

基于经验模式分解与人工神经网络的短期电力负荷预测

郑连清, 郑艳秋

(重庆大学输配电装备及系统安全与新技术国家重点实验室, 重庆 400044)

摘要: 为了有效预测具有一定周期性和随机性的非平稳时间序列的电力负荷, 提高预测精度, 提出了一种基于经验模式分解(EMD)和人工神经网络(ANN)的电力短期负荷预测方法。该法利用 EMD 的自适应性, 自动地将目标负荷序列分解为若干个独立的内在模式分量(IMF), 对各分量分别进行分析, 可准确把握负荷变化特性和环境因素影响。对这些分量采用相匹配 ANN 模型进行预测, 综合得到负荷序列的最终预测结果。仿真试验表明, 与传统 BP 神经网络预测方法相比该方法具有较高的精度和较强的适应能力。

关键词: 短期电力负荷; 经验模式分解; 内在模式分量; 人工神经网络

Short-term power load forecasting based on empirical mode decomposition and ANN

ZHENG Lian-qing, ZHENG Yan-qiu

(State Key Laboratory of Power Transmission Equipment & System Security and New Technology,
Chongqing University, Chongqing 400044, China)

Abstract: In order to predict effectively the short-term power load, which is inherently non-stationary and has a certain periodicity and randomness by itself, a novel approach for short-term load forecasting is presented based on empirical mode decomposition (EMD) and artificial neural network (ANN). The load sequence is decomposed into some intrinsic mode functions (IMF), and the local characteristic information of load can be reflected by them respectively. The regularity of the IMFs is analyzed to explore the degree of different factor influence on the IMFs, and the characteristics of load are concluded. Then these IMFs are forecasted by appropriate artificial neural networks. After the synthesis of the forecasted results from the IMFs, the final forecasting result of the load sequence is obtained. The simulation results show that the proposed method possesses higher precision and better adaptability than the traditional BP neural network method.

This work is supported by National Natural Science Foundation of China(No.50777066).

Key words: short-term power load; empirical mode decomposition; intrinsic mode functions; artificial neural network

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2009)23-0066-04

0 引言

电力短期负荷预测是电力系统调度管理部门制定开停机计划及实行在线安全分析的基础, 也是电力市场实现电能计划管理的基础, 对电力系统运行有着非常重要的作用。常用的负荷预测方法主要有回归分析法、时间序列法、人工神经网络法、小波-神经网络组合法和模糊方法等^[1-3]。

电力负荷为非平稳时间序列, 但传统的预测方法是假设它为平稳信号, 预测精度难以提高。为了提高预测精度, 对负荷序列进行分解, 解析出其中

代表负荷不同变化特性的分量, 根据各个分量的变化规律分别予以预测是一种合理的方法。目前常用的是小波方法对负荷进行分解^[4-7], 利用此方法需要预先确定小波基函数和分解尺度, 它们通常都是根据经验来选择。所以小波分解不是一种自适应的分解方法。经验模式分解(EMD)作为一种新的信号处理方法, 尤其适用于非线性和非平稳性数据, 在电力系统已得到应用, 但用于负荷预测领域的还很少^[8-10]。利用 EMD 方法将非平稳信号分解成若干个具有特征振荡周期的本征模式分量(IMF), 尽管有些分量仍具有不同程度的非平稳性, 但是他们之间的相互影响却被隔离了, 利用这种隔离可以尽可能地减小非平稳行为对预测的影响。

基金项目: 国家自然科学基金(50777066)

根据上述分析, 本文尝试将 EMD 和神经网络相结合, 对负荷进行短期预测。首先运用 EMD 将负荷序列分解成具有不同特征尺度的 IMF 分量及余项, 从不同方面分析各个 IMF 及余项的规律性, 然后根据各个分量的特性分别构建神经网络模型进行预测, 最后所有分量的预测值组合得到最终的预测值。

1 EMD 原理与算法

EMD 是一种适用于分析非线性、非平稳性数据的新方法, 由 Norden E.Huang 于 1998 年提出^[11]。分解过程基于下面的假设:

- 1) 被分析信号至少有一个极大值和一个极小值。
- 2) 极值间的时间间隔为特征时间度。
- 3) 如果信号数据没有极值点只有拐点, 可通过对数据进行一次或几次微分来获得极值点, 再通过积分获得分解结果。

由于数据自身的复杂性, 也许在同一时间, 有许多不同的振荡模式共存。EMD 基于数据自身的局部特征尺度, 可以从原始数据中解析出这些内在模式, 即本征模式分量 IMF。这些 IMF 需要满足 2 个条件:

- 1) 在整个数据序列中, 极值点的数量与过零点的数量必须相等或最多相差 1 个。
- 2) 在任何一点, 由数据序列局部极大值点确定的上包络线和由局部极小值点确定的下包络线均值为 0, 即信号关于时间轴对称。

EMD 分解步骤如下^[12]:

- 1) 确定时间序列 $x(t)$ 的局部极大值和局部极小值点。
- 2) 利用三次样条插值分别连接所有极大值点和所有极小值点, 形成信号的上包络线 $e_{\max}(t)$ 和下包络线 $e_{\min}(t)$, 使信号的所有数据点都在两包络线之间。
- 3) 由极大值包络线与极小值包络线取平均得到均值包络线。记为 $m_1(t)$:

$$m_1(t) = (e_{\max}(t) + e_{\min}(t)) / 2 \quad (1)$$

- 4) 计算 $x(t)$ 与 $m_1(t)$ 之差, 记为 $h_1(t)$:

$$h_1(t) = x(t) - m_1(t) \quad (2)$$

- 5) 判断 $h_1(t)$ 是否满足 IMF 的条件, 如果满足条件, 则 $h_1(t)$ 为第一个 IMF; 如果不满足条件, 则将 $h_1(t)$ 当作原始序列, 得到 $h_1(t)$ 极大值、极小值

包络线的均值包络线 $m_{11}(t)$, 再判断 $h_{11}(t) = h_1(t) - m_{11}(t)$ 是否满足 IMF 条件, 若不满足, 则重复循环 k 次, 得到 $h_k(t) = h_{(k-1)}(t) - m_k(t)$, 使 $h_k(t)$ 满足 IMF 的条件。记 $c_1(t) = h_k(t)$, 则为 $x(t)$ 的第 1 个 IMF, 视为 IMF1。

6) 将 $c_1(t)$ 从 $x(t)$ 中分离出来, 将余项 $r_1(t) = x(t) - c_1(t)$ 当作原始序列, 重复步骤 1)~5), 即可依次得到 IMF2, IMF3, ..., 直到 $c_n(t)$ 或 $r_n(t)$ 满足给定的终止条件时, 筛选过程结束。原始序列可被表示为 IMF 和最终余项的和:

$$x(t) = \sum_{i=1}^m c_i(t) + r(t) \quad (3)$$

式(3)说明, 可以将信号 $x(t)$ 分解成频率从大到小排列的 m 个 IMF 分量 c_i 和一个趋势项 r 之和。因为每个 IMF 分量代表一个特征时间尺度的数据序列, 故“筛”过程实际上将原始数据序列分解为各个不同特征波动序列的叠加。

2 基于 EMD 与 BP 神经网络的负荷预测

神经网络因为其较强的适应能力和学习能力, 使之在非线性系统的预测方面得到了广泛的应用。而电力系统负荷数据经常受到随机因素的影响, 其本质上是非平稳的, 因此利用神经网络进行电力负荷预测, 其预测结果往往不理想。为了提高预测精度, 用 EMD 方法把负荷序列分解成有限个具有特征震荡周期的分量 IMF。尽管每一个分量都可能是变频和变幅的, 或者仍然保持着不同程度的非平稳性, 但是它们之间的相互影响却被隔离了。利用这种隔离可以尽可能地减小非平稳行为对预测的影响。然后对每一个 IMF 分别进行分析, 了解各影响因素对不同 IMF 的影响情况, 更清楚的把握各 IMF

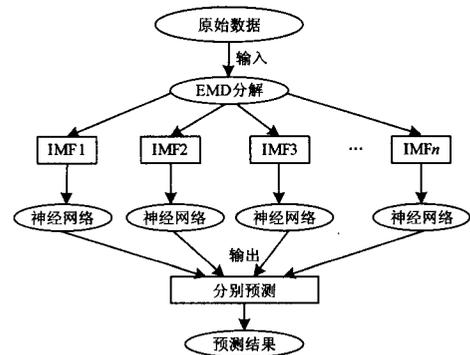


图 1 EMD 和神经网络预测模型

Fig.1 Forecasting model of EMD and ANN

的规律性。在此基础上,根据各个 IMF 的变化特点分别用 BP 神经网络算法建立不同的模型,最后将预测结果叠加。其预测方法结构图见图 1,步骤为:

- 1) 利用 EMD 对负荷数据进行分解得到 IMF1, IMF2, ..., IMF $n-1$ 和 res 等 n 个分量。
- 2) 对分解后的各 IMF 分量及余项从不同方面进行分析,了解各影响因素对不同 IMF 及余项的影响情况。
- 3) 根据各 IMF 分量及余项的特性分别建立合适的 BP 神经网络模型。本文采用多输入、单输出的一步预测方法。
- 4) 对各预测分量叠加得最终预测值。

3 仿真试验

本文利用贵州省某地区电力系统 2007 年 8 月份的整点有功负荷作为采样数据,通过 EMD,负荷序列可被分解为一系列具有不同尺度的、独立的 IMF 及余项。对于这些 IMF 及余项的分析可有助于从一个新的角度挖掘负荷的变化特性和形成机理。

图 2 为 2007 年 8 月 1 日~31 日整点有功负荷数据运用 EMD 分解得到的 IMF 及余项。所有的 IMF 按从高频到低频的顺序排列,它们展示了变化的频

率和振幅,最后一个显示的是余项。由图 2 可观察到 IMF1 波动频繁,变化规律不明显,具有一定的随机性,反映了负荷的高频部分,说明高频突发事件对 IMF1 有一定的影响。可将高频分量看作在典型周期波动基础上的随机波动,主要反映了高频突发事件的影响和人们用电的随机性,但是其数值较小,在预测精度要求不是特别高的情况下可忽略。IMF2 周期幅度较小,为高频周期分量,说明受到一定气象因素的影响。IMF3 与原负荷变化相似,数值较大,以天为周期平稳变化,受气象等因素的影响并不显著,说明该分量主要由日常固定的用电习惯所决定,进行着以天为周期的典型波动,基本不会由于外界环境的变化而产生波动。IMF4、IMF5 为低频周期分量,它们的周期幅度较大,但他们对整体负荷的波动贡献较小,且其数值较小。余项 res 代表负荷的趋势分量,其均值接近整体负荷的均值,说明它包含了整体负荷的基荷部分,同时反映了负荷在分析范围内的总体变化趋势。该分量受气象因素影响比较显著。基于以上分析,对 IMF1、IMF2, ..., IMF5 和 res 分别建立相应的预测模型,每个网络模型都是 3 层,即输入层、隐含层和输出层。每个模型的输出层都只有一个输出元,对应要预测小时的负荷值。大量试验表明,如果对各 IMF 分量应用同一神经网络模型进行预测,其预测精度没有明显的改变,主要原因是各 IMF 分量具有不同的特征,因此,各 IMF 分量应采用不同的预测模型。IMF1 和 IMF2 为高频随机分量,数值较小,且二者波动情况类似,使用同一个 17-12-1 的 BP 网络,IMF4 和 IMF5 为低频周期分量,数值较小,也使用同一个 26-15-1 的网络,IMF3 具有日周期性,且数值较大,单独使用一个 6-6-1 的网络,res 为趋势向,数值最大,且受气象因素影响显著,预测时考虑气象因素,使用 25-5-1 的网络。具体参数参见表 1。

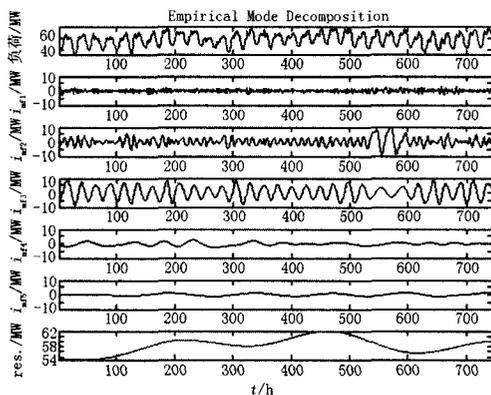


图 2 原始负荷 EMD 分解得到的 IMF 和余项

Fig.2 IMFs & residue for the original load through EMD

表 1 各 IMF 预测模型参数
Tab.1 Forecasting model parameters for IMFs

名称	IMF1、IMF2	IMF4、IMF5	IMF3	res
输入元数	17	26	6	25
隐含元数	12	15	6	5
输出元数	1	1	1	2
输入层节点信息	$T(i-1)$; $T(i)$ 及 前 12 时刻的数据	$T(i-1)$; $T(i)$ 及 前 24 时刻的数据	$L(t,i-3)$; $L(t,i-2)$; $L(t,i-1)$; $L(t-1,i)$; $L(t-2,i)$; $L(t-3,i)$	$T(i)$ 及前 24 时刻的数据

注:表中 $T(i)$ 表示第 i 天的最高温度, $L(i,t)$ 表示第 i 天第 t 小时的负荷值。

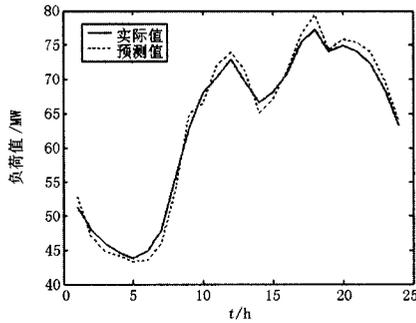


图3 EMD-BP模型最终预测结果

Fig 3 Final forecasting result of EMD-BP model

表2 预测误差比较

Tab.2 Comparison of forecasting errors

时刻	实际值 /MW	BP 算法		EMD-BP 算法	
		预测值 /MW	相对误差 /(%)	预测值 /MW	相对误差 /(%)
01	51.25	53.320	4.093	52.794	3.013
02	48.06	50.569	5.221	46.953	-2.303
03	45.85	47.326	3.219	44.791	-2.310
04	44.58	45.055	1.066	44.182	-0.893
05	43.85	41.357	-5.685	43.305	-1.243
06	44.83	46.399	3.500	43.625	-2.688
07	47.91	50.369	5.132	45.896	-4.204
08	55.39	52.016	-6.091	53.534	-3.351
09	63.04	60.159	-4.570	65.001	3.111
10	68.07	67.028	-1.531	66.483	-2.331
11	70.27	75.258	7.098	72.028	2.502
12	72.96	75.146	2.996	74.035	1.473
13	69.64	68.026	-2.318	71.254	2.318
14	66.55	64.059	-3.743	65.098	-2.182
15	68.11	70.599	3.654	67.120	-1.454
16	70.69	73.587	4.098	71.023	0.471
17	75.41	77.355	2.579	76.541	1.500
18	77.23	80.125	3.749	79.503	2.943
19	74.04	71.254	-3.763	74.361	0.434
20	74.92	71.259	-4.887	75.892	1.297
21	74.09	72.698	-1.879	75.360	1.714
22	72.26	70.255	-2.775	73.987	2.390
23	68.39	67.027	-1.993	69.632	1.816
24	63.22	62.897	-0.511	63.789	0.900
MAPE/(%)		3.589		2.035	
MPE/(%)		0.278		0.122	
MSE		5.549		1.855	

样本采用与待预测日接近的30天即2007年8月1日至30日的负荷数据,其各IMF分量性质分析

如上文,气象因素只考虑每天的最高温度。预测误差采用相对误差、平均绝对百分误差(MAPE)、平均百分误差(MPE)和均方误差(MSE)。对训练样本集进行训练,在误差达到一定的阈值以下时确定并保留网络连接权值,每日根据误差对连接权值进行自适应调整,以跟踪负荷的最新变化,保证其准确度。对各IMF分量分别预测后,将结果叠加得到总的预测值。对8月31日的预测结果如图3所示。为了验证此方法的有效性和可行性,直接运用BP神经网络对同一天24点进行预测,其预测误差与本文方法比较见表2。

4 结论

本文提出了基于EMD分解的电力系统短期负荷预测方法,通过EMD把电力负荷分解成独立的IMF分量,降低了负荷序列的非平稳性,跟原始负荷相比,这些分量更容易分析其影响因素并预测,以此作为神经网络的输入数据,使得神经网络具有收敛快、抗干扰能力强的优点。最后叠加各分量预测值得到最终预测结果。试验仿真表明,此方法具有良好的预测精度和较强的适应能力。

参考文献

- [1] 牛东晓,曹树华,赵磊. 电力负荷预测技术及其应用[M]. 北京: 中国电力出版社, 1998.
- [2] 康重庆,夏清,刘梅. 电力系统负荷预测[M]. 北京: 中国电力出版社, 2007.
- [3] 康重庆,夏清,张伯明. 电力系统负荷预测研究综述与发展方向的探讨[J]. 电力系统自动化, 2004, 28(7): 1-11.
- [4] KANG Chong-qing, XIA Qing, ZHANG Bo-ming. Review of Power System Load Forecasting and Development[J]. Automation of Electric Power Systems, 2004, 28(7): 1-11.
- [5] Yao S J, Zhang L Z. Wavelet Transform and Neural Networks for Short-term Electrical Load Forecasting[J]. Energy Conversion and Management, 2000, 41(18): 1975-1988.
- [6] 谢宏, 陈志业, 牛东晓, 等. 基于小波分解与气象因素影响的电力系统日负荷预测模型研究[J]. 中国电机工程学报, 2001, 21(5): 6-10.
- [7] XIE Hong, CHEN Zhi-ye, NIU Dong-xiao, et al. The Research of Daily Load Forecasting Model Based on Wavelet Decomposing and Climatic Influence[J]. Proceedings of the CSEE, 2001, 21(5): 6-10 (in Chinese).
- [8] 邵能灵, 侯志俭, 李涛, 等. 基于小波分析的电力系统短期符合预测方法[J]. 中国电机工程学报, 2003, 23(1): 45-50.

(下转第74页 continued on page 74)

- NIU Zhen-yong, DU Zheng-chun, XIA Dao-zhi. Parameter Optimization of Multi-machine Power System Stabilizers Using Evolutionary Strategy[J]. Proceedings of the CSEE, 2004, 24(2): 22-27.
- [8] 韩英铎, 王仲鸿, 陈淮金. 电力系统最优分散协调控制[M]. 北京: 清华大学出版社, 1997.
HAN Ying-duo, WANG Zhong-hong, CHEN Huai-jin. Optimization Decentralized Control of Power System[M]. Beijing: Tsinghua University Press, 1997.
- [9] Chow J H, Sanchez Gasca J J. Pole-Placement Designs of Power System Stabilizers[J]. IEEE Trans on Power Systems, 1989, 4(1): 271-277.
- [10] 方思立, 朱方. 电力系统稳定器的原理及其应用[M]. 北京: 中国电力出版社, 1996.
FANG Si-li, ZHU Fang. The Theory and Application of PSS[M]. Beijing: China Electric Power Press, 1996.
- [11] Joze Ritonja, Drago Dolinar, Bojan Grcar. Design of an Adaptive Power System Stabilizer[J]. IEEE Trans on International Symposium, 1999, 3(12): 1306-1311.
- [12] 王海风, 韩祯祥. 自适应电力系统稳定器设计的频域方法[J]. 中国电机工程学报, 1992, 12(6): 1-10.
WANG Hai-feng, HAN Zhen-xiang. Adaptive Power System Stabilizer Design in Frequency Domain[J]. Proceedings of the CSEE, 1992, 12(6): 1-10.
- [13] 安德逊 M, 佛阿德 A A. 电力系统的控制与稳定翻译组译 电力系统的控制与稳定(第一卷)[M]. 北京: 水利电力出版社, 1979.
Anderson P M, Fouad A A. Team of Power System Control and Stability Translate, Power System Control and Stability[M]. Volume I. The Public of Water Conservancy and Electric Power, 1979.
- [14] 倪以信, 陈寿孙, 张宝霖. 动态电力系统的理论和分析[M]. 北京: 清华大学出版社, 2002.
NI Yi-xin, CHEN Shou-sun, ZHANG Bao-lin. Theory and Analysis of Dynamic Electric Power System[M]. Beijing: Tsinghua University Press, 2002.
- [15] Liu Q, Zhou S X, Feng Z H. Using Decoupled Characteristic in the Synthesis of Stabilizers in Multi-machine Systems[J]. IEEE Trans on Power Systems, 1987, 2(1): 31-36.

收稿日期: 2009-06-01

作者简介:

贾继灏(1981-), 男, 硕士研究生, 现在从事输变电运行部工作; E-mail: jihaoj@yahoo.com.cn

马丽丽(1982-), 女, 硕士研究生, 现在从事变电检修工作;

刘宪林(1955-), 男, 教授, 现从事电力系统分析与控制和电力电子与电力传动方面的科研与教学工作。

(上接第 69 页 continued from page 69)

- TAI Neng-ling, HOU Zhi-jian, LI Tao, et al. New Principle Based on Wavelet Transform for Power System Load Forecasting[J]. Proceedings of the CSEE, 2003, 23(1): 45-50 (in Chinese).
- [7] Fryzlewicz P, Bellegem S V, Sachs R V. Forecasting Non-stationary Time Series by Wavelet Process Modeling[J]. Annals of the Institute of Statistical Mathematics, 2003, 55(4): 737-764.
- [8] 李天云, 高磊, 聂永辉, 等. 基于经验模式分解处理局部放电数据的自适应直接阈值算法[J]. 中国电机工程学报, 2006, 26(15): 29-34.
LI Tian-yun, GAO Lei, NIE Yong-hui, et al. A New Adaptive Direct-threshold Algorithm to Partial Discharge Data Processing Based on Empirical Mode Decomposition[J]. Proceedings of the CSEE, 2006, 26(15): 29-34.
- [9] 牛东晓, 李媛媛, 乞建勋, 等. 基于经验模式分解与因素影响的负荷分析方法[J]. 中国电机工程学报, 2008, 28(16): 96-102.
NIU Dong-xiao, LI Yuan-yuan, QI Jian-xun, et al. A Novel Approach for Load Analysis Based on EMD and Influencing Factors[J]. Proceedings of the CSEE, 2008, 28(16): 96-102.
- [10] 祝志慧, 孙云莲, 季宇, 等. 基于 EMD 和 SVM 的短期负荷预测[J]. 高电压技术, 2007, 33(5): 118-122.
ZHU Zhi-hui, SUN Yun-lian, JI Yu, et al. Short-term Load Forecasting Based on EMD and SVM[J]. High Voltage Engineering, 2007, 33(5): 118-122.
- [11] Huang N E, Shen Z, Long S R. The Empirical Mode Decomposition Method and the Hilbert Spectrum for Nonlinear and Nonstationary Time Series Analysis[A]. in: Proceeding of the Royal Society of London, Series A[C]. 1998. 454: 903-955.
- [12] Balocchi R, Menicucci D, Varanini M. Empirical Mode Decomposition to a Approach the Problem of Detecting Sources from a Reduced Number of Mixtures[A]. in: Proceeding of the 25th Annual International Conference of the IEEE EMBS[C]. Cancun Mexico: 2003.

收稿日期: 2008-12-15; 修回日期: 2009-01-16

作者简介:

郑连清(1964-), 男, 博士研究生, 教授, 主要研究方向为电力电子技术在电力系统中的应用;

郑艳秋(1983-), 女, 硕士研究生, 主要研究方向为短期电力负荷预测. E-mail: zyqq1983@126.com