

应用于月度用电量预测的小波分析法

吴雪花

(南京航空航天大学金城学院,江苏南京 211156)

摘要:月度用电量预测是中期负荷预测的主要内容,也是制定月度发电规划的基础。文中以美国亚利桑那州为例,采用小波分析法,首先使用小波变换获得若干个采样点减少一半的小波系数;然后分别对各系数插零、重构,恢复到原数据的长度;最后采用RBF神经网络对恢复长度的各系数进行预测。该方法将月度用电量的时间序列分解成趋势项和波动项,分别进行预测,提高了预测精度。

关键词:用电量预测,小波,RBF神经网络

中图分类号:TM715

文献标志码:A

文章编号:1009-0665(2014)02-0008-04

月度用电量预测是中期负荷预测的主要内容,也是制定月度发电规划的基础。近年研究发现,用电量不仅呈逐年变化的趋势,而且受气温波动的影响^[1]。因此将月度用电量数据逐年变化趋势的特征和随气温波动的特征这2种特征进行分离剖析,能够提高预测的准确性^[2,3]。小波分析法是一种运用伸缩平移运算,对高频分量进行时间细分,低频分量进行频率细分,最终将信号分解成一系列小波函数叠加的分析方法。该方法实现了时间频率的局部化分析。相较于傅里叶分析,小波函数可以逼近非稳态信号中尖锐变化的部分,也可以逼近离散不连续具有局部特性的信号,描述能力更强,是信号分解的一种常用方法,对非线性信号具有较好的分解效果^[4]。

文献[3]采用小波分析法,将用电量数据分解成若干不同尺度的分量,使得数据逐年变化趋势的特征和随气温波动的特征这两种特征分离,然后采用BP神经网络对各分量分别进行预测,总体预测精度更高。然而小波分析每进行一次分解,小波系数的采样点会减少一半,影响预测精度,文献[3]并未对小波分解的这种不足加以分析。

针对这种不足,本文将做如下改进:首先采用小波分析法对月度用电量进行分解;然后采用小波重构将各小波系数恢复到原数据的长度;最后采用RBF神经网络对恢复长度的各系数进行月度用电量预测,并与传统的小波分析法进行比较。

1 小波分析法

1989年,Mallat等人采用滤波器的方法实现了离散小波变换^[4],Mallat离散小波变换可表示为:

$$cA_{j+1}(n)=\sum_k H(k-2n) \times cA_j(k) \quad (1)$$

$$cD_{j+1}(n)=\sum_k G(k-2n) \times cA_j(k) \quad (2)$$

收稿日期:2013-10-08;修回日期:2013-11-17

式(1,2)中: j 为分解尺度; k,n 为平移系数; cA_j 为第 j 层小波系数的低频部分; cA_{j+1} 和 cD_{j+1} 分别为第 $j+1$ 层小波系数的近似分量和细节分量; H,G 为小波分解滤波器。

式(1)和式(2)所示的离散小波变换等效于分别采用高通滤波器 H 和低通滤波器 G 对 cA_j 进行滤波,并进行降采样,得到近似分量 cA_{j+1} 和细节分量 cD_{j+1} 。

形象化的小波分解过程如图1所示。首先对原信号 $x(t)$ 进行小波变换,即对 $x(t)$ 进行滤波和降采样,得到近似分量 cA_1 和细节分量 cD_1 ;然后对近似分量 cA_1 进行小波变换,即对 cA_1 进行滤波和降采样,得到 cA_2 和 cD_2 ;接着对近似分量 cA_2 进行小波变换, \dots ,以此类推,直至得到近似分量 cA_{j+1} 和细节分量 cD_{j+1} 。

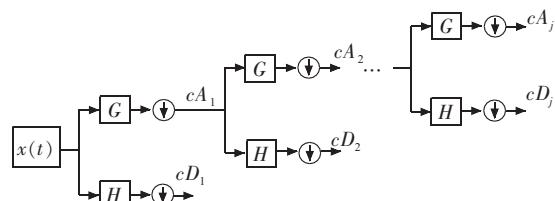


图1 小波分解的流程图

文献[3]中采用小波分析法,将原信号 $x(t)$ 进行3次滤波和降采样,得到相应的近似分量和细节分量。其中近似分量表征逐年变化趋势的特征,细节分量表征随气温波动的特征。然后采用组合预测的方法,利用小波系数 cD_1,cD_2,cD_3 和 cA_3 ,对波动分量和趋势分量分别进行预测。然而,这种仅利用小波系数 cD_1,cD_2,cD_3 和 cA_3 进行组合预测的方法存在2个缺点。

(1) 各小波系数中横坐标为采样点,纵坐标为系数值,缺乏具体的物理意义。

(2) 在离散小波分解过程中,每进行一次滤波和降采样,采样点就会减少一半。如果原信号数据有269个采样点,那么,经4次滤波和降采样后得到的 cA_4 仅剩17个采样点,显然会降低表征逐年变化趋势的特征分

量的预测精度。

为了克服上述缺点,可以对小波系数 cD_1, cD_2, cD_3, cD_4 和 cA_4 分别进行重构,使得它们恢复原来的数据长度。借助 Mallat 离散小波变换对应的反变换,可以有效实现该重构目标。Mallat 离散小波变换对应的反变换可表示为:

$$cA_j(k) = \sum_n G'(k-2n) \times cA_{j+1}(n) + \sum_n H'(k-2n) \times cD_{j+1} \quad (3)$$

式(3)中: H' , G' 为小波重构滤波器,且 H' 为高通滤波器, G' 为低通滤波器。

式(3)表示的离散小波反变换等效于采用低通滤波器 G' 对近似分量 cA_{j+1} 进行滤波,同时采用高通滤波器 H' 对细节分量 cD_{j+1} 进行滤波,然后对这 2 个输出量进行求和并升采样,重构得到上一层小波系数的低频部分 cA_j 。升采样过程中要在各系数各采样点之间插零,并通过重构滤波器 H', G' 进行滤波。形象化的小波分解和重构的全过程如图 2 所示。

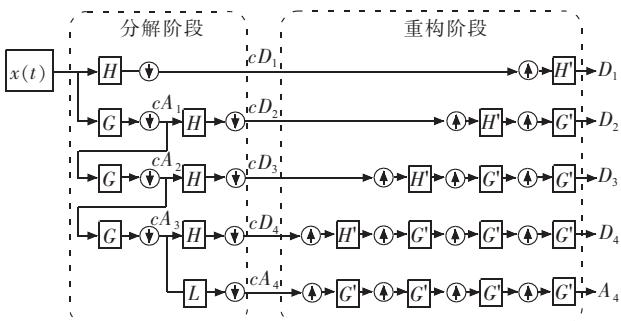


图 2 月度用电量数据小波分解的全过程

通过小波重构,各小波系数不仅恢复了原来的数据长度,且都被赋予了明确的物理意义, D_1, D_2, D_3, D_4 和 A_4 可以看作是原信号 $x(t)$ 的 4 个分量,并且有:

$$x(t) = D_1 + D_2 + D_3 + D_4 + A_4 \quad (4)$$

小波函数决定着小波变换及其反变换过程中各滤波器 H, G, H', G' 的表达式,其选取直接关系着分解效果的好坏。Daubechies 是一类正交小波函数,在分解的过程中不会造成信息的丢失,因此被广泛应用于负荷预测领域。

2 算例分析

以美国亚利桑那州从 1990 年 1 月至 2007 年 5 月共 209 个月的月用电量数据为例,该数据来自美国能源信息局官方网站:<http://www.eia.gov/electricity/data.cfm>。数据曲线如图 3 所示。其中,前 173 个月的数据用于训练,后 36 个月的数据用于测试。本文进行月度用电量预测方法的流程图如图 4 所示。

首先对月度用电量数据 $x(t)$ 进行小波分解,4 次

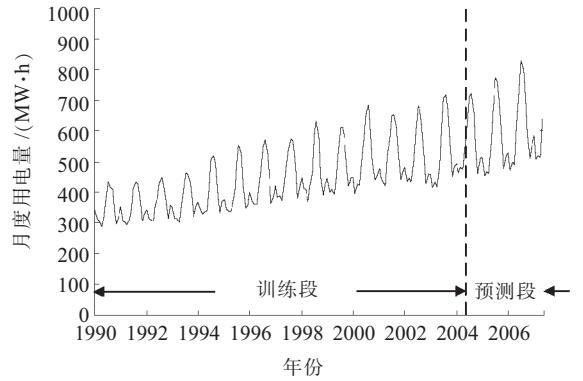


图 3 亚利桑那州 1990 年 1 月至 2007 年 5 月月度用电量曲线

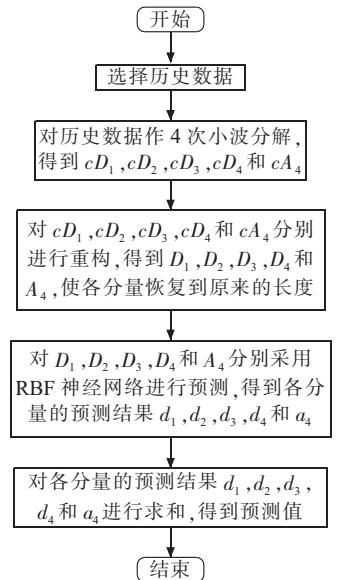


图 4 本文预测方法的流程图

滤波和降采样之后,再通过小波重构恢复数据长度,得到 D_1, D_2, D_3, D_4 和 A_4 的 5 个分量;然后对 D_1, D_2, D_3, D_4 和 A_4 分别采用 RBF 神经网络进行预测,本次预测模型需要建立 5 个 RBF 神经网络;最后对 5 个预测结果进行求和,得到预测值。具体的,首先采用 Daubechies 4 小波函数,将亚利桑那州月用电量数据进行小波分解,结果如图 5 所示。

从图 5 中可以看出,第 4 次小波变换后,近似分量 cA_4 已基本没有波动的特征,因此可以认为系数 cA_4 代表了月度用电量数据中不随气温变化的那一部分趋势分量,此外的 cD_1, cD_2, cD_3 和 cD_4 ,与 cA_4 相对应,是反映月度用电量数据随气温波动的那一部分分量。

经过小波分解,原信号 $x(t)$ 中不同尺度的分量已基本被分离出来,在此基础上对各分量进行对应的小波重构,使得各分量恢复原来的数据长度。重构后的各分量分别为 D_1, D_2, D_3, D_4 和 A_4 ,它们的曲线图如图 6 所示。

获得上述分析结果后,就可以对未来一个月的用

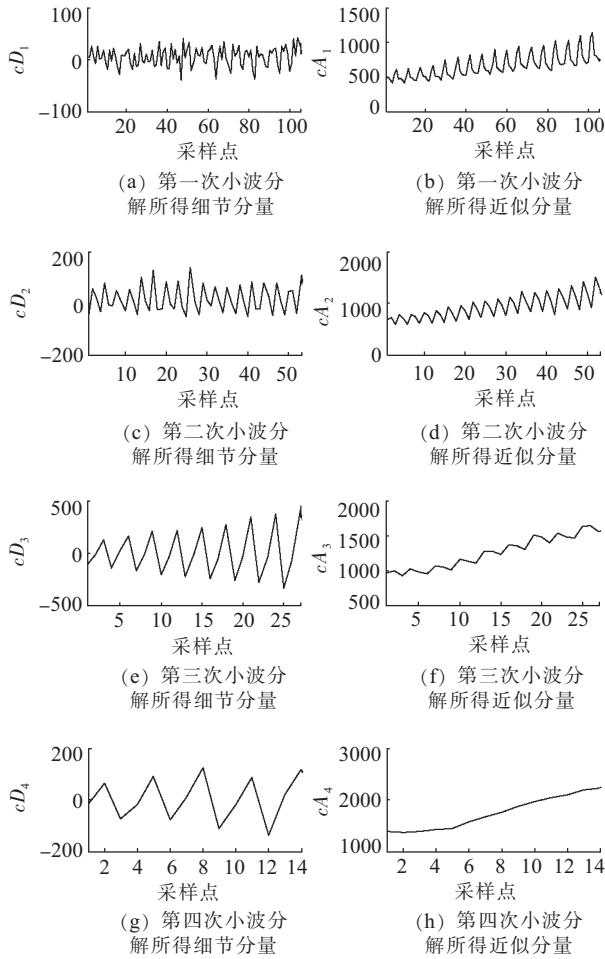


图 5 月度用电量曲线小波分解结果

电量值进行预测了。虽然月度用电量数据受到气温、经济、政治等因素的影响,但是这些因素大多以 12 个月为周期,因此采用过去 12 个月的月用电量数据来预测未来一个月的用电量是非常合理的^[5,6]。本文采用 RBF 神经网络对上述分析结果进行预测。RBF 神经网络是一种三层前馈网络,具体的结构图如图 7 所示。图中 $x(t_p-1), x(t_p-2) \dots x(t_p-12)$ 为所需预测月度 t_p 之前连续 12 个月的用电量数据,而 $x_{\text{pre}}(t_p)$ 为该月度用电量的预测值。

本次算例中,需要建立 5 个如图 7 所示的 RBF 神经网络,依次命名为 RBFNN1~5。然后,将恢复原来数据长度的小波系数 D_1, D_2, D_3, D_4 和 A_4 作为历史数据,分别输入 RBFNN1~5 中,每个小波系数对应一个 RBF 神经网络。譬如,将 D_1 中前 173 个月的数据每连续 12 个月作为一组输入 RBF 神经网络 RBFNN1 中,预测相应未来一个月的用电量,预测值输出量结合对应月份已知用电量可以训练 RBFNN1。利用训练好的神经网络 RBFNN1 预测小波系数 D_1 中后 36 个月的数据 $D_{1\text{pre}}(i)$,其中变量 i 为 1~36 的自然数。参照以上步骤,分别预测 D_2, D_3, D_4 和 A_4 中后 36 个月的数

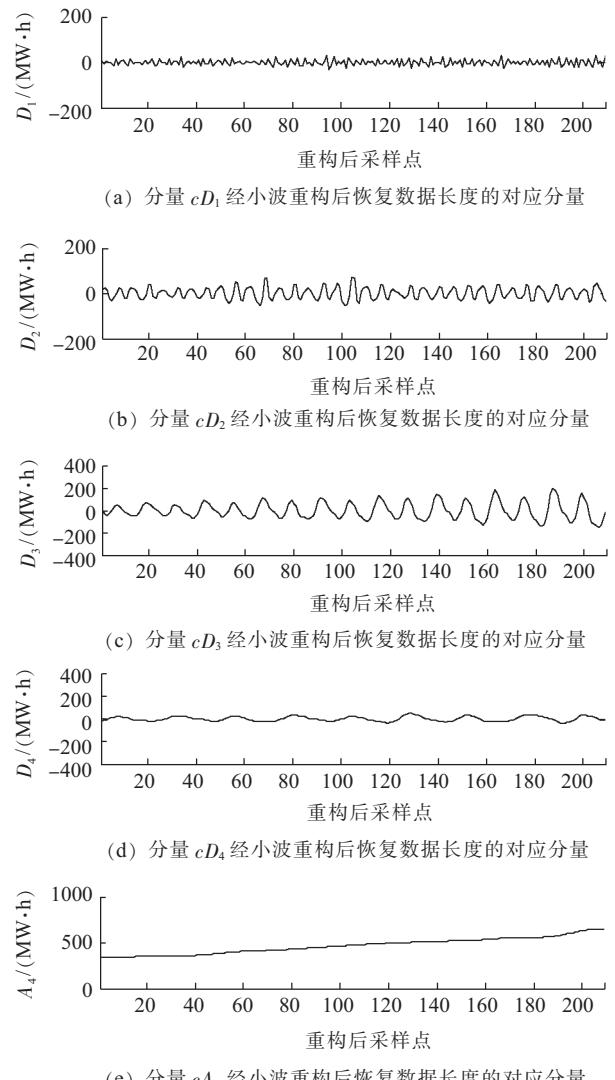


图 6 小波重构后恢复原来数据长度各分量

历史数据

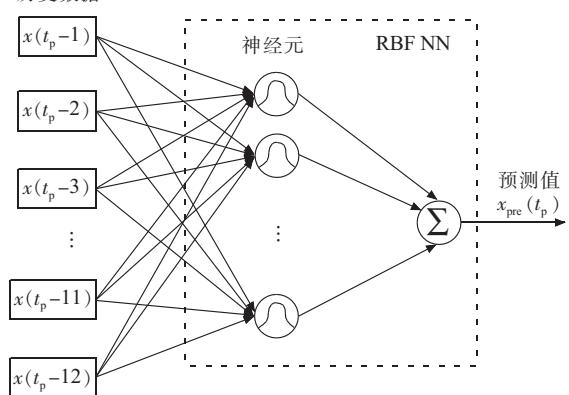


图 7 RBF 神经网络结构图

据,分别为 $D_{2\text{pre}}(i), D_{3\text{pre}}(i), D_{4\text{pre}}(i), A_{4\text{pre}}(i)$,其中变量 i 为 1~36 的自然数。 $D_{1\text{pre}}(i), D_{2\text{pre}}(i), D_{3\text{pre}}(i), D_{4\text{pre}}(i)$ 和 $A_{4\text{pre}}(i)$ 是后 36 个月的预测用电量 $x_{\text{pre}}(i)$ 的 5 个分量,并且有:

$$x_{\text{pre}}(i) = D_{1\text{pre}}(i) + D_{2\text{pre}}(i) + D_{3\text{pre}}(i) + D_{4\text{pre}}(i) + A_{4\text{pre}}(i) \quad (5)$$

MATLAB 仿真结果显示,本文提出的方法预测精

确度较高。为了充分说明这点,接下来将采用另外2种方法进行预测对比。其中,方法1不对月度用电量数据 $x(t)$ 做任何分解,直接采用RBF神经网络对 $x(t)$ 进行预测;方法2采用文献[3]提出的小波分析法对 $x(t)$ 进行预测;方法3是本文提出的方法。3种方法的36个月用电量数据预测结果如图8所示。

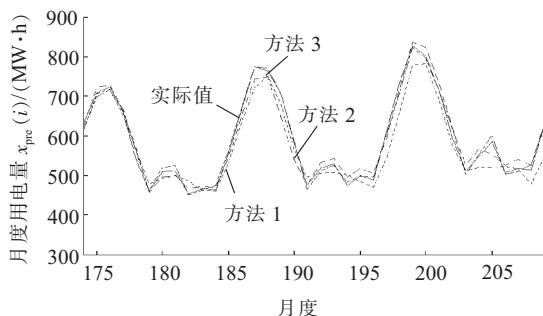


图8 各预测方法预测结果

从图8中可以看出,相比于其他2种方法,本文所提出的方法具有更高的预测精度。为进一步比较上述3种方法的预测精度,还可以比较它们预测结果的2个指标。

平均绝对百分误差:

$$\delta_{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{x(i) - x_{pre}(i)}{x(i)} \right| \times 100\% \quad (6)$$

均方根误差:

$$\delta_{RMSE} = \sqrt{\frac{\sum_{i=1}^N [x(i) - x_{pre}(i)]^2}{N}} \quad (7)$$

式(6,7)中: N 为测试样本的个数,这里为36个; $x(i)$ 为实际值; $x_{pre}(i)$ 为预测值。3种方法的平均绝对百分误差 δ_{MAPE} 和均方根误差 δ_{RMSE} 如表1所示。

从表1可以看出,方法3的 δ_{MAPE} 和 δ_{RMSE} 比另外2种方法要小,再一次证明了本文所提出的方法对月度用电量数据的预测更加精确。

表1 3种方法的预测误差

误差	方法1	方法2	方法3
$\delta_{MAPE}/\%$	4.22	2.90	1.40
δ_{RMSE}/MW	32.84	20.26	10.24

3 结束语

本文提出了一种应用于月度用电量预测的小波分析法。传统的Mallat小波分析法在小波分解过程中,每进行一次分解,采样点就会减少一半,从而影响预测精度。针对这种现象,该法可以通过小波重构将各分量的采样点个数恢复到原来数据的长度,再通过RBF神经网络进行预测,大大提高预测精度。

参考文献:

- [1] 许琦,曾凌.南京电网负荷与气温敏感性分析[J].江苏电机工程,2012,31(5):55-57.
- [2] 刘学琴,吴耀华,崔宝华.小波软阈值去噪和GRNN网络在月度负荷预测中的应用[J].电力系统保护与控制,2009,37(14):59-62.
- [3] 姚李孝,刘学琴.基于小波分析的月度负荷组合预测[J].电网技术,2007,31(19):65-68.
- [4] MALLAT S. A Theory for Multiresolution Signal Decomposition—the Wavelet Representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1989, 11(7):674-693.
- [5] CHEN Y, LUH P B, GUAN C. Short-Term Load Forecasting:Similar Day-Based Wavelet Neural Networks[J]. IEEE Transactions on Power Systems, 2010, 25(1):322-330.
- [6] AGNALDO R R, ALEXANDRE P A. Feature Extraction via Multiresolution Analysis for Short-term Load Forecasting [J]. IEEE Transactions on Power Systems, 2005, 20(1):189-198.

作者简介:

吴雪花(1986),女,江苏金坛人,硕士研究生,从事开关电源、电力系统研究工作。

A Wavelet based Method for Monthly Electricity Demand Forecasting

WU Xuehua

(Jincheng College of Nanjing University of Aeronautics and Astronautics, Nanjing 211156, China)

Abstract: Monthly electricity demand forecasting is the main content of medium-term load forecasting and the base of monthly scheduling for the power grid operation. This paper proposes a wavelet based monthly electricity demand forecasting method. It consists of three steps: first, the wavelet transform converts the original data series into several coefficients which are down sampled; second, inserting zeroes between each coefficient to recover the coefficients to the origin length; finally, RBF neural network is adopted to forecast the coefficients. By decomposing the monthly electricity consumption data series into trend component and fluctuation component and forecasting each component separately, the proposed method greatly improves the precision of monthly electricity demand forecasting.

Key words: demand forecasting; wavelet; RBF neutral network