

基于 HHT 和神经网络组合的负荷预测模型研究

白玮莉, 刘志刚, 彭权威, 谢建

(西南交通大学电气工程学院, 四川 成都 610031)

摘要: 首次提出了一种基于 HHT 和神经网络组合的预测模型。负荷数据首先经过 EMD 分解, 得到一系列 IMF 分量及余项, 通过各分量的频谱观察, 针对低频 IMF 分量规律性及周期性, 高频分量相对较弱的特性, 对低频 IMF 分量选择合适的预测模型直接进行预测, 高频 IMF 采用多神经网络组合预测方法。仿真结果表明, 文中提出的预测模型的精度高于任一单一模型, 并且高于传统的线性组合预测模型。

关键词: HHT; 频谱; 神经网络组合预测模型; 单一模型; 线性组合预测

Research of the load forecasting model based on HHT and combination of ANN

BAI Wei-li, LIU Zhi-gang, PENG Quan-wei, XIE Jian

(School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: A new forecasting model based on HHT and combination of ANN is proposed in the paper. Load data is decomposed into several IMF components and remainder by EMD firstly. Through calculating the spectrum of decomposed series, we can choose one appropriate forecasting model for each low frequency component, while use combination of ANN model for the high frequent component, according to the low frequency components having stronger regularity and periodicity than high frequency components. Simulation results indicate that accuracy of the forecasting model discussed in the paper is higher than any one sole model and the traditional linear combination forecast model.

Key words: HHT; spectrum; combination of ANN model; one sole model; linear combination forecast model

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2009)19-0031-05

0 引言

电力系统负荷序列既具有波动性又具有特殊的周期性, 可看作多个不同频率分量的叠加。每个分量呈近似周期性变化, 具有相似的频率特性和一致的变化规律, 从而具有更强的可预测性。因此, 在对负荷进行频域分解的基础上, 根据各频率分量特点进行建模是提高预测精度的有效途径。文献[1~3]均采用 EMD 方法对负荷数据进行分解, 然后分别对各分量和余项采用同一种预测模型进行预测, 最后将这些预测分量加起来作为最终的预测结果, 它们利用 EMD 的优点成功地提高预测精度, 但没有考虑每个分量的特点及预测方法的适应性, 具有一定的不合理性。文献[4]将 EMD 分解后的子序列重构成三

个分量, 用三种不同的预测方法进行预测, 这与利用 EMD 分解提高预测精度的初衷自相矛盾。另外经本人进行大量的实际数据测试发现, 利用 EMD 进行预测的误差主要来源于高频分量, 减小预测误差关键在于提高对高频分量的预测精度。本文提出基于 HHT 和神经网络组合的电力系统负荷预测模型, 该模型首先将负荷数据进行 EMD 分解, 得到一系列 IMF 分量及余项, 通过各分量的频谱观察, 针对低频 IMF 分量规律性及周期性, 高频分量相对较弱的特性, 对低频 IMF 分量选择合适的预测模型直接进行预测, 高频 IMF 采用神经网络组合预测方法。通过实际数据检验, 此方法有较高的预测精度。

1 HHT 算法简介

HHT (Hilbert-Huang Transform)^[5] 是全新的信号处理方法, 它由经验模态分解法 EMD 及 Hilbert 变换两部分组成。EMD 是美国 N.E. Huang 提出的信号分解算法, 此算法的目的是把复杂信号分解为简

基金项目: 2008 教育部新世纪优秀人才支持项目; 教育部霍英东青年教师基金资助项目 (101060); 四川省杰出青年基金项目 (07JQ0075)

单的单分量信号的组合,即将性能不好的信号分解为一组性能较好的具有瞬时频率的固有模态函数(IMF)和具有单调性或一个极值点的余项 Rn 。该方法分解过程基于数据信号局部特征,不需要预先设定参数,是自适应的。分解得到的IMF分量都是平稳的,包含原始信号的局部特征信息,尤其适用于非线性和非平稳性数据。HHT具有如下特点:IMF概念的提出使得用HT定义的瞬时频率具有实际的物理意义,可用于复杂的非平稳信号的分析;瞬时频率的定义方法与频率的经典定义方法(信号相位的导数)相一致,从而可以给出信号频率变化的精确表达,而且该法简单、通用。近几年该法已经被应用于地球物理学、生物医学、工学等领域的研究,并取得了较好的效果。

2 本文提出的模型原理和方法

电力负荷可表示为周期分量、随机变化量与趋势分量之和。EMD对负荷序列有平稳化的作用能将负荷按其内在特性自适应地分解为若干个不同频率平稳的IMF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地周期项、随机项和趋势项,对其进行分析能更清楚的把握负荷特性。在此基础上,根据IMF变化特点分别建立不同的预测模型,最后将预测结果相加得到最终预测值。

本文提出的预测方法步骤如下:

(1)数据预处理——利用小波对预测数据进行去噪处理;

(2)应用HHT算法——通过EMD对负荷数据进行分解,得到若干个频率由高到低的IMF分量和余项;

(3)提取规律——对各个IMF分量通过Hilbert求频谱,通过观察其瞬时频率值、频带宽度、频率波动情况掌握其规律;

(4)低频分量处理——将频率值较低、频率变化范围较窄的IMF分量和余项定位低频分量,对它的预测较简单,选择一种合适的预测方法既可;

(5)高频分量处理——将频率值较高、频率变化波动性较大、频带宽的分量定为高频分量。它除了包含高频的周期信息外,绝大部分为负荷数据中的随机变化量,对于这些分量采用单一的预测方法往往效果不佳,本文采用神经网络组合模型的预测方法;

(6)预测结果综合——将各个IMF预测值相加得到最终的预测结果。

2.1 数据预处理

负荷数据的采集过程是经过人工或设备的传

输,这就不可避免会存在误差和噪声,所以在进行数据分析预测之前需要对数据进行消噪处理。文献[6]提出利用小波包对信号分解重构,去除噪声干扰信号,该方法减少噪声对EMD分解的干扰,从而减少由于分解无用的噪声信号引入的边界效应误差和分解层数提高EMD分解的准确性和时效性,使EMD算法在信号的分析中更具实用性。本文采用此种方法对负荷数据进行去噪处理。

2.2 应用HHT算法

首先对去噪后的负荷数据做EMD分解,得到一组IMF分量及余项,对各IMF求频谱的过程如下:

对每个IMF分量 $c_i(t)$ 作希尔伯特变换可得数据序列 $\hat{c}_i(t)$

$$\hat{c}_i(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{c_i(\tau)}{t-\tau} d\tau \quad (1)$$

由 $c_i(t)$ 和 $\hat{c}_i(t)$ 可以构成一个复序列 $z_i(t)$

$$z_i(t) = c_i(t) + j\hat{c}_i(t) = a_i(t)e^{j\phi_i(t)} \quad (2)$$

其中幅值函数和相位函数

$$a_i(t) = \sqrt{c_i^2(t) + \hat{c}_i^2(t)} \quad (3)$$

$$\phi_i(t) = \arctan \frac{\hat{c}_i(t)}{c_i(t)} \quad (4)$$

从而得到瞬时频率为

$$f_i(t) = \frac{1}{2\pi} \frac{d\phi_i(t)}{dt} = \frac{1}{2\pi} w_i(t) \quad (5)$$

由此可看出各负荷分量的频率分布和变化范围,通过它选取合适的负荷预测模型。

3 预测模型

(1) 神经网络模型

在负荷预测的研究中,BP是应用最多的神经网络模型,它结构简单,具有很强的非线性拟合能力。然而,由于BP网络过分强调克服学习错误而泛化性能不强。这使得它对比较平稳的信号预测效果十分理想,但对于高频宽频波动性和随机性比较大的信号预测不是十分准确。RBF网络能够将输入层到隐含层的非线性映射转变成另一个空间上的线性映射,在某些复杂情况下拟合能力没有BP强,但学习速度快并可以避免局部最优。

(2) 支持向量机SVM模型

支持向量机SVM的机器学习算法,实现了结构风险最小化原理(SRM),找到经验风险最小和推广能力最大的平衡点,对未来样本有较好的泛化性能。较好地解决了小样本、非线性、高维数和局部极小

点等实际问题。

(3) 组合模型

将多种不同的预测方法进行适当组合, 综合利用各种方法提供的信息, 便形成了所谓的组合预测方法。组合预测模型将各种预测结果进行总体性综合考虑, 比单个模型更系统、更全面, 且Bates和Granger证明了2种或2种以上无偏的单项预测可以组合出优于每个单项的预测结果, 能有效地提高预测精度^[7]。

传统的线性组合预测模型, 基本思想是认为实际值和几种网络的预测值成一种线性的关系, 通过数学方法可以求出各自的权重系数。但事实上实际值和它们之间未必是一种线性关系, 因此本文提出了一种基于神经网络的组合预测模型, 利用神经网络的非线性拟合能力, 考虑将几种网络得到的预测值作为神经网络的输入, 将实际值作为输出, 训练出一个新的网络。预测结果表明, 本文给出的模型预测精度高于传统的线性组合预测模型。

设 f_{1i}, f_{2i}, f_{3i} 分别是三种预测模型的第 i 次预测结果, 而 f_i 是第 i 次的实际负荷值, 我们如果认为它们之间是较复杂的非线性关系, 考虑如下式子:

$$\sum_{i=1}^m [f_i - g(f_{1i}, f_{2i}, f_{3i})]^2 \quad (6)$$

其中: m 为样本个数, 为了使得式(7)取得最小值, 就是要求出非线性函数 $g(\cdot)$, 而传统的梯度法或遗传算法都不能正确的求解。

Hornik 等人的研究表明前向三层神经网络能实现复杂的非线性映射, 其不仅能以任意精度逼近任意连续函数, 还能以任意精度逼近其各阶导数, 所以本文考虑选择三层前向神经网络逼近上述非线性映射 $g(\cdot)$ 。本文采用的是 BP 神经网络, 将各种神经网络的预测值作为 BP 的输入, 实际值作为输出来训练网络, 它的结构图如图 1 所示。

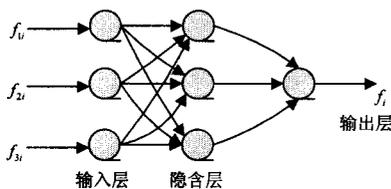


图1 组合预测的神经网络结构图

Fig.1 Structure of ANN for combined forecasting

4 数据仿真

本文选取四川某电网 2006 年 7 月 5 日~8 月 7

日电网负荷数据来预测 8 月 8 日号一天 24 小时的负荷数据。经去噪后通过 EMD 分解为 7 个 IMF 分量和一个余项 r , 如图 2、图 3 为通过 Hilbert 方法求得频谱。

设负荷实际值为 $R(i)$, 预测值为 $Y(i)$

则每点相差值:

$$d_i = R(i) - Y(i) \quad (7)$$

相对预测误差:

$$e_i = [|R(i) - Y(i)| / R(i)] \times 100\% \quad (8)$$

平均误差:

$$ee = \frac{1}{24} \sum_{i=1}^{24} e_i \quad (9)$$

由图 3 可看出分量 $IMF1$ 和 $IMF2$ 的瞬时频率较高, 频带较宽, 突变较大, $IMF3 \sim IMF7$ 瞬时频率较低, 频带窄, 基本平稳。经过实际数据测试, 对 $IMF3 \sim IMF7$ 直接采用一种预测模型就能达到比较高的预测效果, 而对 $IMF1$ 和 $IMF2$ 单单使用任何一种模型效果都很差。所以本文提出对 $IMF1$ 和 $IMF2$ 采用组合预测方法, 并在模型中考虑温度因素的影响。分别对上述提到的两种组合预测方法进行实验, 将结果进行了对比。本文规定 C1 代表线性组合预测的结果, C2 代表神经网络组合预测的结果。C1 中的权重系数由文献[7]中的公式求出。

对于 $IMF1$ 和 $IMF2$ 本文采用 BP、SVM、RBF 三种模型进行组合, 各种模型、C1、C2 的预测结果与实际负荷曲线图如下, C2 采用 BP 3-8-1 结构。

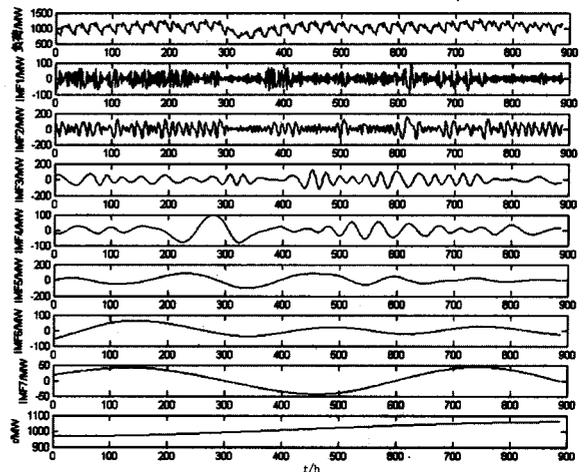


图2 原始负荷及 EMD 分量

Fig.2 Original load data and decomposed component of EMD

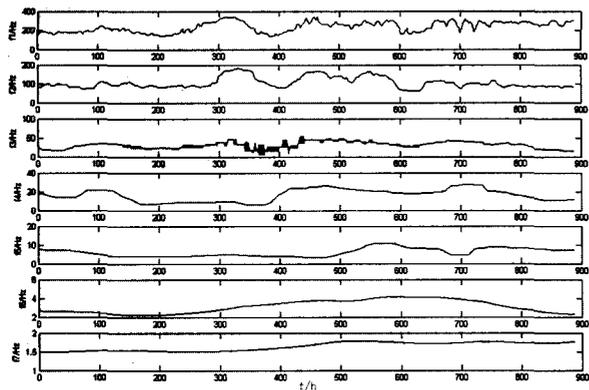


图3 各IMF分量频谱
Fig.3 Spectrum of each IMF

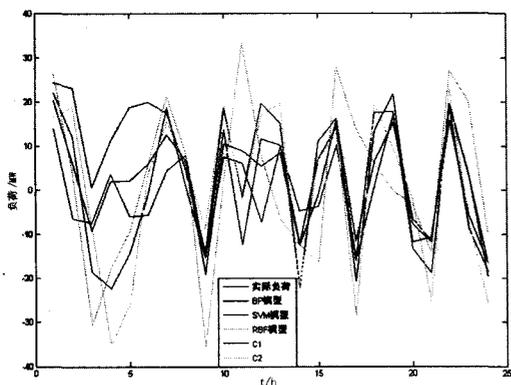


图4 IMF1 各模型预测曲线
Fig.4 Each model forecasting curve of IMF1

表1 IMF1 各种模型相差值比较

Tab.1 Comparison of each model forecasting of IMF1

相差/MW	BP	SVM	RBF	C1	C2
最大相差	25.521 9	20.822 5	35.762 2	24.316 2	12.749 8
平均相差	8.399 5	7.736 3	9.759 5	6.999 8	5.787 9

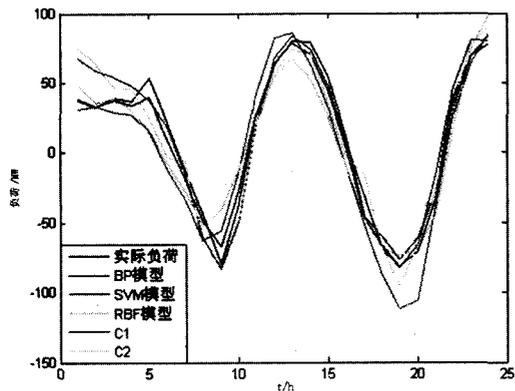


图5 IMF2 各模型预测曲线
Fig.5 Each model forecasting curve of IMF2

表2 IMF2 各种模型相差值比较

Tab.2 Comparison of each model forecasting of IMF2

相差/MW	BP	SVM	RBF	C1	C2
最大相差	25.537 0	22.518 1	28.265 1	15.805 8	12.023 2
平均相差	15.524 6	11.139 9	14.195 3	8.291 4	5.900 7

从表1和表2可看出,组合模型的预测精度比单一的预测模型高。

对于IMF3~IMF6本文根据其波形和频率特性分别选择合适的预测模型,分别选择对IMF3~4,5~6,7~9采用SVM、BP、线性神经网络。

表3列出了经两种组合预测模型的误差,从表3中可看出神经组合预测方法优于线性组合预测。

表3 预测结果误差比较

Tab.3 Comparison of forecasting results error

时刻	实际负荷/MW	C1 /MW	e1 / (%)	C2 /MW	e2 / (%)
0:00	1190.2	1155.4	2.92	1192.3	0.18
1:00	1145.8	1102.9	3.74	1157.8	1.05
2:00	1086.2	1049	3.42	1086.8	0.06
3:00	1052.8	1019	3.21	1035.1	1.69
4:00	1029.7	1036.9	0.7	1002.3	2.66
5:00	1006.6	999.6	0.69	982.9	2.35
6:00	980.4	962.2	1.86	978.0	0.24
7:00	909.9	917	0.78	898.4	1.26
8:00	871.6	868.5	0.34	867.4	0.48
9:00	940.9	943.5	0.27	933.7	0.76
10:00	996.1	1011.2	1.51	991.7	0.44
11:00	1087.8	1064.9	2.11	1070.3	1.62
12:00	1122.6	1106	1.48	1113.4	0.82
13:00	1112.1	1104.7	0.66	1094.3	1.61
14:00	1125.8	1116.4	0.83	1114.4	1.01
15:00	1114.9	1118.9	0.36	1109	0.53
16:00	1063.4	1067.4	0.20	1076.4	1.22
17:00	1073.8	1082.3	0.80	1092.8	1.77
18:00	1068.7	1089.6	1.95	1069.8	0.10
19:00	1057.3	1086.3	2.75	1078.1	2.58
20:00	1098.1	1114.6	1.50	1111.8	1.25
21:00	1190.9	1206.8	1.33	1216.6	2.16
22:00	1186.7	1223.6	3.11	1204	2.14
23:00	1163	1199.5	3.0	1186.8	2.17
最大误差			3.74		2.66
平均误差			1.78		1.25

5 结论

本文提出基于HHT和神经网络组合的电力系统短期负荷预测模型,该方法简单,无需考虑复杂的数学模型。负荷数据通过EMD的分解后,对各分量频谱的观察,可将IMF分为高频和低频两类,据实际仿真数据表明,针对它们各自的频率、带宽特性,采用不同的预测方法对这两类数据进行预测可提高预测精度。对低频分量直接选择单一的合适

的模型即可, 对于高频分量采用组合模型比较好, 本文做了关于传统线性组合模型和神经网络组合模型的对比研究, 结果表明神经网络组合模型优于线性组合模型。本文提出的该模型有效改善了高频分量的预测效果, 从而提高了整体预测精度。

参考文献

- [1] ZHU Zhi-hui, SUN Yun-lian, LI Huang-qiang. Hybrid of EMD and SVMs for Short-Term Load Forecasting[A]. in: IEEE International Conference on Control and Automation[C]. 2007.1044-1047.
- [2] 王洪波, 朱启兵. 基于 EMD 和 LS-SVM 的非平稳振动信号趋势预测[J]. 计算机工程与应用, 2008,44(16): 157-159.
WANG Hong-bo, ZHU Qi-bing. Trend Prediction of Non-stationary Vibration Signals based on Empirical Mode Decomposition and Least Square Support Vector Machin[J]. Computer Engineering and Applications 2008,44(16): 157-159.
- [3] 谢景新, 程春田. 基于经验模式分解与混沌分析的直接多步预测模型[J]. 自动化学报, 2008,34(6): 684-689.
XIE Jing-xin, CHENG Chun-tian. A New Direct Multi-step Ahead Prediction Model Based on EMD and Chaos Analysis[J]. Journal of Automation, 2008,34(6): 684-689.
- [4] 李媛媛, 牛东晓, 乞建勋, 等. 基于因散经验模式分解的电力负荷混合预测方法[J]. 电网技术, 2008,32(8): 58-62.
LI Yuan-yuan, NIU Dong-xiao, QI Jian-xun, et al. A Novel Hybrid Power Load Forecasting Method Based on Ensemble Empirical Mode Decomposition[J]. Power System Technology, 2008,32(8):58-62.
- [5] 胡国胜, 陈一天. 基于 HHT 变换的电机故障信号频率分析[J]. 电力学报, 2005,20(4): 327-330.
HU Guo-sheng, CHEN Yi-tian. The Study of Motor

Fault Signal Frequency Based on Hilbert-Huang Transform [J]. Journal of Electric Power, 2005,20(4): 327-330

- [6] 徐仁林, 安伟. 小波降噪在信号基于 EMD 的 Hilbert 变换中的应用[J]. 噪声与振动控制, 2008,6(3): 74-77.
XU Ren-lin, AN Wei. Wavelet Denoise Application in the Signal Hilbert Transform Based on EMD[J]. Control of Noise and Vibration, 2008,6(3): 74-77.
- [7] 李林川, 吕东, 武文杰. 一种简化的电力系统负荷线性组合预测法 [J]. 电网技术, 2002,26 (10): 10-13.
LI Lin-chuan, Lü Dong, WU Wen-jie. A Linear Combination Based Simplified Load Forecasting Method for Power System[J]. Power System Technology, 2002,26(10): 10-13.
- [8] AlFuhaid A S. Cased Artificial Neural Networks For Short-Term Load Forecasting[J]. IEEE Trans on Power Systems, 1997, 12(4): 1524-1529.
- [9] Kwang-Ho. Short-Term Load Forecasting for Special Days in Anomalous Load Conditions Using Neural Networks and Fuzzy Inference Method[M]. IEEE Trans on Power Systems, 2000,15 (2): 559-565.
- [10] Bashir Z, El-Hawary M E. Short Term Load Forecasting by Using Wavelet Neural Networks [A]. in: Canadian Conference on Electrical and Computer Engineering[C]. Halifax(Canada): 2000, 163-166.

收稿日期: 2008-10-23; 修回日期: 2009-03-16
作者简介:

白玮莉(1986-), 女, 硕士研究生, 主要研究方向为 HHT 及其在电力系统中的应用; E-mail: bwl1986@163.com

刘志刚(1975-), 男, 博士, 教授, 博士生导师, 主要研究方向为现代信号处理及其在电力系统中的应用;

彭权威(1982-), 男, 硕士研究生, 主要研究方向为列车网络技术。

(上接第 21 页 continued from page 21)

是中压配网规划而言, 至今没有一套完善的、定量的评价体系, 需要我们归纳、提炼更恰当的评价指标组成评价体系, 这方面需要做进一步深入探讨。

参考文献

- [1] 郭永基. 电力系统可靠性分析[M]. 北京: 清华大学出版社, 2003.
- [2] 陈立新. 电力工程技术经济知识[M]. 北京: 中国电力出版社, 1999.
- [3] 孙宏斌, 张伯明, 相年德. 配电潮流前推回推法的收敛性研究[J]. 中国电机工程学报, 1999, 19(7): 27-30.
SUN Hong-bin, ZHANG Bo-ming, XIANG Nian-de. Study Convergence of Back/forward Sweep Distribution Power Flow[J]. Proceedings of the CSEE, 1999,19(7):27-30.

[4] 王平洋, 胡兆光. 模糊数学在电力系统中的应用[M]. 北京: 中国电力出版社, 1999.

[5] 上海电网若干技术原则的规定[Z]. 上海: 上海市电力公司, 2004.

[6] 城市电力网规划设计导则. 能源电[1993]288 号 [Z]. 199317-18.

[7] 上海市电力公司供电分公司创一流同业对标 2004 年度指标评价报告[R]. 上海: 上海电力公司, 2005.

收稿日期: 2008-10-20; 修回日期: 2009-04-24
作者简介:

潘锋(1979-), 男, 硕士研究生, 工程师, 专业方向为高中压配电网规划; E-mail: bolza@tom.com

周敏(1973-), 男, 总工程师, 硕士研究生, 高级工程师, 从事配电网运行及规划管理工作。