

基于 LSSVM 与 SMO 稀疏化算法的短期负荷预测

刘耀年, 沈轶群, 姜成元, 陈灵根

(东北电力大学电气工程学院, 吉林 吉林 132012)

摘要: 针对最小二乘支持向量机(LSSVM)仅考虑等式约束, 失去了支持向量机(SVM)解的稀疏性, 影响了二次学习效率的问题, 把最小二乘支持向量机与序列最小优化算法(SMO)相结合, 后者应用改进的剪枝算法对解进行稀疏化处理, 解决了上述问题; 算法与最小二乘支持向量机相比降低了计算的复杂度, 提高了计算精度。将此方法应用到电力系统短期负荷预测, 与SVM和LSSVM算法比较表明该方法运行速度快, 精度高, 取得了较好的预测结果。

关键词: 最小二乘支持向量机; 序列最小优化; 短期负荷预测; 剪枝算法; 稀疏化

A short-term load forecasting approach based on imposing sparseness upon LSSVM integrated SMO algorithms

LIU Yao-nian, SHEN Yi-qun, JIANG Cheng-yuan, CHEN Ling-gen
(Northeast Dianli University, Jilin 132012, China)

Abstract: Least squares support vector machines (LSSVM) losses the sparseness of solution, because LSSVM only considers equation constraint. It influences second learning efficiency. In order to solve the problem, LSSVM integrates with sequential minimal optimization (SMO) algorithm and a modified pruning algorithm imposes sparseness upon the solution of LSSVM integrated SMO algorithms. Compared with LSSVM, the integrative algorithms reduce calculation complexity and improve computing accuracy. The integrative algorithms are applied in power system short-term load forecasting. Through comparison and analysis of load forecasting results between the integrative algorithms, SVM and LSSVM, the results show the integrative algorithms have high accuracy and high efficiency, so the accuracy of load prediction is furtherly improved.

Key words: LSSVM; SMO; short-term load forecasting; pruning algorithm; sparseness

中图分类号: TM715 文献标识码: A 文章编号: 1003-4897(2008)04-0063-04

0 引言

电力系统短期负荷预测是调度的一项重要工作, 也是制定购电计划和经济运行的主要依据, 对电力系统安全、可靠的运行意义重大^[1]。随着电力系统的发展, 预测精度高、能够考虑各种影响因素的预测方法越来越受到重视。

近年来, 支持向量机(SVM)算法在预测理论中得到了全面深入的发展, 已成为机器学习和数据挖掘领域的标准工具^[2]。为了能够对大样本进行学习, Suyken 提出了最小二乘支持向量机(LSSVM), 由于算法仅考虑等式约束, 失去了 SVM 解的稀疏性, 因此样本数量对 LSSVM 算法的速度仍有较大的影响^[3]。

本文将最小二乘支持向量机(LSSVM)与序列最小优化(SMO)^[4]算法结合起来形成新算法, 算法应

用改进的剪枝算法对解进行稀疏化处理^[5], 与最小二乘支持向量机相比降低了计算的复杂度, 提高了计算速度, 算法在短期负荷预测中得到较好的预测结果。

1 最小二乘支持向量机

最小二乘支持向量机^[3]与标准支持向量机的不同在于把不等式约束改为等式约束, 并把经验风险由偏差的一次方改为二次方。回归最小二乘支持向量机提法如下:

设有 N 个训练样本的数据集 $\{x_k, y_k\}_{k=1}^N$ 输入 $x_k \in R^n$, 输出 $y_k \in R$, 在原始空间中, 最小二乘支持向量机回归模型具体如下形式:

$$y(x) = w^T \phi(x) + b \quad (1)$$

综合考虑函数复杂度和拟合误差, 回归问题可以表

示为约束优化问题:

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

$$\text{s.t. } y_k = w^T \phi(x_k) + b + e_k, \quad k=1,2,\dots,N$$

为了求解上述优化问题,把约束优化变为无约束优化问题,建立 Lagrange 函数:

$$L(w,b,e,a) = \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{k=1}^N e_k^2 - \sum_{k=1}^N a_k \{w^T \phi(x_k) + b + e_k - y_k\} \quad (3)$$

式中: a_k 是拉格朗日乘子, e_k 为样本点处的误差。根据 KKT 条件有:

$$\frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{k=1}^N a_k = 0$$

$$\frac{\partial L}{\partial e_k} = 0 \Rightarrow a_k = \gamma e_k$$

$$\frac{\partial L}{\partial a_k} = 0 \Rightarrow w^T \phi(x_k) + b + e_k - y_k = 0$$

$$\frac{\partial L}{\partial w} = 0 \Rightarrow w = \sum_{k=1}^N a_k \phi(x_k)$$

消去 w 和 e_k 得:

$$\begin{bmatrix} 0 & 1_v^T \\ 1_v & Q + \frac{1}{\gamma} \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (4)$$

其中: $y = (y_1, y_2, \dots, y_N)^T$, $1_v = (1, 1, \dots, 1)^T$,

$a = (a_1, a_2, \dots, a_N)^T$, $i, j = 1, 2, \dots, N$,

$Q_{ij} = (\phi(x_i) \phi(x_j)) = k(x_i, x_j)$ 。所求的拟合函数,即支持向量机的出为:

$$y(x) = \sum_{k=1}^N a_k k(x, x_k) + b \quad (5)$$

最小二乘支持向量机与标准支持向量机比较起来,具有以下特点:

- 1) 具有更小的计算复杂性;
- 2) 解丧失稀疏性;
- 3) 最小二乘支持向量机能够扩展为自回归的形式来处理动态的问题;
- 4) 最小二乘支持向量机把支持向量、调节神经网络、高斯过程、bays 技术有机的统一在一起,能够探讨它们的本质联系。

2 LSSVM-SMO 结合稀疏化算法

2.1 LSSVM 与 SMO 结合的算法

序列最小优化 SMO (Sequential Minimal Optimization) 算法起到“固定工作样本集”的作用,它可以把工作样本集的规模减少至两个样本^[6]。

LSSVM 与 SMO 算法的结合过程为:设计两层嵌套循环,选择两个样本作为工作样本集。首先外层循环遍历整个样本空间,选取第一个样本,即选取违反 KKT 条件的样本进行调整,直到所有样本全部满足 KKT 条件为止。内层循环选取另一个样本与第一个样本配对优化,选择根据最大优化步长来定,即满足

$$\max |f(x_1) - f(x_2) + y_1 - y_2| \quad (6)$$

条件的样本点,使其余的拉格朗日乘子保持不变。再用解析的方法对这两个样本点的拉格朗日乘子进行联合优化(最小二乘支持向量机可以通过式(4)直接求出其拉格朗日乘子),这样处理可以将大的矩阵计算转化为只有两个样本点的矩阵计算,虽然叠代过程增多,但在速度上也有明显的提高。

2.2 解的稀疏化处理

LSSVM 算法的最大缺点是丧失了解的稀疏性,其原因有两方面^[7]:一是 LSSVM 的目标函数采用了 2-范数 $\sum e_k^2$;二是支持值的大小与训练点的误差成正比, $a_k = \gamma e_k$, 这使得 $a_k=0$ 的点大大减少。

Suyken 在文献[5]中给出了一种简单易行的剪枝方法用来稀疏化解向量,在 LSSVM 的训练后,根据 $|a_k|$ 的大小对样本降序排列,剔除 $|a_k|$ 较小的一部分样本,再对其余样本重新训练直到用户定义的性能指标急剧下降或是剩余样本集满足需要为止。

本文 LSSVM-SMO 结合的改进的解的稀疏化步骤如下:

- 1) 根据 2.1 中所阐述的方法对 N 个样本进行 LSSVM 和 SMO 算法训练;
- 2) 得到支持值绝对值的结果数列 $\{|a_k|, k=1, 2, \dots, N\}$, 将 $|a_k|$ 的 0.05 分位数 $M_{0.05}$ 分位数作为阈值,将所有 $|a_k| < M$ 的样本点删除;
- 3) 将阈值的支持值所对应的样本点保留,重新进行 LSSVM 和 SMO 算法训练,得到新的分类,直至用户所定义的性能指标下降为止。

这样循环训练势必对速度会有些影响,但是准确性会大大提高。

3 LSSVM-SMO 算法的短期负荷预测

3.1 样本及其输入、输出量的选择

训练样本可通过聚类找出与预测点在星期属性、节假日属性以及预测时段都相同的数据作为 LSSVM 中的 y 值, 输入 x 值的具体考虑是:

1) $B = \{b_1, b_2, \dots, b_n\}$, 预测日前 n 日内在预测时段的负荷数据。

2) $C = \{C_1, C_2, \dots, C_m\}$, 预测日前一日预测时段之前 m 个时段的负荷数据。

3) $D = \{d_1, d_2, \dots, d_s\}$, 预测日的气温预报, 共 s 个数据, 包括平均气温、最高温度、最低温度、风力、湿度等。

4) $E = \{e_1, e_2, \dots, e_7\}$, 预测日的周属性, 代表周一到周日每个变量用 1 和 0 表示。

本文的样本选择如下:

设 $L(d, h)$ 为预测负荷, d 为预测日, h 为预测时刻。本文选取 16 个输入数据: 其中历史数据 7 维, 分别是 $L(d-1, h), L(d-1, h-1), L(d-1, h-2), L(d-1, h-3), L(d-2, h), L(d-3, h), L(d-7, h)$; 气象数据是预测日的最高气温与最低气温; 日类型 7 个, 分别表示周一至周日, 如 $[0\ 0\ 1\ 0\ 0\ 0\ 0]$ 表示周三。

本文核函数选择高斯基 RBF 核函数,

$$K(x, x_i) = \exp(-\|x - x_i\|^2 / 2\sigma^2), \quad \gamma = 15, \quad \sigma^2 = 20.$$

3.2 负荷预测步骤

1) 对历史数据进行平滑和归一化处理, 即将原始数据通过线性变化至 $[-1, 1]$ 区间中, 构成训练样本集。归一化公式为:

$$x_m = \frac{x_{\max} + x_{\min}}{2} \quad x'_i = \frac{x_i - x_m}{0.5 \cdot (x_{\max} - x_{\min})}$$

其中: x_m 代表数据变化范围的中间值。 x'_i 为归一化

数据, x_i 为实测值。

2) 根据样本集建立如式(2)的目标函数。

3) 用 LSSVM-SMO 算法对样本集训练及稀疏化处理, 得到合适的权系数向量 a_k 、偏移量 b 。

4) 将所求的 a_k 和 b 带入式(5), 预测样本完成对预测日的预测。

表 1 三种算法的误差对照表

Tab.1 Comparison of forecasting results error of three algorithms

算法	误差 %	周一	周二	周三	周四	周五	周六	周日
SVM	eMAPE	2.46	2.70	2.75	1.70	1.29	3.27	3.43
	最大相对误差	3.19	4.48	4.54	5.11	4.19	7.12	6.21
	误差 >5% 个数	0	0	0	2	0	2	1
LSSVM	eMAPE	1.70	1.31	1.86	2.54	1.24	2.33	2.14
	最大相对误差	3.56	3.54	3.08	5.33	2.44	6.69	5.86
	误差 >5% 个数	0	0	0	2	0	2	3
稀疏化的 L-S 算法	eMAPE	1.53	1.66	1.71	1.88	1.16	1.53	1.34
	最大相对误差	3.36	3.84	4.20	3.99	2.31	3.60	5.38
	误差 >5% 个数	0	0	0	0	0	0	1

表 2 2006 年 8 月 3 日负荷预测结果

Tab.2 Load forecasting results on August 3, 2006

时刻	实际值/MW	预测值/MW	相对误差/(%)	时刻	实际值/MW	预测值/MW	相对误差/(%)
1:00	27.55	27.99	1.61	13:00	33.40	32.64	2.27
2:00	29.00	28.60	1.36	14:00	35.24	35.10	0.39
3:00	28.21	28.58	1.32	15:00	35.78	35.13	1.80
4:00	27.82	28.43	2.19	16:00	34.68	34.96	0.79
5:00	30.72	31.36	2.09	17:00	36.16	36.45	0.81
6:00	33.47	32.56	2.79	18:00	39.60	39.39	0.53
7:00	35.13	34.47	1.88	19:00	32.65	33.63	2.99
8:00	33.48	33.69	0.63	20:00	37.28	38.04	2.04
9:00	34.02	34.93	2.67	21:00	35.02	35.92	2.58
10:00	34.82	36.21	3.99	22:00	32.65	31.90	2.30
11:00	37.34	37.70	0.96	23:00	30.68	30.50	0.59
12:00	31.59	32.71	3.53	0:00	26.72	25.92	2.99

4 预测结果与分析

为了能够体现负荷预测的季节特点, 本文以吉

林辽源地区 2006 年 4 月 1 日至 7 月 31 日负荷数据及气象数据为例, 在 PC 机上 (256 M 内存, 40 G

硬盘)用 VB6.0 进行编程与训练。并对 8 月 1 日至 7 日一周的负荷用 SVM、LSSVM 与本文算法分别进行 24 点预测。表 1 为预测负荷的 e_{MAPE} (平均相对误差), 大于 5% 误差的个数及最大相对误差比较结果。表 2 为本文算法对 2006 年 8 月 3 日星期四的 24 点负荷预测结果。

从表 1 可以看出稀疏化的 L-S(LSSVM 与 SMO 结合)算法要比常规支持向量机算法与常规最小二乘支持向量机算法具有更高的精确度。从表 2 清楚的看出, 采用稀疏化的 L-S 算法能有效提高短期负荷预测的精度。为了体现本文算法在速度方面的优越性, 用对 SVM、LSSVM、L-S 未稀疏化算法以及 L-S 的稀疏化算法对 60 个样本进行训练并做了训练时间上的比较, 结果见表 3。

表 3 训练时间对照表

Tab.3 Comparison of training time

	SVM 算法	LSSVM 算法	未稀疏化的 L-S 算法	稀疏化的 L-S 算法
支持向量个数	4	38	38	6
训练时间/ms	3600	1700	1220.39	1747.8

从表 3 可以看出由常规最小二乘算法计算出的支持向量数很多, 势必要影响计算的速度和准确性; 未稀疏化的 L-S 算法, 由于没有做稀疏化的循环处理, 所以在时间上会很快, 由于支持向量数很多, 所以预测准确性却不高。这也从另一个角度得出 L-S 算法的确可行的, 本文算法不但在预测精度上有所提高, 也大大降低了计算复杂度(减少支持向量数), 从而提高了计算速度和预测准确度。

5 结论

1) 本文提出的 LSSVM-SMO 结合算法, 应用改进的剪枝算法对解进行稀疏化处理, 结果表明该方法运行速度快, 精度高, 是一种很有价值的算法。

2) 应用 LSSVM-SMO 结合算法的电力系统短期负荷预测, 具有预测速度快、精度高特点。

在 SVM 与 LSSVM 具体应用过程中, 其核函数及其参数的选择对预测效果都有很大的影响。目前还

没有比较有效的方法来合理地选择这些参数, 本文大多根据经验来选取这些参数, 下一步应着重研究如何利用相关的寻优算法来合理地选择其参数。

参考文献

- [1] 周佃民, 管晓宏, 孙婕, 等. 基于神经网络的电力系统短期负荷预测研究[J]. 电网技术, 2002, 26(2): 10-13.
ZHOU Dian-min, GUAN Xiao-hong, SUN Jie, et al. Short term Electric Load Prediction Based on Artificial Neural Network[J]. Power System Technology, 2002, 26(2): 10-13.
- [2] Vapnik V N. The Nature of Statistical Learning Theory[M]. New York: Springer Verlag, 1995.
- [3] Suykens J A K, Van G T, De B J, et al. Least Squares Support Vector Machines [M]. World Scientific, 2002.
- [4] Platt J. Fast Training of Support Vector Using Sequential Minimal Optimization[A]. In: Advances in Kernel Methods- Support Vector Learning[C]. 1999. 185-208.
- [5] Suykens J A K, Lukas L, Vandewalle J. Sparse Least Squares Support Vector Machine Classifier[A]. In: European Symposium on Artificial Neural Networks[C]. Bruges Belgium: 2000. 37-42.
- [6] 张浩然, 韩正之. 回归支持向量机的改进序列最小优化学习算法[J]. 软件学报, 2003, 14(12): 2006-2013.
ZHANG Hao-ran, HAN Zheng-zhi. An Improved Sequential Mini-mal Optimization Learning Algorithm for Regression Support Vector Machine[J]. Journal of Software, 2003, 14(12): 2006-2013.
- [7] 王海峰, 胡德金. 最小二乘支持向量机的一种稀疏化算法[J]. 计算机工程与应用, 2005, 33(3): 68-70.
WANG Hai-feng, HU De-jin. A Pruning Algorithm Imposed to Sparseness Upon the Solution of LSSVM[J]. Computer Engineering and Application, 2005, 33(3): 68-70.

收稿日期: 2007-07-18; 修回日期: 2007-09-29

作者简介:

刘耀年(1951-), 男, 教授, 主要研究方向配电系统自动化和人工智能在电力系统中的应用; E-mail: liuyaonian@163.com

沈轶群(1982-), 女, 硕士研究生, 研究方向电力系统负荷预测;

姜成元(1982-), 男, 硕士研究生, 研究方向为电力系统及其自动化。

与时俱进 平台共享——《继电器》共享网络化期刊工作平台

为适应当前期刊发展的需要, 《继电器》杂志社于 2007 年成功进行了网站改版, 建立了集读者、作者、审稿专家和编辑于一体的网络化期刊工作平台。

本系统已于 2008 年 1 月份开始使用, 我们原则上不再受理电子邮件投稿, 所有稿件均需作者登录我们的网站 <http://www.dlhb.net> 注册, 取得用户名和设定密码后, 由“作者登录”处进入投稿, 并可由此随时查询稿件处理状态和处理意见; 审稿专家也凭编辑部提供的用户名和密码由“审稿登录”处进入在线审稿; 编辑的稿件处理工作全在网上进行, 在收到初稿、提交审稿意见时, 将通过电子邮件通知注册作者。

初始使用阶段, 可能有诸多不完善之处, 如有任何问题, 均可通过电话与本刊编辑部联系。电话: 0374-3212254, 3212234