

一种基于最小二乘支持向量机的年电力需求预测方法

王晓红¹, 吴德会^{1,2}

(1. 九江学院电子工程系, 江西 九江 332005; 2. 合肥工业大学仪器科学与光电工程学院, 安徽 合肥 230009)

摘要: 针对电力系统年用电量增长的特点, 将最小二乘支持向量机 LS-SVM (least squares support vector machine) 回归模型引入年电力需求预测领域, 并给出了相应的过程和算法。与常规基于人工神经网络 ANN (artificial neural networks) 的智能预测方法比较, 该模型优点是明显的: 1) 将神经网络迭代学习问题转化为直接求解多元线性方程; 2) 整个训练过程中有且仅有一个全局极值点, 确定了预测的稳定性; 3) 将年电力需求预测的外插回归问题转换为内插问题, 提高了预测精度。应用实例表明: 该模型实现容易、预测精度高, 更适合年电力需求预测。

关键词: 年电力需求; 最小二乘支持向量机 (LS-SVM); 回归; 预测

中图分类号: TM715 **文献标识码:** A **文章编号:** 1003-4897(2006)16-0074-05

0 引言

电力需求预测是保证电力产生质量的重要工作之一, 准确的需求预测, 可以经济合理地安排电网内部发电机组的启停, 保持电网运行的安全稳定, 减少不必要的储备容量, 合理安排机组检修计划, 确保社会的正常生产和生活。准确的负荷预测结果, 还有利于决定未来装机容量的大小、地点和时间, 决定电网的增容和改建, 决定电网的建设和发展。负荷预测工作的水平已成为衡量一个电力企业的管理是否走向现代化的显著标志之一^[1]。

传统的电力负荷预测方法有: 回归分析、时间序列、专家系统^[2]、灰色理论^[3]等, 但由于生活和生产用电系统是一个受到众多因素影响的复杂系统, 用常规的数学方法来建立模型, 不仅工作量大, 而且精度也难以保证。人工神经网络 ANN (Artificial Neural Network) 作为一种新兴的预测法被引入电力系统负荷预测领域并取得了一定的成果^[4]。ANN 具有较强的自学习、容错能力和解决非线性, 能处理噪声和不完全数据。但该方法也存在先天性不足: 计算量大, 易陷入局部极值点、所需数据量大、外插能力弱等^[5]。

支持向量机 SVM (Support Vector Machines) 基于结构风险最小化 SRM (Structural Risk Minimization) 准则, 其拓扑结构由支持向量决定, 克服了 ANN 结构依赖设计者经验的缺点, 较好解决了高维数、局部极小等 ANN 先天问题。SVM 较好地兼顾了神经网络和灰色模型的优点^[6,7]。最小二乘支持向量机 LS-SVM (Least Square SVM) 是标准 SVM 的

一种新扩展, 优化指标采用平方项, 并用等式约束代替标准支持向量机的不等式约束, 既将二次规划问题转化为线性方程组求解, 降低了计算复杂性, 加快了求解速度和抗干扰能力^[8,9]。

本文根据年用电量时间序列的实际分布特点, 建立了一种基于 LS-SVM 的适合年电力需求时间序列的预测的专用模型。在该模型中将年电力负荷预测的外插问题转换为内插问题以提高预测精度。最后, 结合实际年电力需求预测应用, 进行了预测精度和误差方面的比较分析, 进一步论证了本文所建模型在年电力需求预测中的适用性与合理性。

1 最小二乘回归估计模型的建立

1.1 标准 SVM 回归估计原理

设某一待回归的数据集为 $\{x_i, y_i\}$, ($i=1, 2, \dots, N$), $x_i \in R^n$ 为 n 维系统输入向量, $y_i \in R$ 为系统输出。SVM 回归的基本思想是^[6]: 通过非线性变换 (\cdot) 将 n 维输入的样本从原空间映射到高维特征空间 F , 并在此空间中构造最优线性回归函数

$$f(x) = \langle \Phi(x), w \rangle + b \quad (1)$$

标准 SVM 以 ϵ -不敏感损失函数作为风险最小化的估计问题, 因此可建立优化目标表示为:

$$\begin{aligned} \min & \frac{1}{2} \|w\|^2 + c \sum_{i=1}^N (\xi_i + \xi_i^*), \\ \text{s.t.} & \begin{cases} y_i - \langle \Phi(x_i), w \rangle - b \leq \xi_i \\ \langle \Phi(x_i), w \rangle + b - y_i \leq \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0, i = 1, \dots, N \end{cases} \end{aligned} \quad (2)$$

式中: c 被称为平衡因子, 通常取 $1, \xi_i, \xi_i^*$ 为引入训

训练集的误差,它们可表示样本点超出拟合精度的程度。

可以根据式 5 目标函数和约束条件建立 Lagrange 求解方程:

$$l(\alpha, b, \lambda, \mu) = \frac{1}{2} \alpha^T \alpha + c \sum_{i=1}^N (\lambda_i + \mu_i) - \sum_{i=1}^N \lambda_i (\alpha_i + \mu_i + y_i - \alpha^T (x_i) - b) - \sum_{i=1}^N \mu_i (\alpha_i + \mu_i + y_i - \alpha^T (x_i) - b) \quad (3)$$

式中:参数 $\lambda_i, \mu_i \geq 0, i=1, 2, \dots, N$ 。

分别对式 (3) 中的变量求偏导,并整理可得对偶优化问题,其中 $(\lambda_i - \mu_i) \geq 0$ 对应的 x_i 为支持向量;变量 α 反映了函数的复杂度,是映射函数 (\cdot) 的线性组合。因此, SVM 进行系统辨识的计算复杂度和输入空间的维数是无关的,它依赖于样本的数量。

引进核函数来代替非线性映射 (\cdot) ,即

$$(x_i, x_j) = (x_i)^T (x_j) \quad (4)$$

则优化问题式 (3) 可转化为其对偶问题求解:

$$\max_{\alpha} J = -\frac{1}{2} \sum_{i,j=1}^N (\lambda_i - \mu_i) (\lambda_j - \mu_j) (x_i, x_j) - \sum_{i=1}^N (\lambda_i + \mu_i) + \sum_{i=1}^N y_i (\lambda_i - \mu_i)$$

$$s.t. \begin{cases} \sum_{i=1}^N (\lambda_i - \mu_i) = 0, \\ \lambda_i, \mu_i \in [0, c] \end{cases} \quad (5)$$

解式 (5) 的二次规划问题,可求标准 SVM 回归模型:

$$y(x) = \sum_{i=1}^N (\lambda_i - \mu_i) (x_i, x) + b$$

$$b = \sum_{SV_s} (\lambda_i - \mu_i) [(x_j, x_i) + (x_k, x_i)] \quad (6)$$

式中: x_j, x_k 为两个任意支持向量。

1.2 LS-SVM 回归估计原理

LS-SVM 是标准 SVM 的一种扩展,它选择误差 α 的二范数为损失函数^[8],如此则优化问题变为:

$$\min \frac{1}{2} \alpha^T \alpha + \frac{1}{2} \sum_{i=1}^N \alpha_i^2$$

$$s.t. y_i = \alpha^T (x_i) + b + \alpha_i, i=1, 2, \dots, N \quad (7)$$

在这里,正实数 α 是调节常数,它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 α 值越大,模型的回归误差越小。LS-SVM 定义了与标准 SVM 不同的损失函数,并将其不等式约束改为等式约束,可在对偶空间

上求取 α 。引入 Lagrangian 函数:

$$L(\alpha, b, \lambda, \mu, a) = \frac{1}{2} \alpha^T \alpha + \sum_{i=1}^N \alpha_i^2 - \sum_{i=1}^N a_i [\alpha^T (x_i) + b + \alpha_i - y_i] \quad (8)$$

式中: $a_i (i=1, \dots, N)$ 是 Lagrangian 乘子。

最优的 α 和 b 可以通过 KKT 条件获得:

$$\frac{\partial L}{\partial \alpha} = 0, \frac{\partial L}{\partial b} = 0, \frac{\partial L}{\partial \lambda} = 0, \frac{\partial L}{\partial a} = 0 \quad (9)$$

进一步可得:

$$\begin{cases} \alpha = \sum_{i=1}^M a_i X_i, \sum_{i=1}^M a_i = 0, a_i = \lambda_i - \mu_i \\ \alpha^T X_j + b + \alpha_j - y_j = 0 \end{cases} \quad (10)$$

由上式消去 α 和 b , 优化问题转化为求解如下方程:

$$\begin{bmatrix} 0 & \alpha^T \\ \alpha & -1 \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (11)$$

其中: $y = [y_1, \dots, y_N]^T, \alpha = [1, \dots, 1]^T, a = [a_1, \dots, a_n]^T$, 为一个方阵,其第 i 行第 j 列元素为 $\alpha_{ij} = (x_i, x_j) = (x_i)^T (x_j)$ ((\cdot, \cdot) 是满足 Mercer 条件的对称函数^[6])。

求取参数 α 和 b 后, LS-SVM 回归模型即为:

$$y(x) = \sum_{i=1}^N a_i (x_i, x) + b \quad (12)$$

2 基于 LS-SVM 的年电力需求预测方法

2.1 模型训练样本集的构造

要利用 LS-SVM 模型对时间序列 z_t 进行预测,必先根据已有的时间序列数据建立训练样本集 $\{x_i, y_i\}, i=1, 2, \dots, N$ 。由于时间序列数据 z_t 是单维的,而 LS-SVM 回归算法的输入向量 $x_i \in R^n$,为此,我们建立了一个随时间滚动的数据区间,并保持该区间长度为 n 。在时间序列上从左向右移动该区间,则不断有新数据从区间右侧加入,同时区间内最左的数据相应地从定长区间移动出去,使得保持在区间内的数据始终为 n 个。由于这个定长的数据区间在时间轴上移动,因此本文将该区间称为时间窗^[10]。时间窗在时间轴上的移动如图 1 所示。

假设当前时间窗的位置为 i ,则采集到训练样本的输入向量 x_i 为区间内数据 $z_i \sim z_{i+n-1}$,样本输出 $y_i = z_{i+n}$,继续移动时间窗可生成下一训练样本 (x_{i+1}, y_{i+1}) 。如此,将时间窗从时间序列起始位置

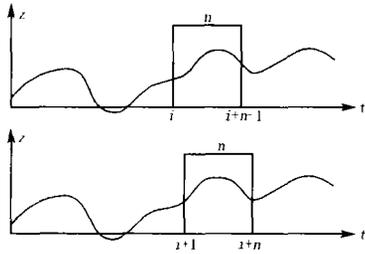


图 1 时间窗滚动示意图

Fig 1 Schematic diagram of the sliding time-window

向后移动直至序列最后一个元素,便可生成训练样本集。

2.2 基于 LS-SVM 电力需求预测模型

通过对各地区年用电量序列历史数据的对比研究,不难发现该数据分布明显有别于其它时间序列。由于近 30 年来我国经济的高速发展,各地区用电量均呈现单调递增分布。现有的智能预测方法大多是将历史数据作为训练样本,通过学习机拟合该样本集,发现其潜在规律并对未来数据进行预测。

然而,对于年电力预测的实际问题,由于现实中各地区用电量逐年递增,未来年份的电力需求值必然不会出现在历史数据中(大于历史数据)。因此,在对未来年份电力需求进行智能预测时几乎不可能从历史数据中找出相似样本,只能根据潜在规律进行外推,很明显这种预测属于“外插问题”。若能合理构造预测模型结构,将“外插问题”转换为“内插问题”,则可以有效提高预测精度。

根据年用电量数据的实际分布特点,我们建立了基于 LS-SVM 技术的年电力需求预测模型,图 2 给出了利用 LS-SVM 进行年电力需求预测的过程。

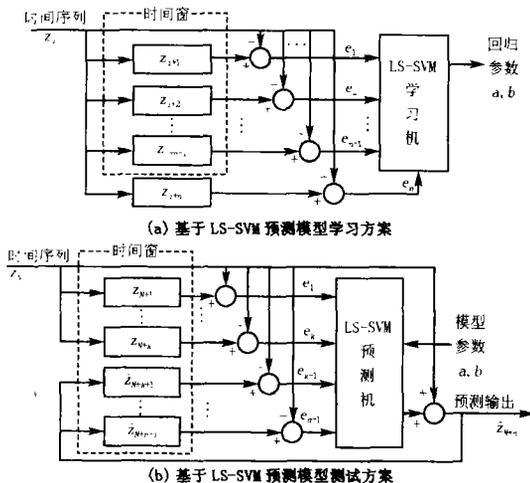


图 2 基于 LS-SVM 的年电力需求预测过程

Fig 2 Electric consumption prediction process of LS-SVM

从图 2(a)中不难发现,本文设计的时间序列预测模型并没有直接将时间窗中提取的数据输入 LS-SVM 学习机进行训练,而是进行了差分预处理。LS-SVM 学习机实际进行训练的样本输入向量 $x_i = \{e_1, e_2, \dots, e_{n-1}\}$, 输出向量 $y_i = e_n$, 其中差分量 e_j 可通过下式计算:

$$e_j = z_{i+j} - z_i \quad (13)$$

式中: z_i 为时间序列第 i 个数据, $j = 1, 2, \dots, n$, n 为时间窗长度。

通过式 (13)所示的预处理后,原始的年用电量历史数据被转换为差分数据 e_j , 其现实含义表达时间窗内 (n 年内)用电量的递增变化规律。虽然未来年份的电力需求值不可能出现在历史样本中,但其递增变化规律是可以在历史数据中找到相似样本,因此这种预测在本质上属于“内插问题”,因此能有效提高预测精度。

将由差分数据 e_j 构成的训练样本输入 LS-SVM 学习机进行训练,可求得回归参数 a, b 。对未来年份电力需求值进行预测时,将模型参数 a, b 输入 LS-SVM 预测机中;同时将时间窗移动到时间序列末端,提取窗内历史数据并差分预处理后构成输入向量 x_N , 输入到 LS-SVM 预测机可得到模型预测响应 \hat{y}_N , 其表示未来年份电力需求的增加量, $\hat{y}_N + z_N$ 为未来年份电力需求的预测值,即时间序列在 $N+n$ 位置上的预测值 \hat{z}_{N+n} 。若将该预测值 \hat{z}_{N+n} 看作时间序列 $N+n$ 位置上的真值,便可对时间序列在 $N+n+1$ 位置上的数据作下一步预测。利用 LS-SVM 模型进行预测的过程如图 2(b)所示。

3 模型实际应用算例

随着我国社会经济的快速发展,各省份乡村用电量的充分供给已成为促进乡村经济持续、健康发展的有效保障,因而对农村电力需求的精确预测也十分重要。影响用电量的因素有很多,但从较大范围内来看,由于影响用电量的这些随机因素的综合作用在一段时间内又相对稳定,用电量也相应保持在一定的稳定增长范围之内。

表 1 给出了我国某省 1987 ~ 2003 年乡村用电总量的历史数据,以 1987 ~ 2000 年实际用电量历史数据作为时间序列构造学习样本,对 2001 年 ~ 2003 年的数据进行预测。

该算例中 LS-SVM 模型时间窗长度 n 取 5, SVM 核函数的选取至今还没有彻底解决的方法,考虑到本文模型主要通过“内插”实现时间序列的预测功

能,因此本文取“内插”回归精度较高的 RBF径向基为核函数:

$$(x, y) = \exp\left\{-\frac{(x - y) \cdot (x - y)^T}{2}\right\} \quad (14)$$

式中:函数参数会影响训练样本回归精度,本文多次实验发现取值 50~200 之间对训练结果影响不大,本算例取 100。

表 1 某省 1987~2003 年农村用电量历史数据

Tab 1 Historical data of rural electric consumption in one province

		亿 kWh					
序号		1	2	3	4	5	6
年份		1987	1988	1989	1990	1991	1992
需求值		40.24	43.82	57.01	60.82	65.24	69.68
序号		7	8	9	10	11	12
年份		1993	1994	1995	1996	1997	1998
需求值		83.97	98.01	115.40	147.02	169.17	181.20
序号		13	14	15	16	17	
年份		1999	2000	2001	2002	2003	
需求值		190.12	200.91	219.76	255.27	285.25	

对 LS-SVM 预测模型测试时,我们先输入训练样本集检测模型的回归能力。由于这些样本在训练模型时已经使用,对于模型而言其输出已知,因此这部分测试其实质是“样本检验”,不是严格意义上的“预测”,其结果如图 3 中 1992 年~2000 年段。

用 1996~2000 年历史数据差分后构成输入向量,此时的模型输出即为 2001 年预测值;再用 1997~2000 年历史数据及 2001 年预测值构成下一输入向量,预测 2002 年电力需求;最后用 1998~2000 年实际值及 2000~2001 年预测数据推断 2003 年的电力需求量。

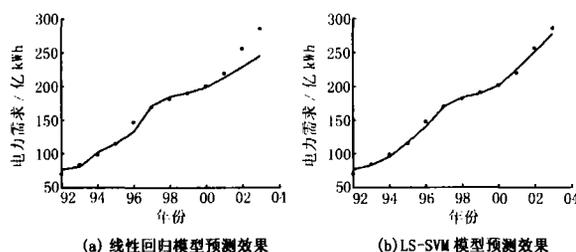


图 3 两种模型预测效果对比

Fig 3 Comparison between estimated outputs of two models

图 3 给出了用线性回归模型和 LS-SVM 模型预测的效果。图中,圆心点表示年用电量的实际值,实线表示模型输出,其中 1992~2000 年段为模型“回归检验”,2001~2003 年段为“预测值”。从图中不难看出,LS-SVM 预测模型的训练样本回归精度及预测准确度均明显优于线性模型。

再将 LS-SVM 模型与其它常见模型预测结果的

误差进行对比,见表 2。

表 2 多种预测方法结果对比 (2001~2003 年)

Tab 2 Comparison of forecasting result of several kinds of model

		亿 kWh		
年份		2001 年	2002 年	2003 年
实际值		219.76	255.27	285.25
GM(1,1) 预测值		245.06	277.23	313.63
预测 ^[11]	误差量	25.30	21.96	28.38
线性回归预测值		213.81	229.01	245.38
归预测	误差量	5.95	26.26	39.87
灰色马尔可夫预测 ^[12]	预测值	245.67	279.35	317.56
LS-SVM 预测值	误差量	25.91	24.08	32.31
预测	预测值	224.91	251.14	277.50
	误差量	5.15	4.13	7.75

由于本文设计的 LS-SVM 预测模型内含时间窗预处理环节,可将普通预测模型的“外插问题”转变为“内插”来解决。因此从上表四种预测方法中,本文方法预测误差最小。

4 结束语

本文根据年用电量历史数据的实际分布特点,对时间窗数据进行差分预处理,然后再对其建立基于最小二乘支持向量机的预测模型。由于实现了“内插”预测并充分利用了 LS-SVM 回归精度高、模型参数确定方便的优点,因此可得到较好的预测结果,实际的对比实验结果也表明该点。

最后必须指出的是,由于本文的 LS-SVM 预测模型结构是根据年用电量序列实际分布特点设计的,因此具有一定的针对性。若将其直接用于其它类型的时间序列预测效果不显著,但可依据本文思路,设计相对应类型的预处理结构以进一步提高预测精度。

参考文献:

- [1] 吕金虎,张锁春. 加权一阶局域法在电力系统短期负荷预测中的应用[J]. 控制理论与应用, 2002, 19(5): 767-700.
L ÜJin-hu, ZHANG Suo-chun. Application of Adding-weight One-rank Local-region Method in Electric Power System Short-term Load Forecast[J]. Control Theory and Applications, 2002, 19(5): 767-700.
- [2] Hung C Q, Batanov D N, Lefevre T. KBS and Macro-level Systems Support of Energy Demand Forecasting[J]. Computers in Industry, 1998: 87-95.
- [3] 王成山,杨军,张崇见. 灰色系统理论在城市年用电量预测中的应用——不同预测方法的分析比较[J]. 电网技术, 1999, 23(2): 15-18.

- WANG Cheng-shan, YANG Jun, ZHANG Chong-jian Application of Grey System Theory in City Electricity Demand Forecasting[J]. Power System Technology, 1999, 23(2): 15-18.
- [4] Metaxiotis K, Kagiannas A, Askounis A, et al Artificial Intelligence in Short Term Electric Load Forecasting: a State-of-the-art Survey for the Researcher [J]. Energy Conversion and Management, 2003, 44: 1525-1534.
- [5] 何飞, 张国忠, 刘亚. 基于 BP网络的改进负荷预测方法 [J]. 华东电力, 2004, 32(3): 31-33.
- HE Fei, ZHANG Guo-zhong, LU Ya Improved Load Forecasting Method Based on BP Network [J]. East China Electric Power, 2004, 32(3): 31-33.
- [6] Vapnik V N. The Nature of Statistical Learning Theory [M]. New York: Springer-Verlag, 1999.
- [7] Vapnik V N. An Overview of Statistical Learning Theory [J]. IEEE Trans on Neural Networks, 1999, 10(5): 988-999.
- [8] Suykens J A K, Vandewalle J. Least Squares Support Vector Machine Classifiers [J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [9] Suykens J A K, Vandewalle J. Sparse Least Squares Support Vector Machine Classifiers [A]. European Symposium on Artificial Neural Networks Bruges (Belgium): 2000. 37-42.
- [10] 白建社, 盛戈峰, 江秀臣, 等. 基于移动时间窗的直流局部放电特征提取方法 [J]. 电力系统自动化, 2005, (3): 55-59.
- BAI Jian-she, SHENG Ge-hao, JIANG Xiu-chen, et al Features Extraction Method of DC Partial Discharge Based on Mobile Time Window [J]. Automation of Electric Power Systems, 2005, (3): 55-59.
- [11] 鲍一丹, 吴燕萍, 何勇. 基于 GM(1,1)模型和线性回归的组合预测新方法 [J]. 系统工程理论与实践, 2004, (6): 95-98.
- BAO Yi-dan, WU Yan-ping, HE Yong A New Forecasting Model Based on the Combination of GM(1,1) Model and Linear Regression [J]. Systems Engineering-theory & Practice, 2004, (6): 95-98.
- [12] 董沛武, 李汉铃, 潘慧峰. 基于市盈率模型的风险投资企业价值评估方法研究 [J]. 系统工程理论与实践, 2002, (6): 121-125.
- DONG Pei-wu, LI Han-ling, PAN Hui-feng Research on Method of the Venture Capital in Enterprise Price Evaluation on P/E Model [J]. Systems Engineering-theory & Practice, 2002, (6): 121-125.

收稿日期: 2006-02-24; 修回日期: 2006-04-24

作者简介:

王晓红(1976-), 女, 讲师, 硕士研究生, 从事电力预测领域的研究; E-mail: wdh_hf_mail@163.com

吴德会(1975-), 男, 博士研究生, 长期从事智能控制、电气工程领域的研究。

Annual electric consumption forecasting model based on least square support vector machines

WANG Xiao-hong¹, WU De-hui^{1,2}

(1. Department of Electronic Engineering, Jiujiang University, Jiujiang 332005, China

2. School of Instrument Science and Opto-electronic Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: According to the speciality of electric power consumption development, an improved regression model based on the least squares support vector machine (LS-SVM) is introduced into the field of electric power demand forecasting. The design steps and learning algorithm are also addressed. Compared with forecasting methods based on artificial neural networks (ANN), there are some advantages of the proposed method. First, the LS-SVM solution follows directly from solving a set of linear equations instead of an iterative problem. Second, the machine learning in the standard ANN approach are replaced by linear equations in LS-SVM, so the global optimal solution can be uniquely obtained. Third, the forecasting precision can be enhanced due to the model converts extrapolation regression into interpolation regression. The application case proved that the proposed method is of easy realization, accurate prediction and fits for annual electric power demand forecasting.

Key words: annual electric power demand; least squares support vector machine (LS-SVM); regression; forecasting

(上接第 48 页 continued from page 48)

voltage, line energizing overvoltage, transformer energizing overvoltage and power flow. Finally, the pre-condition & PRO of the black start schemes for Guangzhou metropolitan power grid are listed.

This project is supported by National Natural Science Foundation of China (No. 50337010).

Key words: metropolitan power grid; black start; self-excitation; overvoltage; simulation