

# 基于经验模式分解和最小二乘支持向量机的短期负荷预测

祝志慧, 孙云莲, 季宇

(武汉大学电气工程学院, 湖北 武汉 430072)

**摘要:** 电力负荷是具有一定的周期性和随机性的非平稳时间序列, 传统的预测方法是建立在负荷是平稳序列的前提下, 难以精确的预测。为了进行有效的预测, 提高预测精度, 提出将经验模式分解 EMD (Empirical Mode Decomposition) 和最小二乘支持向量机 LS-SVM (Least Square Support Vector Machine) 相结合对短期负荷进行预测。首先, 运用 EMD 将负荷序列自适应地分解成一系列不同尺度的本征模式分量 IMF (intrinsic mode function), 分解后的分量突出了原负荷的局部特征, 能更明显地看出原负荷序列的周期项、随机项和趋势项; 然后, 根据各个 IMF 的变化规律, 采用合适的核函数和超参数构造不同的 LS-SVM 进行预测, 最后对各分量的预测值进行相加得到最终的预测值。仿真试验表明, 此方法具有较高的精度和较强的推广能力。

**关键词:** 经验模式分解; 最小二乘支持向量机; 负荷预测

## Short-term load forecasting based on empirical mode decomposition and least square support vector machine

ZHU Zhi-hui, SUN Yun-lian, JI YU

(School of Electrical Engineering, Wuhan University, Wuhan 430072, China)

**Abstract:** The power load is inherently non-stationary time series so that it is difficult to construct the model of accurate forecast. In order to improve forecast precision, a hybrid forecasting method based on Empirical Mode Decomposition (EMD) and Least Square Support Vector Machine (LS-SVM) is presented in this paper. Firstly, the power load series is adaptively decomposed into a series of stationary intrinsic mode functions (IMF) in different scale space. The local features of original load series are prominent in the IMF so that it is more obvious to observe the cycle, random and trend parts of the original load sequence. Secondly, according to the change regulation of each IMF, the right parameter and kernel functions are chosen to build different LS-SVM respectively to forecast each IMF. Finally, these forecasting results of each IMF are combined to obtain final forecasting result. The simulation results show that the hybrid method has faster speed, higher precision and greater generalization ability than that of the single LS-SVM method and that of the BP neural network method, which proves that it is an effective method.

**Key words:** empirical mode decomposition; least square support vector machine; load forecasting

中图分类号: TM715

文献标识码: A

文章编号: 1003-4897(2007)08-0037-04

## 0 引言

短期负荷预测是能量管理系统 EMS 的一个重要组成部分, 现有的负荷预测方法主要有回归分析法<sup>[1]</sup>、时间序列法<sup>[2]</sup>、人工神经网络法<sup>[3~5]</sup>, 其中神经网络预测法由于具有强非线性映射能力, 在电力负荷预测中得到广泛的应用, 但是它存在着网络结构难以确定、容易陷入局部极小值、收敛速度慢等缺点。其次, 电力负荷具有一定的周期性和随机性, 它实质上是一种随机的非平稳时间序列。这些传统的预测方法都是在负荷序列是平稳信号的假设下建模的, 因此, 其建立的模型不能精确地预测非平稳

的负荷时间序列。文献[6, 7]提出将小波变换和神经网络相结合对负荷进行预测, 预测精度有所提高。但是小波变换的有效性取决于的小波基的选择, 不能保证信号的最优分解。经验模式分解 EMD (Empirical Mode Decomposition) 是一种处理非线性、非平稳信号的新方法, 该方法吸取了小波变换的多分辨的优势, 同时克服了小波变换中需要选取小波基的困难, 是一种自适应的小波分解方法。本文尝试将 EMD 和最小二乘支持向量机 LS-SVM (Least Square Support Vector Machine) 相结合, 对短期负荷进行预测。首先运用 EMD 将非平稳的负荷时间序列分解成具有不同特征尺度的本征模

式分量 IMF (Intrinsic Mode Function), 然后根据 IMF 的变化规律, 利用不同的 LS-SVM 建立不同的 IMF 分量预测模型。最后, 所有分量的预测值组合得到最终的预测值。实验仿真表明, 此方法具有较高的预测精度, 并且计算时间短。

## 1 原理

### 1.1 经验模式分解

经验模式分解 (EMD) 是 1998 年由 Hung<sup>[8]</sup> 提出的一种新的信号处理方法, 它通过对信号的“筛选”将信号分解成不同频率的 IMF 本征模式分量。具体的分解过程参考文献[9]。于是信号可以表达为:

$$x(t) = \sum_{i=1}^n c_i + r \quad (1)$$

式中:  $c_i$  为第  $i$  个 IMF,  $r$  为余项。因此, EMD 可以将信号  $x(t)$  分解成频率从大到小排列的  $n$  个平稳的 IMF 分量和一个趋势项之和。

### 1.2 最小二乘支持向量机原理

支持向量机<sup>[10,11]</sup>是一种全新的和强有力的分类和回归的工具。它建立在 VC (Vapnik-Chervonenks Dimension) 维理论和结构化风险最小原则基础上的, 具有学习速度快, 泛化性好的特点, 能够较好地解决小样本、非线性、高维数和局部极小点等实际问题, 被认为是神经网络的替代方法。标准的 SVM 算法是将一个实际问题转化为一个带不等式约束的二次凸规划问题, 而 LS-SVM<sup>[12]</sup>是将实际问题转化为求解一组线性方程组的问题, 简化了计算, 提高了收敛速度。其具体回归算法如下:

对于给定的训练数据集  $S = ((x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)) \in R^p \times R$ , 利用高维特征空间的线性函数:

$$f(x) = w^T \cdot \phi(x) + b \quad (2)$$

来拟合样本集, 其中,  $\phi(x)$  为从输入空间到高维特征空间的非线性映射,  $w$  为特征空间权系数向量,  $b$  为偏置。根据结构风险最小化原理, LS-SVM 法回归问题可以表示为如下约束优化问题:

$$\min \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^l e_i^2 \quad (3)$$

Subject to  $y_i = w^T \phi(x_i) + b + e_i, i=1, \dots, l$

为了求解上述优化问题, 需将约束优化问题变

为无约束优化问题。引入拉格朗日函数, 将式 (3) 的优化问题变换到对偶空间。

$$L = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^l e_i^2 - \sum_{i=1}^l \alpha_i [w^T \phi(x_i) + b + e_i - y_i] \quad (4)$$

式中:  $\alpha_i$  为拉格朗日乘子,  $\gamma$  为常数, 根据 KKT (Karush-Kuhn-Tucker) 条件, 得

$$\begin{cases} \frac{\partial L}{\partial w} = 0 \rightarrow w = \sum_{i=1}^l \alpha_i \phi(x_i) \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^l \alpha_i = 0 \\ \frac{\partial L}{\partial e_i} = 0 \rightarrow \alpha_i = \gamma e_i, i=1, \dots, l \\ \frac{\partial L}{\partial \alpha_i} = 0 \rightarrow w^T \phi(x_i) + b + e_i - y_i = 0, i=1, \dots, l \end{cases} \quad (5)$$

对于式 (5), 消去  $w$  和  $e_i$  可得到如下线性方程组:

$$\begin{bmatrix} 0 & e_l^T \\ e_l & Q + I/\gamma \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (6)$$

式中:  $e = [1, \dots, 1]^T$ ,  $a = [a_1, \dots, a_l]^T$ ,  $y = [y_1, \dots, y_l]^T$ ,  $Q = (Q_{ij})_{l \times l}$ ,  $Q_{ij} = \phi(x_i)^T \phi(x_j)$ 。根据 Mercer 条件定义核函数  $k(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ , 常用的核函数有①多项式核函数  $k(x, y) = ((x \cdot y) + 1)^d$ ; ②径向基 (RBF) 核函数  $k(x, y) = \exp(-\|x - y\|^2 / \sigma^2)$ ; ③ Sigmoid 核函数  $k(x, y) = \tanh(\gamma(x, y) + c)$ 。

利用最小二乘法求解式 (6) 表示的线性方程组, 从而解出  $a$  和  $b$ , 最后得到 LS-SVM 回归函数为:

$$f(x) = \sum_{i=1}^l \alpha_i k(x_i, x) + b \quad (7)$$

从式 (6) 中可以看出只有参数  $\gamma$  是待选的, 这比标准支持向量机法待选的参数少, 不再需要指定  $\epsilon$  的逼近精度。所以, LS-SVM 算法运行简单, 速度快, 精度高。

## 2 基于 EMD 与 LS-SVM 的混合负荷预测

由于电力负荷序列是具有周期性和随机性的非平稳序列, 它可以表示为周期分量、随机变化量与趋势分量之和。经验模式分解 (EMD) 对负荷序列进行平稳化的处理, 将负荷按其内在特性自适应地分解为若干个平稳的 IMF, 如图 1 利用 EMD 对某一周的负荷进行分解, 分解后的 IMF 突出了原负荷的局部特征, 能更明显地看出原负荷序列的周期项、随机项和趋势项, 对其进行分析能更清楚地把握负荷特性。在此基础上, 根据 IMF 变化特点分别选用合适

的 LS-SVM 算法建立不同的预测模型, 最后将预测结果相加得到最终预测结果。具体流程图如图 2 所示。

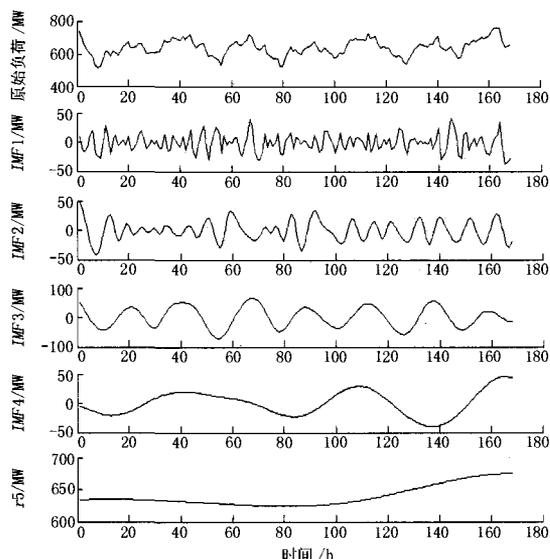


图 1 某周原始负荷及其 EMD 分量

Fig.1 One-week original load and its EMD decomposition components

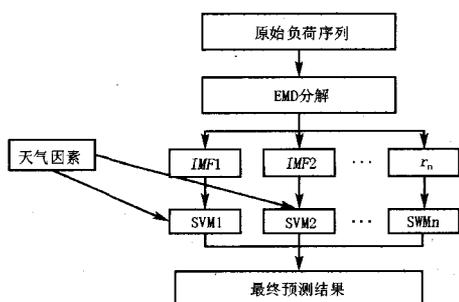


图 2 EMD 和 LS-SVM 混合预测模型

Fig.2 Hybrid forecasting model of EMD and LS-SVM

### 3 仿真试验

本文数据来源湖北省某电力公司, 利用 2005 年 1 月 1 日至 2 月 27 日, 5 月 1 日至 6 月 30 日整点有功负荷值, 气象特征和节假日类型作为学习样本, 预测 2 月 28 日 24 点的负荷值。预测误差采用平均绝对百分误差 (MAPE) 和相对误差 (Pe)。其中,  $r_i$  为实际负荷值,  $f_i$  为预测负荷值,  $N$  为预测值总个数。

$$MAPE = \frac{1}{N} \left[ \sum_{i=1}^N \left| \frac{r_i - f_i}{r_i} \right| \times 100\% \right]$$

$$Pe = \left| \frac{r_i - f_i}{r_i} \right| \times 100\%$$

从图 1 中可以看出, 分解后的分量表现出更强的规律性。IMF1 为负荷剧烈变化的高频分量, 数值

较小, 反映了负荷受随机因素的影响; IMF3 与原始负荷变化相似, 数值大, 以天为周期平缓地变化, 为基本日负荷周期分量; IMF2、IMF4 数值小, 呈现出一定的变化规律;  $r_5$  为趋势项。根据各分量的变化规律, 分别选用不同的核函数及参数建模, 再进行组合预测。由于目前核函数的选择还没有统一的方法, 进行 IMF1、IMF2、IMF3、IMF4 预测时, 核函数选用 RBF 函数  $k(x, y) = \exp(-\|x - y\|^2 / \sigma^2)$ , 其超参数分别为:  $\sigma = 0.283$ ,  $\gamma = 10$ ; 对于  $r_5$ , 选用多项式核函数  $k(x, y) = ((x \cdot y) + 1)^d$ , 其中  $d = 3$ ; 将各分量的预测值相加得到最终的预测结果如图 3 所示。

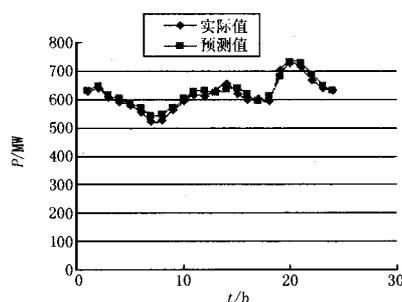


图 3 混合模型最终预测结果

Fig.3 The final forecasting result of hybrid model

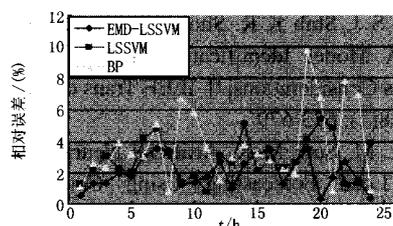


图 4 相对误差比较

Fig.4 Comparison of percent errors

为了验证此方法的有效性和可行性, 分别运用了 BP 神经网络和单独的 LS-SVM 进行预测, 其预测相对误差比较见图 4 以及平均绝对百分误差比较见表 1。

表 1 预测误差比较

Tab.1 Comparison of forecasting errors

预测方法	MAPE/(%)	最大相对误差/(%)
BP 神经网络	3.75	9.75
LS-SVM	2.89	5.3
EMD-LS-SVM	2.24	3.5

从图 4 中可以看出混合算法的相对误差变化平滑, 数值小; BP 法的相对误差波动较大, 数值大。表 1 中可以看出, 采用 EMD-LSSVM 组合预测效果最好, LS-SVM 效果次之, BP 神经网络最差。由此可知, 在小样本的情况下, 支持向量机的预测能力比神经

网络强, EMD-LSSVM 组合预测的能力最强。

这是因为 EMD 将非平稳的原始负荷序列分解为一系列平稳的具有一定规律的单一分量, 跟原始负荷序列相比, 这些分量更容易预测; 其次, 与传统的神经网络方法相比, 支持向量机不是以经验风险最小化为原则, 而是建立在结构风险最小化原理基础上, 通过调整常数, 使误差尽可能的小的同时, 使回归函数尽可能地平滑, 因此, 它具有更强的泛化能力。

#### 4 结论

电力负荷是一个非平稳信号, 运用 EMD 对其平稳化处理, 能得到一系列的不同频率的平稳分量, 这些分量更能准确地反映原负荷的特征信息。根据这些分量的变化规律建立不同的 LS-SVM 子模型, 最后通过对子模型预测结果进行相加得到最终预测结果。试验仿真结果表明, 此方法运算速度快, 精度高, 泛化能力强, 是一种行之有效的预测方法。

#### 参考文献

- [1] Moghram I, Rahman S. Analysis and Evaluation of Five Short-term Load Forecasting Techniques[J]. IEEE Trans Power Systems, 1989, 14 (4): 1484-1491
- [2] Huang S J, Shih K R. Short-term Load Forecasting Via ARMA Model Identification Including Non-Gaussian Process Considerations[J]. IEEE Trans on Power Systems, 2003, 18(2): 673-679.
- [3] Saini L M, Soni M K. Artificial Neural Network-based Peak Load Forecasting Using Conjugate Gradient Methods [J]. IEEE Trans on Power Systems, 2002, 12 (3): 907-912.
- [4] Hippert H S, Pedreira C E, Souza R C. Neural Networks for Short-term Load Forecasting: a Review and Evaluation [J]. IEEE Trans on Power Systems, 2001, 16(1): 44-55.
- [5] Kim K H, Youn H S, Kang Y C. Short-term Load Forecasting for Special Days in Anomalous Load Conditions Using Neural Networks and Fuzzy Inference Method [J]. IEEE Trans on Power Systems, 2000, 15(2): 559-565.
- [6] Rocha Reis A J, da Silva A P. Feature Extraction via Multiresolution Analysis for Short-term Load Forecasting[J]. IEEE Trans on Power Systems, 2005, 20(1): 189-198.
- [7] 杨延西, 刘丁. 基于小波变换和最小二乘支持向量机的短期电力负荷预测[J]. 电网技术, 2005, 29(13): 60-63.  
YANG Yan-xi, LIU Ding. Short-term Load Forecasting Based on Wavelet Transform and Least Square Support Vector Machines[J]. Power System Technology, 2005, 29(13): 60-63.
- [8] Huang N E, Shen Z, Long S R. The Empirical Mode Decomposition and The Hilbert Spectrum for Nonlinear and Non-stationary Time Series Analysis[J]. Proc R Soc London A, 1998, 454: 903-99.
- [9] 李天云, 赵妍, 李楠. 基于 EMD 的 Hilbert 变换应用于暂态信号分析[J]. 电力系统自动化, 2004, 29(4): 49-51.  
LI Tian-yu, ZHAO Yan, LI Nan. Apply Empirical Mode Decomposition Based Hilbert Transform to Power System Transient signal Analysis[J]. Automation of Electric Power Systems, 2004, 29(4): 49-51.
- [10] Vapnik V N. The Nature of Statistical Learning Theory [M]. New York: Springer Verlag, 1999.
- [11] Suykens J A K, Vande walle J. Least Squares Support Vector Machine Classifiers[J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [12] Vapnik V N, Golowich S E, Smola A J. Support Vector Method for Function Approximation, Regression Estimation and Signal Processing[J]. Adv Neural Information Processing Systems, 1996, 281-287.

收稿日期: 2006-07-26

作者简介:

祝志慧 (1975-), 女, 博士研究生, 主要研究方向为现代信号处理在电力系统中的应用; E-mail: zzhlsx@sohu.com

孙云莲 (1963-), 女, 教授, 博士生导师, 主要从事信号处理研究。

Planning[M]. Beijing: China Electric Power Press, 2003.

收稿日期: 2006-07-02; 修回日期: 2007-03-14

作者简介:

苏慧玲 (1983-), 女, 硕士研究生, 从事电力系统规划与可靠性方面的研究; E-mail: suhuil@163.com

王淳 (1963-), 男, 博士, 副教授, 从事电力系统规划、可靠性与电力市场方面的研究。

(上接第 30 页 continued from page 30)

- [8] 雷秀仁, 任震, 等. 电力系统可靠性评估的不确定性数学模型探讨[J]. 电力自动化设备, 2005, 25(11): 1-4.  
LEI Xiu-ren, REN Zhen, et al. Study on Uncertainty Math Models of Power System Reliability Evaluation[J]. Electric Power Automation Equipment, 2005, 25(11): 1-4.
- [9] 王锡凡. 电力系统规划基础[M]. 北京: 中国电力出版社, 2003.  
WANG Xi-fan. The Basis Knowledge of Power System