

最小二乘支持向量机的短期负荷多尺度预测模型

刘遵雄¹, 钟化兰², 张德运¹

(1. 西安交通大学电子与信息工程学院, 710049, 西安; 2. 华东交通大学电子与电气学院, 330013, 南昌)

摘要: 提出了一种改进的电力负荷短期预测小波网络模型, 该模型采用最小二乘支持向量机(LS-SVM) 实现了小波分解系数的多尺度组合预测. 首先使用多孔算法对短期负荷序列进行小波分解, 得到指定尺度下的近似系数和相关尺度下的小波系数, 然后利用 LS-SVM 对预测点的系数进行多尺度组合预测, 通过小波重构可以求得相应的预测值. 结合某地区短期负荷需求数据进行了仿真试验, 研究了预测点与历史记录数据的相关关系. 预测结果表明, 使用本模型进行短期负荷预测同比传统小波神经网络方法可以获得更好的预测精度, 同时 LS-SVM 的引入大大提高了模型的可计算性.

关键词: 短期负荷; 多尺度预测; 多孔算法; 最小二乘支持向量机

中图分类号: TM 715; TP 18 **文献标识码:** A **文章编号:** 0253-987X(2005)06-0620-04

Multi-Scale Short Term Load Prediction Model Using Least Square Support Vector Machine

Liu Zunxiong¹, Zhong Hualan², Zhang Deyun¹

(1. School of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. School of Electronics and Electric Engineering, East China Jiaotong University, Nanchang 330013, China)

Abstract: A revised wavelet network model for short-term electric load prediction was proposed by using LS-SVM (least square support vector machine) to achieve the combined prediction of wavelet decomposition coefficients, in which the wavelet decomposition of short-term load time series is performed by *à trous* algorithm firstly, the approximate coefficients at the specified scale and the wavelet coefficients at the related scales can be obtained, then LS-SVM is utilized to perform the multi-scale combined prediction for the coefficients of predicted points, the corresponding predicted value is yielded by the wavelet reconstruction. The simulation experiments are carried out with short-term load demand data from a local region, and the correlation between the predicted points and history data is explored. The results show that the predicted accuracy with the proposed model is better than that of traditional neural-network-wavelet approaches for short term load prediction.

Keywords: *short term electric load; multi-scale prediction; à trous; least square support vector machine*

准确有效的短期负荷预测是电力系统可靠、安全和经济运行的保证. 人工神经网络具有良好的非线性逼近能力和自适应自学习的功能, 在短期负荷预测上得到了广泛的应用^[1,2], 但是存在需要确定网络结构、要求的训练样本大、过学习和在非线形优化问题中的局部极小等问题. 基于小样本统计学习理论的支持向

量机(SVM)在小样本、非线性、高维问题及泛化能力方面表现突出, 而且具有成熟的理论基础, 它在形式上类似于多层前向网络, 可自动解决网络结构问题. 从 SVM 引申出的支持向量回归(SVR)已被广泛使用在时间序列预测领域, 并在电力负荷的中期预测中取得了较好的预测效果^[3].

小波分析是处理非平稳信号的有力工具,具有良好的时频局域化性质.与小波分析相结合神经网络(小波网络)也广泛地用于时间序列预测^[4],如水文数据预测^[5]、短期电力负荷预测^[6],但这些小波网络采用的是传统的人工神经网络技术,其预测精度存在神经网络固有的缺点,而且效率较低.本文提出了一种基于最小二乘支持向量机(LS-SVM)^[7]的多尺度预测模型,并在短期电力负荷预测中获得了较为理想的预测效果,且运算复杂度大大降低.

1 小波变换算法

小波变换^[8]就是用一合适的母小波 $\psi(t)$ 通过在时间轴上的位移、缩放和幅度的变化产生一系列的派生小波,用系列小波与要分析的信号进行时间轴上的平移比较,获得用以表征信号与小波相似程度的小波系数.

小波多分辨率分析的主要思想是:用不同的分辨率来逐级逼近待分析的函数 $f(t)$.利用多分辨率分析,可以将函数 $f(t)$ 投影到相互正交的函数空间中.尺度相同的小波函数或尺度函数构成了一个函数空间的基,而不同函数空间的基的尺度不同,不同的尺度则表征了不同的频率特性.通过不断地进行投影,可逐步得到原函数在其任意子空间中的分量,从而可以通过区分粗、细信号来分析信号,再利用滤波器组的思想方法可以方便地实现信号的分解.这里把信号分为近似部分和细节部分,近似部分是指信号中可以投影到大尺度(即尺度值较大)空间中的低频分量,而细节部分是指信号中与小尺度空间对应的高频分量.

小波变换通常分为连续小波变换和离散小波变换,而连续小波变换主要用于理论分析.因为短期负荷数据为离散的时间序列,所以在此采用离散小波变换(DWT)来分析短期负荷数据. DWT不具备平移不变性,在数据处理上一般采用冗余小波变换.时间序列的冗余小波变换,将在每个分解尺度上产生与时间序列同长度的小波系数(每一点都有对应的小波系数).多孔算法(A Trous)是使用最为广泛的冗余离散小波变换,本文将采用该算法.

定义 $Z(t)$ 和 $C_0(t)$ 为原始离散时间序列数据,则多孔算法对基于该数据的信号分解式为

$$C_i(t) = \sum_{l=-\infty}^{+\infty} h(l)C_{i-1}(t+2^l), t=1,2,\dots \quad (1)$$

式中: $h(l)$ 表示离散低通滤波器; $C_i(t)$ 是在分解尺

度 i 下的尺度系数(近似分量).各尺度下的细节信号 $W_i(t)$ 可通过尺度系数的差来表示,即

$$W_i(t) = C_{i-1}(t) - C_i(t) \quad (2)$$

而 $W_i(t), t=1,2,\dots$ 是分解尺度 i 下的小波系数(细节分量),则 $W_1(t), W_2(t), \dots, W_p(t)$ 和 $C_p(t)$ 就是分解尺度数为 p 情况下的离散小波变换.在式(1)中取 $C(n+k)=C(n-k)$ 可解决信号边沿问题.

使用小波分量 $\{W_1(t), W_2(t), \dots, W_p(t), C_p(t)\}$ 可方便地重构原时间序列信号,重构式为

$$Z(t) = C_p(t) + \sum_{i=1}^p W_i(t) \quad (3)$$

可见,多孔分解重构算法使用简单、快捷,但重要的是如何选定离散小波低通滤波器.

2 LS-SVM^[7]

在支持向量机求解过程中的凸优化问题需要通过二次规划来解决,二次规划需要计算和存储核函数矩阵,其大小与训练样本数的平方相关,属于计算密集型作业,内存占用量较大.利用LS-SVM可在一定程度上解决SVM的计算复杂性问题,即将SVM中的求解二次规划问题转化成求解一组线性关系式,从而演化成简单的矩阵逆运算.

LS-SVM回归使用二次惩罚函数,它将问题变成求解等式约束 $d_i = \mathbf{w}^T \boldsymbol{\varphi}(x_i) + b + e_i, i=1, \dots, N$ 下的最小化问题求解,即

$$\min_{\mathbf{w}, b, e} J_p(\mathbf{w}, e) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \frac{1}{2} \sum_{i=1}^N e_i^2 \quad (4)$$

其中,前项表示最小化模型VC维,后项表示最小化训练误差, C 是惩罚系数,表示模型函数的光滑度和最小经验误差的折中性.

相应的Lagrange函数式为

$$L(\mathbf{w}, b, e, \boldsymbol{\alpha}) = J_p(\mathbf{w}, e) - \sum_{i=1}^N \alpha_i \{ \mathbf{w}^T \boldsymbol{\varphi}(x_i) + b + e_i - d_i \} \quad (5)$$

式中: α_i 为Lagrange乘子.从而,可由

$$\left. \begin{aligned} \frac{\partial L}{\partial \mathbf{w}} &= 0, & \mathbf{w} &= \sum_{i=1}^N \alpha_i \boldsymbol{\varphi}(x_i) \\ \frac{\partial L}{\partial b} &= 0, & \sum_{i=1}^N \alpha_i &= 0 \\ \frac{\partial L}{\partial e_i} &= 0, & \alpha_i &= C e_i \\ \frac{\partial L}{\partial \alpha_i} &= 0, & \mathbf{w}^T \boldsymbol{\varphi}(x_i) + b + e_i - d_i &= 0 \\ & & i &= 1, \dots, N \end{aligned} \right\} \quad (6)$$

求解优化问题.式(6)的关系可以表示成线性关系

式,即

$$\begin{bmatrix} 0 & \mathbf{1} \\ \mathbf{1} & \mathbf{K} + \mathbf{C}^{-1}\mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{d} \end{bmatrix} \quad (7)$$

式中: $\mathbf{d} = [d_1, d_2, \dots, d_N]^T$; $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_N]^T$; $\mathbf{1} = [1, \dots, 1]^T$; $\mathbf{K}(x_i, x_j) = \mathbf{K}_{ij} = \boldsymbol{\varphi}(x_i)\boldsymbol{\varphi}(x_j)^T$. 这样, 回归问题可以通过最小二乘法求解, 所得回归函数为

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

LS-SVM 仅需要确定核函数的形状参数和惩罚系数 C , 而不需要选取不敏感损失函数的 ε 值, 这不仅简化了计算, 而且便于使用.

3 预测方法

使用小波 LS-SVM 方法进行短期电力负荷预测, 通常分为以下 3 个阶段.

(1) 对短期负荷序列数据进行小波多尺度分解, 得到一个近似系数序列和一组不同尺度下的小波系数序列.

(2) 将 t 时刻的小波分解序列系数组合作为 LS-SVM 的输入, $t+T$ (T 为预测步) 时刻的某个小波分解系数作为输出来建立不同的模型, 并使用 LS-SVM 预测 $t+T$ 时刻的各小波分解系数.

(3) 利用小波重构获得短期负荷 $t+T$ 点的预测值.

使用多孔算法可对短期负荷数据进行小波多尺度分解, 但首先必须选定离散小波低通滤波器 $h(l)$ 和分解级数 P . 这里 $h(l)$ 选用三阶 B 样条, 即


$$h(l) = \left(\frac{1}{16}, \frac{1}{4}, \frac{3}{8}, \frac{1}{4}, \frac{1}{16} \right) \quad (9)$$

分解级数 P 既不能太小又不能太大, 如果分解级数选择太小, 则不能有效地将原信号中具有不同频率特征的分量分离出来, 而分解级数过大, 则需要用较多的模型对分解后的各分量进行预测, 各个模型也会引入一定的误差, 从而加大了最终预测误差.

分解级数主要是根据小波分解的近似序列的平滑程度进行选取.

使用多孔算法分解, 得到近似系数序列和小波系数序列 $C_4(t)$ 、 $W_1(t)$ 、 $W_2(t)$ 、 $W_3(t)$ 和 $W_4(t)$, 其小波分解系数序列曲线见图 1, 图中数据已进行了归一化处理.

在求 $t+T$ 点负荷数据前, 必须使用 LS-SVM 求出 $t+T$ 点的近似系数和小波系数, 共 5 个量, 需要 5 次使用 LS-SVM, 各向量机的输入输出量见表 1.



(a) C_0 、 W_2 和 W_4 序列 (b) W_1 、 W_3 和 C_4 序列

图 1 短期负荷数据的 4 级多孔算法分解的系数序列

表 1 5 次使用 LS-SVM 的结果

LS-SVM	输入	输出
第 1 次使用	$W_1(t), W_2(t), W_3(t)$	$W_1(t+T)$
第 2 次使用	$W_2(t), W_3(t), W_4(t)$	$W_2(t+T)$
第 3 次使用	$W_3(t), W_4(t)$	$W_3(t+T)$
第 4 次使用	$W_4(t)$	$W_4(t+T)$
第 5 次使用	$C_4(t)$	$C_4(t+T)$

4 算例分析

本文使用的短期负荷数据为某地区在 1998 年 1 月中每半小时记录一次的日电力负荷数据序列, 共 1 488 个测点. 按时间顺序选用前 1 000 个测点的历史记录数据作为训练样本, 其后的 488 个测点作为预留测试样本. 试验中使用绝对百分误差(APE)

$$e_{APE}^k = 100\% \times \frac{L^k - \hat{L}^k}{L^k}, \quad k = 1, 2, \dots, N \quad (10)$$

和平均绝对百分误差(MAPE)

$$e_{MAPE} = \sum_{k=1}^N |e_{APE}^k| / N \quad (11)$$

来评价系统的性能. 其中, L^k 和 \hat{L}^k 分别表示在时刻 k 的负荷真实值和预测值, N 为测试点数.

利用表 1 的结果, 并取 $T=1$ 进行单步预测, 其中 5 次使用 LS-SVM 的核函数全部取高斯函数 $\mathbf{K}(x, x') = \exp(-\|x - x'\|^2) / \theta$, 参数 θ 通过经验选取, 相应的向量机分别为 0.6、0.8、0.8、0.8 和 2, 而对惩罚参数 C , 前 3 者取 5, 后 2 者取 10, 因为后 2 者的模型曲线相对平滑, 所以在该参数的选取上可以宽松些. 图 2 显示的是, 在测试样本集上单步预测的预测值和真实值, 以及测试集中不同记录点的

APE 值,图中的 APE 最大值为 7.031 4,达到了很好的预测精度。

误差也可以用试验误差的均值 μ 和方差 σ^2 来度量,同时使用 APE 的 90%分位点 η 表示误差分布的尾部行为,说明仅 10%的误差超过该值。在测试集上分别取 T 为 1、2、8 和 12 进行单步预测,求得 4 组试验预测误差的上述 3 个指标,结果见表 2。




图2 测试集单步预测值及绝对百分误差曲线

表2 测试集预测性能比较

	$T=1$	$T=2$	$T=8$	$T=12$
μ	0.014 9	0.029 1	0.058 9	0.069 3
σ^2	0.013 3	0.041 8	0.154 4	0.237 4
η	0.030 0	0.057 5	0.116 5	0.138 6

从表 2 可以看出,随着预测点与历史记录数据间距的增加,3 种误差指标呈递增的趋势,而 $T=1$ 时预测的性能效果更好,这说明预测值与最近的历史负荷值相关。 T 取其他值的预测结果可以作为电力调度时的参考。

用神经网络进行了单步预测试验(基于 Matlab 环境的仿真),并采用改进的后向传播(BP)算法。各网络使用 3 层结构,输入、输出见表 1。网络的隐层单元数分别为 6、6、5、5 和 4。BP 算法的学习率和动量因子都取 10^{-4} ,最大训练学习次数为 1 000,神经元的传递函数采用 Sigmoid 函数 $f(x) = 1/(1 + \exp(-x))$ 。将 BP 与 LS-SVM 进行了预测比较,二者的运行时间和 MAPE 指标见表 3。

我们发现,在小波网络模型中引入 LS-SVM,不仅提高了系统的预测精度,而且可以大大减少运行

时间,从而证实了本文模型的可行性和有效性。

表3 LS-SVM 和 BP 算法的预测比较

算法	运行时间/s	e_{MAPE}
LS-SVM	2.634	0.014 9
BP	18.420	0.044 2

5 结束语

本文采用小波 LS-SVM 组合模型进行电力负荷短期预测,利用了小波分析的多分辨率功能和 LS-SVM 的非线性逼近能力,提高了预测精度。

本模型作为一种小波网络,在引入了 LS-SVM 后可大大地提高模型的可计算性,减少了模型学习训练的时间。通过某地区短期电力负荷预测,验证了该模型的可用性。

参考文献:

- [1] Leek Y, Cha Y T, Park J H. Short-term load forecasting using an artificial neural network [J]. IEEE Transactions on Power Systems, 1992,7(1):124-132.
- [2] 张国忠. 应用神经网络预测电力负荷 [J]. 电力自动化设备,2002(5):20-21.
- [3] Chen B J, Lin C J. Load forecasting using support vector machines [EB/OL]. <http://www.csie.ntu.edu.tw/~cjlin/papers.html>,2004-01-04.
- [4] Aussen A, Murtagh F. Combining neural network forecasts on wavelet-transformed time series [J]. Connection Science, 1997,9(1):113-121.
- [5] 李贤彬,丁 晶,李后强. 基于子波变换序列的人工神经网络组合预测 [J]. 水利学报,1999 (2): 1-4.
- [6] Zhang Bailing, Dong Zhaoyang. Adaptive neural wavelet model for short term load forecasting [J]. Electric Power Systems Research, 2001, 59 (2): 121-129.
- [7] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers [J]. Neural Processing Letters, 1999,9(3):293-300.
- [8] 杨福生. 小波变换的工程分析与应用 [M]. 北京:科学出版社,1999.

(编辑 苗 凌)