan University, Wuxi 214122, China)

Abstract: Partial least square (PLS) can decrease the correlation among the power load information. The least square support vector machine (LS-SVM) can get the global optimal forecasting result of the power load and decrease the computation burden. Principles of the PLS, LS-SVM and PLS-LS-SVM are introduced. PLS-LS-SVM is used to establish short-term daily power load prediction forecast model and then the model is applied to the daily power load forecast in a certain area in 2008. Mean relative forecasting error and maximal relative forecasting error are 0.685 percent and 8.8599 percent respectively. Compared with the AR(1) model, excellent forecasting accuracy of the PLS-LS-SVM model can supply the short-term power load forecasting an effective way.

Key words: partial least square (PLS); least square support vector machine (LS-SVM); power load forecasting; AR(1) model; forecasting error

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2010)23-0055-05

0 引言

随着电网技术水平的不断提高, 围绕提高预测精度的电力系统负荷预测工作具有十分重要的现实意义。短期负荷预测一般指一年之内以天或小时为单位的负荷预测, 其意义在于实现发电容量的合理调度, 满足给定运行要求, 使发电成本最小。

电力负荷预测分为经典预测方法和现代预测方法。经典预测方法包括趋势外推法、时间序列法、回归分析等方法。现代预测方法包括灰色数学理论、专家系统方法、神经网络理论、模糊预测理论等^[1-3]。由于电力负荷预测属于典型的非线性问题, 以往人们都是用人工神经网络来处理这种非线性问题, 但这种方法容易使预测陷入局部极小值。近年来出现的以统计学习理论为基础的支持向量机 (Support Vector Machine, SVM), 有机结合了统计理论、机

器学习、优化理论等理论, 根据结构风险最小化原则自动学习模型的结构, 通过调节控制参数改变模型结构, 可以用于电力系统的短期负荷预测^[4-8]。

偏最小二乘 (Partial Least Squares, PLS) 具有高效提取信息的作用, 自上世纪 80 年代以来一直有较多应用。PLS 可以同时输入和输出数据进行分解, 使得 PLS 模型能从较少的已知向量中得到尽可能多的信息^[9]。由于 PLS 采用的是线性回归, 用于非线性建模时性能较差, 因此可以将 PLS 与 SVM 相结合进行日用电量负荷的短期预测, 提高模型的非线性处理能力, 可以取得比常用的时序法更好的预测精度。

1 偏最小二乘 (PLS) 回归分析

PLS 回归方法常用于观测数据的“软”建模, 在同一算法下, 可以实现回归建模、数据结构简化

和多变量之间的相关分析,给多元数据分析带来极大便利。根据对某地区的月用电负荷分析,发现当月的日用电负荷和前面数月的日用电负荷之间具有一定的相关性。因此,可以将每个月的日用电负荷作为一个独立的输入变量矢量,用前数月的日用电负荷预测后面每个月甚至数月的日用电负荷。实际日用电负荷预测结果表明,将每个月的用电负荷作为输入矢量,利用 PLS 方法,其预测精度大大提高。PLS 的建模过程主要包括以下几步^[9]。

(1) 数据的标准化处理

对自变量 $X = \{x_1, x_2, \dots, x_m\}$ (m 为自变量的个数) 和因变量 y 进行标准化,使样本点集合的重心与坐标原点重合,这样可以将不同量纲、不同数量级的数据能在一起进行比较。标准化过程为

$$E_{0_i} = x^* = (x_i - \bar{x}_i) / S_{x_i}; F_0 = y^* = (y - \bar{y}) / S_y \quad (1)$$

式中: E_{0_i}, F_0 分别为 x_i, y 的标准化向量; \bar{x}, \bar{y} 分别为 X, y 的均值; S_x, S_y 分别为 X, y 的均方差。

(2) 提取输入主成分 t_h 和输出主成分 u_h

主成分分析的工作目标就是对多变量数据表进行最佳综合简化,在确保数据信息损失最小的原则下,对高维数据空间进行降维处理。基本原理就是:如果在原数据中有 m 个变量 x_1, x_2, \dots, x_m ,主成分分析将考虑对该组数据中的信息重新组合,从中提取 h 个新的综合变量 $F_1, F_2, \dots, F_h (h < m)$,使这 h 个综合变量能最多地概括原数据组中的信息,这些新的综合变量就是主成分^[9]。从输入变量 E_h 和输出变量 F_h 中提取主成分 t_h 和 u_h 的方法为

$$\begin{cases} t_h = E_{h-1} w_h & w_h = E_{h-1}^T F_{h-1} / \|E_{h-1}^T F_{h-1}\| \\ E_h = t_h p_h^T + E_{h-1} & F_h = t_h r_h^T + F_{h-1} \\ p_h = E_h^T t_h / \|t_h\|^2 & r_h = F_{h-1}^T t_h / \|t_h\|^2 \end{cases} \quad (2)$$

(3) 偏最小二乘回归模型

F_0 关于 $t_1 \sim t_h$ 成分的回归方程为

$$F_0 = r_1 t_1 + r_2 t_2 + \dots + r_h t_h \quad (3)$$

$$t_j = E_{j-1} w_j = E_0 w_j^* = \prod_{i=1}^{j-1} (I - w_i p_i^T) w_j \quad (4)$$

则标准化变量的回归方程为

$$\hat{y}^* = \sum_{i=1}^m \alpha_i x_i^* \quad (5)$$

其中, $\alpha_i = \sum_{j=1}^h r_j w_{ji}^*$ 。如果取 $\alpha_i = \alpha_i S_y / S_x$ 。关于原始变量 y 的估计 \hat{y} 的回归方程为

$$\hat{y} = (\bar{y} - \sum_{i=1}^m \alpha_i \bar{x}_i) + \sum_{i=1}^m \alpha_i x_m \quad (6)$$

2 最小二乘支持向量机 (LS-SVM) 回归模型

支持向量机具有很好的泛化能力,偏最小二乘可以解决多变量之间的相关问题,以达到数据降维和滤除噪声的目的。通过偏最小二乘回归从原始输入数据 X 和输出数据 y 中提取出的主成分 t_1, t_2, \dots, t_h 和 u_h 分别作为支持向量机的样本输入和输出,既能降低输入数据之间的相关性,提高模型的预测能力,又能保证回归过程具有最小的预测风险。而最小二乘支持向量机 (LS-SVM) 可以将 SVM 回归中的不等式约束转变成等式约束,简化优化过程^[5-6]。

给定 l 个样本数据,其值表示为 (x_k, y_k) , 式中 $x_k \in R^n$ 的 n 维向量, $y_k \in R$ 为相应的输出变量。函数拟合问题可以描述为如下的优化问题

$$\min \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{i=1}^l \xi_i^2 \quad (7)$$

$$\text{st. } y_i = w^T \varphi(x_i) + b + \xi_i, i = 1, 2, \dots, l$$

其中, $\varphi(\cdot): R^n \rightarrow R^n$ 是将输入数据映射到高维特征空间的非线性函数,权值向量 $w \in R^{n_k}$, 误差变量和偏置值满足 $\xi_i \in R$ 及 $b \in R$ 。 γ 为损失系数,能够在训练误差和模型复杂度之间取一个折衷以便使所求的函数具有较好的泛化能力,并且 γ 越大,模型的回归误差越小。

定义核函数 $K(x, x_i) = \Psi(x) \Psi(x_i)$ 代替非线性映射,可以得到拟合函数 $f(x)$ 的最小二乘支持向量机估计函数为:

$$f(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b \quad (8)$$

各参数可以通过将求解的优化问题转化为求解最优 Lagrange 乘子 $\alpha_i (i = 1, 2, \dots, l)$ 和偏置 b 的线性方程得到,求解表达式如下:

$$\begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & K(x_1, x_1) + \frac{1}{\gamma} & \dots & K(x_1, x_l) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & K(x_l, 1) & \dots & K(x_l, x_l) + \frac{1}{\lambda} \end{bmatrix} \begin{bmatrix} b \\ \alpha_1 \\ \vdots \\ \alpha_l \end{bmatrix} = \begin{bmatrix} 1 \\ y_1 \\ \vdots \\ y_l \end{bmatrix} \quad (9)$$

这样,LS-SVM 算法将二次规划问题转变为一组线性方程的求解。与标准 SVM 相比,减少了参数调整和变量优化,大大降低了计算复杂度,同时也提高了收敛速度。

3 PLS-LS-SVM 建模

PLS-LS-SVM 方法主要是基于将经过特征提取得到的各主成分向量组成得分矩阵 \mathbf{T} ，代替原有的输入矩阵 \mathbf{X} 用于 LS-SVM 建模，使得输入变量的维数大幅减少，在提高建模速度的同时也消除了由高维变量共线性所引入的噪声。PLS-LS-SVM 的处理过程分为以下三步：

(1) 特征提取

由式 (2) 计算得到的向量 t_i 、 p_i 和 w_i 分别构成训练样本的得分矩阵 $\mathbf{T}_{\text{train}} = [t_1, \dots, t_h]$ ，负载矩阵 $p = [p_1, \dots, p_h]$ 和相关系数矩阵 $\mathbf{w} = [w_1, \dots, w_h]$ 。

(2) LS-SVM 建模

用 $\mathbf{T}_{\text{train}}$ 、 $\mathbf{y}_{\text{train}}$ 训练 SVM 模型，得到参数最优的 Lagrange 乘子 $\alpha_i (i=1, 2, \dots, l)$ 和偏置 b 。这里使用 LS-SVM 方法建模，求解式

$$\begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \mathbf{\Omega} + \gamma^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y}_{\text{train}} \end{bmatrix} \quad (10)$$

其中， $\mathbf{1}^T$ 为矩阵元素都为 1 的矩阵，矩阵维数由 $\mathbf{\Omega} + \gamma^{-1} \mathbf{I}$ 的维数确定， \mathbf{I} 为单位矩阵。其中 $\mathbf{\Omega} = \{\Omega_{kl} = K(t_k, t_l); k, l=1, 2, \dots, N\}$ 为核函数，可以采用 $K(t_k, t_l) = \exp(-\|t_k - t_l\|^2 / \sigma^2)$ 的形式， t_k 和 t_l 为训练样本得分 $\mathbf{T}_{\text{train}}$ 的向量，通过式 (10) 可解出模型系数 b 、 α 。

(3) 模型预测

由待测输入矢量 \mathbf{X}_{test} 和前面计算得到的负载矩阵 \mathbf{W} 以及相关系数矩阵 \mathbf{P} 计算测试样本的得分向量 \mathbf{T}_{test} ，

$$\mathbf{T}_{\text{test}} = \mathbf{X}_{\text{test}} \mathbf{W} (\mathbf{P}^T \mathbf{W})^{-1} \quad (11)$$

计算测试样本的预测值

$$y_{\text{predict}}(t) = \sum_{k=1}^N \alpha_k K(t_k, t) + b \quad (12)$$

其中： t_k 为训练样本的得分向量， t 为测试样本 \mathbf{T}_{test} 的得分向量。

4 电力负荷的实测数据和性能评价

为了验证文中所提出的 PLS-LS-SVM 算法对短期电力负荷预测的有效性，选用南通市海安县 2008 年的日用电负荷数据进行验证^[10]，并与常用的时序法预测进行比较。在预测过程中，以 1、2 月份的日负荷数据作为两维输入矢量数据，训练样本建立适当的数学模型后，预测后面 3 个月甚至更长时间的用电日负荷。

采用基于径向基 (RBF) 核函数的 PLS-LS-SVM 方法建立校正模型时需要设定损失系数 γ 和核函数宽度 σ^2 以及主成分数 h 三个参数。径向基核函数的表达式为

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{\sigma^2}\right) \quad (13)$$

分别考察 σ^2 、 γ 和 h 变化时模型预测效果的变化情况。以预测均方根误差 (Root Mean Square Error of Prediction, RMSE) 来衡量建模效果，其表达式为

$$RMSE = \sqrt{\frac{\sum (y_{\text{pre}} - \hat{y}_{\text{pre}})^2}{n_{\text{pre}}}} \quad (14)$$

式中： \hat{y}_{pre} 为校正样本因变量的 y_{pre} 实测值， n_{pre} 为校正样本中数据组个数。用留一交叉验证的方法，即依次剔除一个样本后用剩余的样本建模后，再用模型预测被剔除样本的负荷值，最后得到对应的 RMSE。根据各参数对建模效果影响的分析，最终确定 $h=3, \gamma=1000, \sigma^2=10^{-6}$ 。图 1 是该地区三到五月份的用电日负荷。

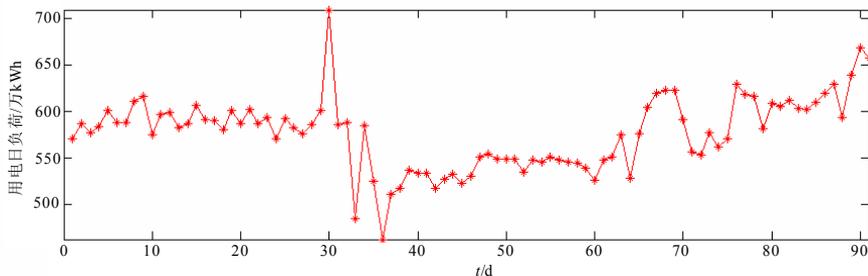


图 1 实际用电日负荷

Fig.1 Original daily power load

图 2 和图 3 是用 PLS-LS-SVM 方法、LS-SVM 方法和 AR 方法进行一步预测的预测结果与实际值

之间的绝对误差比较。从图中可以看出，基于 PLS-LS-SVM 方法的日用电负荷预测结果比基于

LS-SVM 方法和 AR 方法的日用电负荷预测结果要好得多, 因为 AR 模型预测对平稳随机序列的预测效果比较理想, 而电力日负荷受气温等因素影响, 很

难成为一个平稳随机序列^[11]。同时, PLS 可以减少电力负荷之间的相关性, 从而进一步提高预测精度。

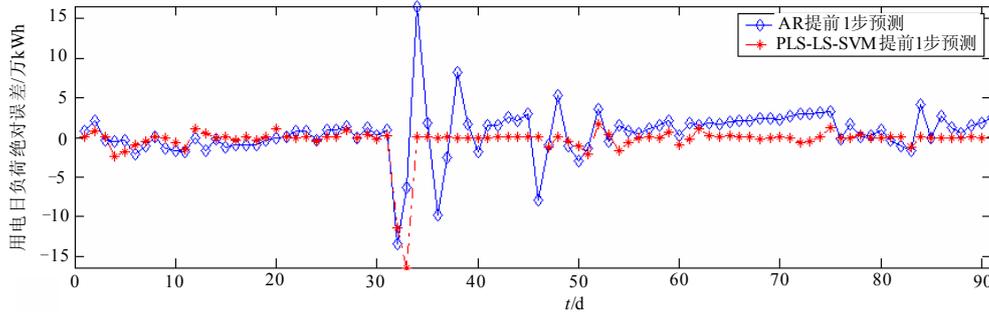


图2 PLS-LS-SVM 和 AR 模型预测绝对误差比较

Fig.2 Comparison between the absolute error from model forecasting of PLS-LS-SVM and AR

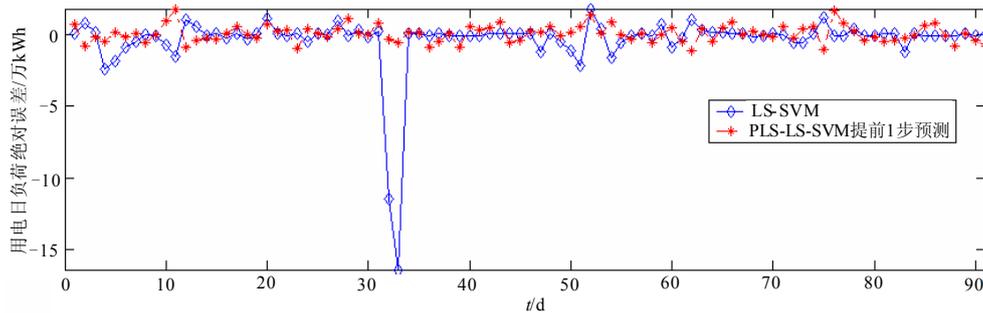


图3 LS-SVM 和 PLS-LS-SVM 预测绝对误差比较

Fig.3 Comparison between the absolute error from model forecasting of LS-SVM and PLS-LS-SVM

为了比较各种预测方法的性能, 采用平均相对误差和最大相对误差表示预测的总体效果, 计算表达式分别为

$$Mean_Error = \frac{1}{12} \left(\sum_{i=1}^{12} \left| \frac{y_i - y_{pre}}{y_i} \right| \times 100\% \right) \quad (15)$$

$$Max_Error = \text{Max} \left(\left| \frac{y_i - y_{pre}}{y_i} \right| \times 100\% \right) \quad (16)$$

表 1 列出了各种预测方法的比较结果。从表中可以看出, AR 模型的预测性能最差, PLS-LS-SVM 预测的平均相对误差是 AR 模型和 LS-SVM 的 16% 和 56.15%, 预测精度是 AR 模型和 LS-SVM 的 5.9 倍和 3.3 倍, 最大相对误差也小于 10%, 完全满足

表 1 各种预测方法的性能比较

Tab.1 Comparison among all the forecasting result			
	AR	LS-SVM	PLS-LS-SVM
RMSE	38.4877	16.8351	6.6537
Mean_Error /%	4.29	1.22	0.3
Max_Error /%	25.9425	14.7302	2.8599

实际电力系统负荷预测的精度要求。因此, 基于 PLS-LS-SVM 的电力系统负荷预测方法可以用于电力系统的短期负荷预测。

5 结论

在选取合适参数后, 基于 PLS-LS-SVM 方法的日用电负荷比基于 AR 方法和 LS-SVM 的预测精度要显著提高, 说明基于核函数的非线性建模方法确实能有效减少由对象的非线性特性引起的系统误差, 而 PLS 方法能够降低信号间的相关性, 和 LS-SVM 结合起来, 可以有效提高模型的整体预测性能。

参考文献

- [1] Kalaitzakis K, Starakakis G S. Short-term load forecasting based on artificial neural networks parallel implementation[J]. Electric Power Systems Research, 2002, 63: 185-196.
- [2] Tomonobu Senjyu, Hitoshi Takara. One-hour ahead load forecasting using neural network[J]. IEEE Transactions on Power Systems, 2002, 17 (1): 113-118.

- [3] Abdel-Aal R E. Improving electric load forecasts using network committees[J]. Electric Power Systems Research, 2005, 74: 83-94.
- [4] 张筱慧. 标么值加权平均组合变量生成法用于中长期电力负荷预测[J]. 电力系统保护与控制, 2009, 37(12): 40-43.
ZHANG Xiao-hui. Per-unit value weighted average combined variable generated method for mid-long term power load forecasting[J]. Power System Protection and Control, 2009, 37(12): 40-43.
- [5] 肖先勇, 葛嘉, 何德胜. 基于支持向量机的中长期电力负荷组合预测[J]. 电力系统及其自动化学报, 2008, 20(1): 84-88.
XIAO Xian-yong, GE Jia, HE De-sheng. Combination method of mid-long term load forecasting based on support vector machine[J]. Proceedings of the CSU-EPSA, 2008, 20(1): 84-88.
- [6] 杨春玲, 李天云, 王爱凤. 基于自适应加权最小二乘支持向量机的短期负荷预测方法[J]. 吉林电力, 2007, 35(3): 18-21.
YANG Chun-ling, LI Tian-yun, WANG Ai-feng. An adaptive weighed LS-SVM approach for STLF[J]. Jilin Electric Power, 2007, 35(3): 18-21.
- [7] 耿艳, 韩学山, 韩力. 基于最小二乘支持向量机的短期负荷预测[J]. 电网技术, 2008, 32(18): 72-76.
GENG Yan, HAN Xue-shan, HAN Li. Short-term load forecasting based on least squares support vector machines[J]. Power System Technology, 2008, 32(18): 72-76.
- [8] Chen Bojun, Chang Mingwei, Lin Chijin. Load forecasting using support vector machines[J]. IEEE Transactions on Power Systems, 2004, 19(4): 1821-1830.
- [9] 王惠文, 吴载斌, 孟洁. 偏最小二乘回归的线性与非线性方法[M]. 北京: 国防工业出版社, 2006.
WANG Hui-wen, WU Zai-bin, MENG Jie. Partial least-squares regression-linear and nonlinear methods [M]. Beijing: National Defense Industry Press, 2006.
- [10] 海安统计年鉴[R]. 2008.
Haian Statistic Annual[R]. 2008.
- [11] 李新炜, 王子琦, 方鸣, 等. 基于分区逐时气象信息的全网负荷预测研究[J]. 电力系统保护与控制, 2009, 37(3): 36-40.
LI Xin-wei, WANG Zi-qi, FANG Ming, et al. Daily load forecasting based on hourly area weather data[J]. Power System Protection and Control, 2009, 37(3): 36-40.

收稿日期: 2009-11-28; 修回日期: 2010-08-26

作者简介:

吉训生(1969-), 男, 副教授, 博士, 研究方向为微机电力系统理论及应用。E-mail: shxybkpg@163.com

(上接第5页 continued from page 5)

- [11] Park K B, Tsuiji T. Terminal sliding mode of second-order nonlinear uncertain system[J]. International Journal of Robust and Nonlinear Control, 1999, 9(11): 769-780.
- [12] 贺昱曜, 闫茂德. 非线性控制理论及应用[M]. 西安: 西安电子科技大学出版社, 2007.
- [13] 刘金琨. 滑模变结构控制MATLAB仿真[M]. 北京: 清华大学出版社, 2005.
- [14] YU Xing-huo, MAN Zhi-hong. Fast terminal sliding-mode control design for nonlinear dynamical systems[J]. IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications, 2002, 49(2): 261-264.
- [15] YU Shuang-he, YU Xing-huo, MAN Zhi-hong. Robust global terminal sliding mode control of SISO nonlinear uncertain systems[C]. //Proceedings of the 39th IEEE Conference on Decision and Control. Sydney(Australia): 2000: 2198-2203.
- [16] Kundur P. Power system stability and control[M]. New York(USA): McGraw-Hill Inc, 1994.
- [17] 孙元章, 焦小红, 申铁龙. 电力系统非线性鲁棒控制[M]. 北京: 清华大学出版社, 2008.
- [18] 卢强, 王仲鸿, 韩英铎. 输电系统最优控制[M]. 北京: 科学出版社, 1982.

收稿日期: 2009-12-09; 修回日期: 2010-03-29

作者简介:

曾正(1986-), 男, 博士研究生, 研究方向为微电网与分布式发电、电力系统运行与控制; E-mail: zengerzheng@126.com

刘涤尘(1953-), 男, 博士, 教授, 博士生导师, 主要研究方向为电力系统运行与控制;

廖清芬(1975-), 女, 博士, 讲师, 主要研究方向为电机及电力系统的稳定与控制。