

# 小波分解层数及其组合分量对短期风速多步预测的影响分析

王东风<sup>1</sup>, 王富强<sup>2</sup>, 牛成林<sup>1</sup>

(1. 华北电力大学自动化系, 河北 保定 071003; 2. 神华国华(北京)电力研究院有限公司, 北京 100069)

**摘要:** 针对风速时间序列的规律性和随机性双重特征, 将小波分解和 RBF 神经网络相结合用于短期风速预测。针对小波分解用于风速信号的不同频率成份的趋势项提取, 研究了基于小波分解后的分量 RBF 网络预测及综合问题, 包括全部高频-低频分量组合预测、部分高频-低频分量组合预测, 以及低频分量组合预测三种方法的预测性能和特点。分析了三种不同方法在短期风速预测中的应用效果。通过对不同时间、不同地点短期风速预测的研究发现, 进行不同步数的预测时, 只有选取合适的分解层数、合适的高频分量和低频分量组合, 才能得到最优的预测效果。该结论对于将小波分解用于短期风速时间序列的预测具有一定的指导意义。

**关键词:** 风速预测; 小波分解; RBF 网络; 时间序列; 多步预测

## Analysis of wavelet decomposition for multi-step prediction of short-term wind speed

WANG Dong-feng<sup>1</sup>, WANG Fu-qiang<sup>2</sup>, NIU Cheng-lin<sup>1</sup>

(1. Department of Automation, North China Electric Power University, Baoding 071003, China;

2. Shenhua Guohua (Beijing) Electric Power Research Institute Co., Ltd, Beijing 100069, China)

**Abstract:** Aiming at the double characteristics of regularity and randomness of wind speed series, wavelet decomposition combined with radial basis function (RBF) neural network are used for short term prediction of wind speed. Aiming at the trend term extraction of different components with different frequencies in wavelet decomposition of wind speed signal, RBF network prediction for different components decomposed with wavelet and the corresponding synthesization method are studied, which includes three kinds of decomposition-combination prediction methods, i.e. prediction using all-high-frequency and low-frequency components, prediction using part-high-frequency and low-frequency components, and prediction using low-frequency component. The prediction performances and characteristics are analyzed. Prediction results, which are based on the data sampled from different dates and different sites, are analyzed in the short-term wind speed prediction by using different methods, and the conclusion is that the optimal prediction results can be obtained only when appropriate decomposition layers, appropriate combination of high-frequency and low-frequency components are used. The conclusions have profound guiding significance for wavelet decomposition-based short term prediction of wind speed.

**Key words:** wind speed prediction; wavelet decomposition; RBF neural network; time series; multi-step prediction

中图分类号: TK89 文献标识码: A 文章编号: 1674-3415(2014)08-0082-08

## 0 引言

风电作为一种可再生能源, 具有广阔的应用前景。随着我国经济发展以及能源结构的调整, 风力发电日益受到重视。尤其是近年来风力发电成本大幅度下降, 风电具有很强的发电竞争潜力。准确的风速预测可以使得电力调度部门及时调整计划, 减

少电力系统运行的成本和旋转备用, 确定合适的风电上网价格, 减小风电对电网的不利影响。然而目前风电场的风速预测效果还不尽人意, 提高其预测性能仍有很多问题需要解决<sup>[1]</sup>。

短期风速呈现非平稳随机特性, 风速建模预测的难度大。常规的短期预测方法主要包括: 神经网络法、时间序列法、卡尔曼滤波器法、支持向量机方法等等<sup>[2-6]</sup>。相比于风电场风速长期预测而言, 采用这些方法进行短期风速预测的效果并不是十分理想, 大大降低了风速预测结果的实用性。

**基金项目:** 高等学校博士学科点专项科研基金(20120036120013); 中央高校基本科研业务费(11MG49)

风速信号表现为典型的非平稳时间序列, 传统基于信号平稳性的预测方法, 难以达到满意的效果。针对风速时间序列的特点, 基于分解-合成的方法得到重视, 如一些学者提出经验模态分解与风速预测相结合的方法<sup>[7-8]</sup>, 也有一些学者提出小波分解理论与风速预测相结合的方法。如文献[5,9]运用神经网络和小波变换实现了短期风场的功率预测, 并与其他方法进行了比较。文献[10-11]运用小波包变换和支持向量回归相结合的方法实现风速的短期预测。文献[6,12]将小波多分辨分析理论与支持向量机理论结合进行风速的预测。文献[13]基于小波变换的风速数据, 结合多层感知器和群智能优化算法进行混合预测, 提高建模精度和预测能力。文献[14-15]利用小波变换作为时频局部化和多分辨特性分析的工具, 对风速信息成分进行逐渐精细的时域与频域处理, 达到了平滑原始风速时间序列以及有效地挖掘历史风速数据特性的目的, 得到了表征风速序列内在特性不同频段上的概貌风速与细节风速。以上文献都提高了风速预测精度, 然而对于小波分解的层数(一般采用 3 层分解)确定没有进行分析, 只是直接给出了分解层数, 没有分析小波分解层数和分量对多步预测的精度影响。

本文利用小波分解理论对时间序列进行分解, 得到时间序列的高频分量和低频分量。由于小波分解时层数的确定没有理论依据, 本文面向风力发电机组的控制应用, 目的是提高控制性能, 提高并网风电质量, 减少对电网的冲击和不利影响, 因此只进行小时级内的短期风速预测。针对该问题, 研究了小波分解层数与多步预测效果的关系。小波分解得到的高频分量, 一方面可以看成是趋势项, 另一方面也可以看成是干扰项(或噪声), 因此在利用分量进行预测的时候研究了三种分量组合: 全部高频-低频分量预测、部分高频-低频分量预测, 以及低频分量预测, 并进行了实验研究。对各分量的预测采用的是具有良好的学习和泛化能力的 RBF 神经网络。为此, 下面先简单介绍 RBF 神经网络和小波分解的基本理论。

## 1 基于 RBF 神经网络的多步预测

### 1.1 RBF 神经网络

RBF 神经网络<sup>[16-18]</sup>是由输入层、隐含层和输出层, 隐含层选取径向基函数作为激励函数, 它一般为高斯函数。其结构如图 1。

网络的输入向量  $\mathbf{x}$  为  $p$  维向量,  $\mathbf{x} = [x_{N-1}, x_{N-2}, \dots, x_{N-p}] \in R^p$ , 隐含层(径向基层)隐节点的

输出为

$$\phi_i(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_i\|^2}{\delta_i^2}\right), \quad 1 \leq i \leq n \quad (1)$$

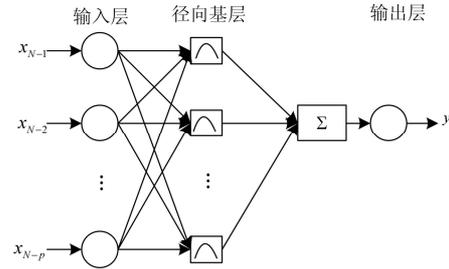


图 1 单个输出单元的 RBF 神经网络结构

Fig. 1 RBF neural network structure with single output

网络的输出为

$$y = f(\mathbf{x}) = w_0 + \sum_{i=1}^n w_i \phi_i(\mathbf{x}) \quad (2)$$

式中:  $\phi_i(\mathbf{x})$  为径向基函数, 一般取高斯基函数;  $\|\cdot\|$  为欧氏范数;  $\mathbf{c}_i = [c_{1i}, c_{2i}, \dots, c_{pi}]^T \in R^p$  为隐层第  $i$  个径向基函数的中心;  $\delta_i$  为径向基函数的宽度;  $w_0$  为偏置项;  $w_i$  为第  $i$  个基函数输出与输出节点的连接权值;  $n$  为隐层节点的数目。

确定 RBF 网络结构的基本原理: 从 1 个神经元开始训练, 依据输出误差自动增加网络的神经元。然后检查新网络的误差, 重复此过程直到误差满足要求或隐含层神经元数达到预置的最大值。

### 1.2 滚动式多步预测

滚动预测是传统而直观的多步预测策略。假定在进行  $H$  步超前预测时, 先利用训练好的神经网络预测模型进行一步超前预测, 然后将其预测值作为预测模型输入信号的一部分, 继续采用神经网络预测模型进行一步超前预测, 此时的预测值即为第二步超前预测值, 以此类推, 就可以得到  $H$  步超前预测值。记  $y = \hat{f}(\mathbf{x})$  为训练好的一步超前神经网络预测模型, 则  $h(h=1, 2, \dots, H)$  步超前滚动预测可表为

$$\hat{x}_{N+h} = \begin{cases} \hat{f}(x_N, \dots, x_{N-p+1}) & h = 1 \\ \hat{f}(\hat{x}_{N+h-1}, \dots, \hat{x}_{N+1}, x_N, \dots, x_{N-p+h}) & h \in \{2, \dots, p\} \\ \hat{f}(\hat{x}_{N+h-1}, \dots, \hat{x}_{N-p+h}) & h \in \{p+1, \dots, H\} \end{cases}$$

其中, 数据变量  $x$  带标记“ $\hat{\cdot}$ ”者表示预测值, 而不带标记者表示实测值。

由于不可避免的测量噪声等因素的存在而导致有预测误差。在多步滚动预测的过程中, 随着预测步数的增加预测误差也会增大, 因为滚动预测模型每一步产生的误差会不断向后传递, 导致误差累积。特别是当预测区间  $h$  超过模型的输入维数  $p$ , 即预

测模型的输入全部为预测值代替实测值时, 预测的效果更差。因此, 这种滚动式多步预测方法主要适用于短期甚至超短期的时间序列预测问题。对于短期的时间序列预测, 它在许多实际问题中获得了成功应用。

## 2 小波分解的基本理论

小波分析是在应用数学的基础上发展起来的新的时频分析工具, 近年来得到广泛应用。小波分析的核心思想是小波多分辨率分析, 其基本原理是通过小波基的伸缩变换, 研究信号各个尺度层次上的信息, 即在低频部分具有较高的频率分辨率和较低的时间分辨率, 而在高频部分则相反, 这正好符合低频信号变化慢和高频信号变化快的特点。

在小波分解方法中, 存在着两个问题: 一是小波函数的选取, 根据具体问题, 需要选取合适的小波。常见的小波函数有 Marr 小波、Morlet 小波、Haar 小波、Daubechies 小波和样条小波; 二是分解层数的确定, 小波分解的层数没有明确的理论依据。小波分解的层数越多, 信号的频率划分越细, 逼近信号和细节信号的稳定性和平滑性越好, 但是在分解过程中会存在计算误差和信息流失, 分解层数越多, 误差就会越大, 从而造成预测精度下降。

小波变换<sup>[19-21]</sup>用一个基函数的平移和伸缩来分解  $L^2(R)$  空间的函数。设基函数满足容许条件:

$$C_\varphi = \int \frac{|\bar{\varphi}^2(\omega)|}{\omega} d\omega < \infty \quad (3)$$

定义

$$\varphi(a, b) = \frac{1}{a} \varphi\left(\frac{t-b}{a}\right) \quad (4)$$

小波变换就是

$$Wf(a, b) = \int f \cdot \varphi(a, b) dt \quad (5)$$

小波变换的反变换, 即由  $Wf(a, b)$  重建  $f(t)$ 。

$$f(t) = C_\varphi^{-1} \int \int \frac{dadb}{a^2} Wf(a, b) \varphi(a, b) \quad (6)$$

在小波变换的算法中, Mallat 算法从函数的多分辨空间分解出发, 在小波变换与多分辨分析之间建立了联系, 并且提出了快速小波变换, 为小波变换的应用提供了一个有力的工具。Mallat 快速小波分解算法为

$$\begin{cases} (HC)_n = \frac{1}{\sqrt{2}} \sum_{j \in Z} C_j h_{j-2n} \\ (GC)_n = \frac{1}{\sqrt{2}} \sum_{j \in Z} C_j g_{j-2n} \end{cases} \quad (7)$$

Mallat 快速小波重构算法为

$$C_n^{k-1} = \frac{1}{\sqrt{2}} \left( \sum_{j \in Z} C_j^k h_{n-2j} + \sum_{j \in Z} d_j^k h_{n-2j} \right) \quad (8)$$

式(7)和式(8)的详细论述可参见文献[22]。

## 3 基于小波分解的风速预测策略

利用 Mallat 算法对风速时间序列作  $n$  层分解与重构。先将时间序列分解为低频分量  $c_1$  和 高频分量  $d_1$ ; 当对序列做进一步分解时, 只将低频分量  $c_1$  分解为  $c_2$  和  $d_2$ , 而对高频分量不予考虑, 后续分解以此类推, 得到低频分量  $c_1, c_2, \dots, c_n$  和 高频分量  $d_1, d_2, \dots, d_n$ 。理论上可以利用小波分析方法对数据长度为  $N$  的序列做  $\log_2^N$  次分解和重构, 一般对序列做 3 层分解就能将趋势项、波动项较好地分离出来<sup>[23-24]</sup>, 如图 2 所示。

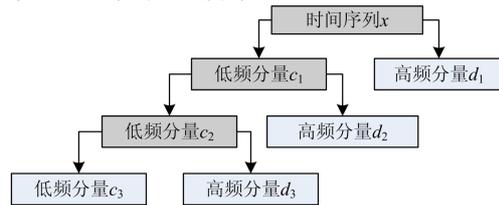


图 2 时间序列 3 层小波分解过程

Fig. 2 Three-layer wavelet decomposition for time series

本文基于一般的  $n$  层分解, 采用以下三种不同的预测策略:

(1) 全部高频-低频分量预测策略。基于小波分解的结果, 运用混沌理论确定低频分量预测模型的输入维为  $u_{cn}$  和 高频分量预测模型的输入维为  $u_{d1}, u_{d2}, \dots, u_{dn}$ 。对每个分量分别建立预测模型, 对每个分量进行预测, 然后将预测结果进行重构, 从而得到最终的预测值, 见图 3, 对于此项预测策略, 图 3 中的虚线全部连接。

(2) 部分高频-低频分量预测策略。基本原理和上述(1)相似, 不同之处在于选择部分高频分量和 低频分量进行建模和预测。对于此项预测策略, 见图 3, 对于此项预测策略, 图 3 中的虚线部分连接。

(3) 低频分量预测策略。对于此项预测策略, 图 3 中的虚线全部不连接, 即只对低频分量进行建模和预测。

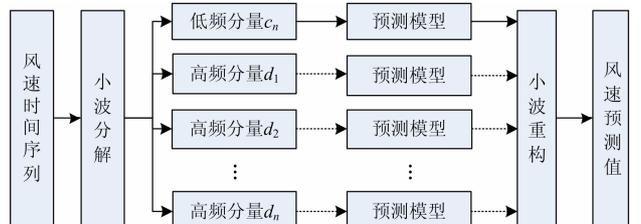


图 3 基于小波分解的风速预测策略

Fig. 3 Wind speed prediction strategy based on wavelet decomposition

经小波分解将风速时间序列分解为趋势项和干扰项, 其中趋势项平稳性强, 在预测过程中, 能够得到更准确的趋势预测; 干扰项的随机性较强, 在预测过程中, 预测难度比较大, 在提高预测精度方面的作用不是很强。全部高频-低频分量预测策略, 考虑全部分量的预测, 进行小波重构能够更加准确地还原时间序列。部分高频-低频分量预测策略剔除部分干扰项, 低频分量预测策略剔除了全部高频干扰项, 在小波重构过程中, 可以避免由于干扰项导致趋势预测效果差, 而使得最终的预测精度降低。当干扰项的预测误差大于干扰项在时间序列重构中的比重时, 采用低频预测策略可以获得较高的预测精度; 反之, 全部高频-低频分量预测策略或部分高频-低频分量预测策略获得较高的预测精度。

#### 4 实验结果及分析

采用 NIWA Client Report 的 STH1 和 CTY1 风电场<sup>[25]</sup>2003~2004年采样时间为 10 min 的风速数据(如图 4), 进行小波分解, 对分解分量分别建立预测模型。对 STH1 风场时间段 A、时间段 B 以及 CTY1 风场的时间段 C 分别进行测试, 以实现同一风场不同时间段以及不同风场预测结果之间的比较。在所有实验中, 用于 RBF 网络建模的数据长度为 5 000, 用于预测检验的数据长度为 1 000; 预测步数分别从 1 到 6, 即从 10 min 到 1 h 的超短期预测。小波的分解层数没有具体的依据, 仅能从经验获得一般小波分解层数为 3, 风速时间序列的 3 层小波分解效果如图 5。本文则对小波的分解层数进行了对比研究, 采用的分解层数分别为 1~5 层。每个分量采用 RBF 网络建模, 并建立相应的多步滚动式预测。基于前面提出的小波分解风速预测的三种思路, 预测实验根据预测分量从全部高频-低频分量、部分高频-低频分量, 以及低频分量的顺序进行研究; 并将实验结果与基于没有经过小波分解的原始时间序列直接预测的结果进行比较。

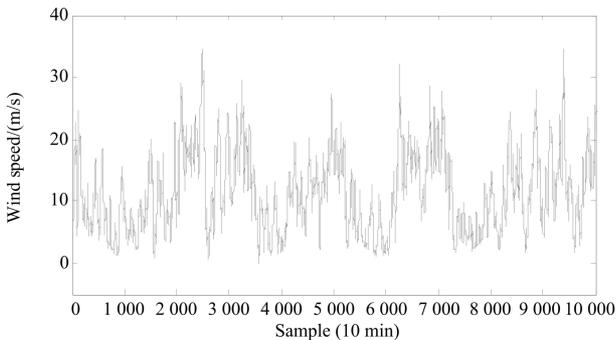


图 4 某风场 10 min 采样的风速数据

Fig. 4 Wind speed data of a wind farm sampled with 10 min

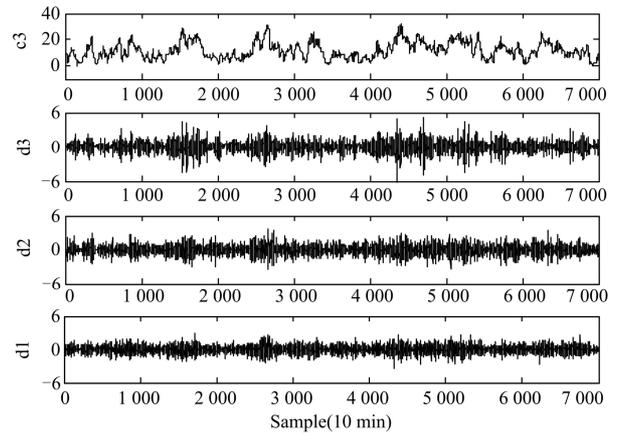


图 5 风速时间序列的 3 层小波分解结果

Fig. 5 Wavelet decomposition results of wind speed time series

实验结果如表 1~表 3 所示, 表 1、表 2、表 3 分别是 STH1 风场时间段 A、STH1 风场时间段 B 以及 STY1 风场时间段 C 的预测结果。表中分解层数为“0”则表示不分解。表中 MSE 和 MAE 分别表示均方误差(单位: m/s)和平均绝对误差(单位: m/s), 是经常被用来评价时间序列预测效果的性能标准<sup>[5]</sup>, 都属于绝对误差范畴, 分别定义如下。

$$MSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (x_t - \hat{x}_t)^2} \quad (9)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |x_t - \hat{x}_t| \quad (10)$$

式中:  $x_t$  表示实际值;  $\hat{x}_t$  表示预测值;  $N$  为预测预测检验的数据长度。

各表中不同小波分解层数的预测结果的最优 MSE 和 MAE 指标以黑体标示。从实验结果可看出, 在风速短期多步预测过程中, 小波分解的全部高频-低频分量组合在预测精度方面效果并不是很好; 而部分高频-低频分量的预测方法, 有效地提高了预测精度, 并且随着预测步数的增加, 分解的层数越多, 在剔除一定的高频分量后, 预测精度越高。同时, 传统 3 层小波分解并不能保证有效分解出趋势项和干扰项, 对于具体的分解层数以及剔除的高频分量, 要根据具体问题具体分析。通过对时间段 A、时间段 B 和时间段 C 的预测指标进行对比分析, 其最优指标呈现一定的规律, 进行小波 4 层分解就可达到 1-6 步预测较优的预测效果。用于预测的具体分量组合见表 4。从表 4 可看出, 实现最优预测的分量呈现一定的规律, 这就为小波分解在风速预测中的应用提供了指导。

表 1 STH1 风场预测的 MSE 和 MAE 指标(时间段 A)

Table 1 MSE and MAE index of data in STH1 wind farm (time range A)

分解层数	分解分量	预测步数及性能指标											
		1		2		3		4		5		6	
		MSE	MAE										
0	$x$	1.7522	1.2944	2.3512	1.7779	2.7891	2.1079	3.1469	2.3935	3.4146	2.5836	3.6184	2.7536
1	$c_1 d_1$	1.7556	1.2985	2.3966	1.8060	2.8641	2.1566	3.2663	2.4517	3.5591	2.6245	3.7806	2.7555
	$c_1$	<b>1.3686</b>	<b>1.0209</b>	<b>2.2300</b>	<b>1.6708</b>	<b>2.8081</b>	<b>2.0908</b>	<b>3.1773</b>	<b>2.3526</b>	<b>3.4674</b>	<b>2.5734</b>	<b>3.7204</b>	<b>2.7236</b>
2	$c_2 d_2 d_1$	1.7556	1.2985	2.3966	1.8060	2.8641	2.1566	3.2663	2.4517	3.5591	2.6245	3.7806	2.7555
	$c_2 d_2$	1.3686	1.0209	2.2300	1.6708	2.8081	2.0908	3.1773	2.3526	3.4674	2.5734	3.7204	2.7236
	$c_2$	<b>1.3639</b>	<b>1.0067</b>	<b>1.9214</b>	<b>1.4319</b>	<b>2.5000</b>	<b>1.8560</b>	<b>2.9954</b>	<b>2.2090</b>	<b>3.3858</b>	<b>2.4898</b>	<b>3.6811</b>	<b>2.6979</b>
3	$c_3 d_3 d_2 d_1$	1.7556	1.2985	2.3966	1.8060	2.8641	2.1566	3.2663	2.4517	3.5591	2.6245	3.7806	2.7555
	$c_3 d_3 d_2$	1.3686	1.0209	2.2300	1.6708	2.8081	2.0908	3.1773	2.3526	3.4674	2.5734	3.7204	2.7236
	$c_3 d_3$	<b>1.3639</b>	<b>1.0067</b>	<b>1.9214</b>	<b>1.4319</b>	<b>2.5000</b>	<b>1.8560</b>	<b>2.9954</b>	<b>2.2090</b>	<b>3.3858</b>	<b>2.4898</b>	<b>3.6811</b>	<b>2.6979</b>
	$c_3$	1.7851	1.3109	1.9842	1.4538	<b>2.2545</b>	<b>1.6546</b>	<b>2.5555</b>	<b>1.8837</b>	<b>2.8590</b>	<b>2.1148</b>	<b>3.1528</b>	<b>2.3373</b>
4	$c_4 d_4 d_3 d_2 d_1$	1.7556	1.2985	2.3966	1.8060	2.8641	2.1566	3.2663	2.4517	3.5591	2.6245	3.7806	2.7555
	$c_4 d_4 d_3 d_2$	1.3686	1.0209	2.2300	1.6708	2.8081	2.0908	3.1773	2.3526	3.4674	2.5734	3.7204	2.7236
	$c_4 d_4 d_3$	<b>1.3639</b>	<b>1.0067</b>	<b>1.9214</b>	<b>1.4319</b>	2.5000	1.8560	2.9954	2.2090	3.3858	2.4898	3.6811	2.6979
	$c_4 d_4$	1.7851	1.3109	1.9842	1.4538	<b>2.2545</b>	<b>1.6546</b>	2.5555	1.8987	2.8590	2.1148	3.1528	2.3373
	$c_4$	2.2147	1.6695	2.2752	1.7191	2.3708	1.7969	<b>2.4961</b>	<b>1.8837</b>	<b>2.6449</b>	<b>2.0167</b>	<b>2.8124</b>	<b>2.1461</b>
5	$c_5 d_5 d_4 d_3 d_2 d_1$	1.7556	1.2985	2.3966	1.8060	2.8641	2.1566	3.2663	2.4517	3.5591	2.6245	3.7806	2.7555
	$c_5 d_5 d_4 d_3 d_2$	1.3686	1.0209	2.2300	1.6708	2.8081	2.0908	3.1773	2.3526	3.4674	2.5734	3.7204	2.7236
	$c_5 d_5 d_4 d_3$	<b>1.3639</b>	<b>1.0067</b>	<b>1.9214</b>	<b>1.4319</b>	2.5000	1.8560	2.9954	2.2090	3.3858	2.4898	3.6811	2.6979
	$c_5 d_5 d_4$	1.7851	1.3109	1.9842	1.4538	<b>2.2545</b>	<b>1.6546</b>	2.5555	1.8987	2.8590	2.1148	3.1528	2.3373
	$c_5 d_5$	2.2147	1.6695	2.2752	1.7191	2.3708	1.7969	<b>2.4961</b>	<b>1.8837</b>	<b>2.6449</b>	<b>2.0167</b>	2.8124	<b>2.1461</b>
	$c_5$	2.5532	1.9111	2.5658	1.9302	2.5980	1.9683	2.6487	2.0209	2.7166	2.0858	<b>2.8000</b>	2.1602

表 2 STH1 风场预测的 MSE 和 MAE 指标(时间段 B)

Table 2 MSE and MAE index of data in STH1 wind farm (time range B)

分解层数	分解分量	预测步数及性能指标											
		1		2		3		4		5		6	
		MSE	MAE										
0	$x$	1.5135	1.1744	2.0641	1.5788	2.4592	1.8697	2.7322	2.1239	3.0018	2.3331	3.2363	2.5135
1	$c_1 d_1$	1.5167	1.1762	2.0933	1.6055	2.4944	1.8753	2.7676	2.1475	3.0562	2.3841	3.3123	2.5607
	$c_1$	<b>1.2097</b>	<b>0.9376</b>	<b>1.9585</b>	<b>1.5018</b>	<b>2.4293</b>	<b>1.8429</b>	<b>2.7174</b>	<b>2.0970</b>	<b>2.9822</b>	<b>2.3133</b>	<b>3.2453</b>	<b>2.4984</b>
2	$c_2 d_2 d_1$	1.5167	1.1762	2.0933	1.6055	2.4944	1.8753	2.7676	2.1475	3.0562	2.3841	3.3123	2.5607
	$c_2 d_2$	1.2097	0.9376	1.9585	1.5018	2.4293	1.8429	2.7174	2.0970	2.9822	2.3133	3.2453	2.4984
	$c_2$	<b>1.1992</b>	<b>0.9230</b>	<b>1.6858</b>	<b>1.2955</b>	<b>2.1818</b>	<b>1.6759</b>	<b>2.6082</b>	<b>2.0079</b>	<b>2.9423</b>	<b>2.2659</b>	<b>3.1952</b>	<b>2.4427</b>
3	$c_3 d_3 d_2 d_1$	1.5167	1.1762	2.0933	1.6055	2.4944	1.8753	2.7676	2.1475	3.0562	2.3841	3.3123	2.5607
	$c_3 d_3 d_2$	1.2097	0.9376	1.9585	1.5018	2.4293	1.8429	2.7174	2.0970	2.9822	2.3133	3.2453	2.4984
	$c_3 d_3$	<b>1.1992</b>	<b>0.9230</b>	1.6858	1.2955	2.1818	1.6759	2.6082	2.0079	2.9423	2.2659	3.1952	2.4427
	$c_3$	1.4808	1.1212	<b>1.6774</b>	<b>1.2665</b>	<b>1.9479</b>	<b>1.4827</b>	<b>2.2493</b>	<b>1.7148</b>	<b>2.5499</b>	<b>1.9384</b>	<b>2.8310</b>	<b>2.1359</b>
4	$c_4 d_4 d_3 d_2 d_1$	1.5167	1.1762	2.0933	1.6055	2.4944	1.8753	2.7676	2.1475	3.0562	2.3841	3.3123	2.5607
	$c_4 d_4 d_3 d_2$	1.2097	0.9376	1.9585	1.5018	2.4293	1.8429	2.7174	2.0970	2.9822	2.3133	3.2453	2.4984
	$c_4 d_4 d_3$	<b>1.1992</b>	<b>0.9230</b>	1.6858	1.2955	2.1818	1.6759	2.6082	2.0079	2.9423	2.2659	3.1952	2.4427
	$c_4 d_4$	1.4808	1.1212	<b>1.6774</b>	<b>1.2665</b>	<b>1.9479</b>	<b>1.4827</b>	2.2493	1.7148	2.5499	1.9384	2.8310	2.1359
	$c_4$	1.9672	1.4860	2.0252	1.5219	2.1095	1.5818	<b>2.2153</b>	<b>1.6592</b>	<b>2.3377</b>	<b>1.7543</b>	<b>2.4716</b>	<b>1.8559</b>
5	$c_5 d_5 d_4 d_3 d_2 d_1$	1.5167	1.1762	2.0933	1.6055	2.4944	1.8753	2.7676	2.1475	3.0562	2.3841	3.3123	2.5607
	$c_5 d_5 d_4 d_3 d_2$	1.2097	0.9376	1.9585	1.5018	2.4293	1.8429	2.7174	2.0970	2.9822	2.3133	3.2453	2.4984
	$c_5 d_5 d_4 d_3$	<b>1.1992</b>	<b>0.9230</b>	1.6858	1.2955	2.1818	1.6759	2.6082	2.0079	2.9423	2.2659	3.1952	2.4427
	$c_5 d_5 d_4$	1.4808	1.1212	<b>1.6774</b>	<b>1.2665</b>	<b>1.9479</b>	<b>1.4827</b>	2.2493	1.7148	2.5499	1.9384	2.8310	2.1359
	$c_5 d_5$	1.9672	1.4860	2.0252	1.5219	2.1095	1.5818	<b>2.2153</b>	<b>1.6592</b>	<b>2.3377</b>	<b>1.7543</b>	<b>2.4716</b>	<b>1.8559</b>
	$c_5$	2.2666	1.6936	2.2915	1.7126	2.3303	1.7457	2.3820	1.7887	2.4453	1.8391	2.5187	1.8998

表 3 STY1 风场预测的 MSE 和 MAE 指标(时间段 C)

Table 3 MSE and MAE index of data in STY1 wind farm (time range C)

分解层数	分解分量	预测步数及性能指标											
		1		2		3		4		5		6	
		MSE	MAE										
0	$x$	0.8712	0.6606	1.1255	0.8581	1.2908	0.9773	1.4423	1.1044	1.5630	1.2104	1.6562	1.2945
1	$c_1 d_1$	0.8836	0.6702	1.1430	0.8598	1.3000	0.9869	1.4505	1.1066	1.5627	1.2038	1.6432	1.2849
	$c_1$	<b>0.6880</b>	<b>0.5121</b>	<b>1.0562</b>	<b>0.7899</b>	<b>1.2676</b>	<b>0.9557</b>	<b>1.3894</b>	<b>1.0648</b>	<b>1.5061</b>	<b>1.1590</b>	<b>1.6151</b>	<b>1.2559</b>
2	$c_2 d_2 d_1$	0.8836	0.6702	1.1430	0.8598	1.3000	0.9869	1.4505	1.1066	1.5627	1.2038	1.6432	1.2849
	$c_2 d_2$	0.6880	0.5121	1.0562	0.7899	1.2676	0.9557	1.3894	1.0648	1.5061	1.1590	1.6151	1.2559
	$c_2$	<b>0.6371</b>	<b>0.4796</b>	<b>0.8366</b>	<b>0.6279</b>	<b>1.0715</b>	<b>0.8147</b>	<b>1.2869</b>	<b>0.9858</b>	<b>1.4566</b>	<b>1.1335</b>	<b>1.5743</b>	<b>1.2298</b>
3	$c_3 d_3 d_2 d_1$	0.8836	0.6702	1.1430	0.8598	1.3000	0.9869	1.4505	1.1066	1.5627	1.2038	1.6432	1.2849
	$c_3 d_3 d_2$	0.6880	0.5121	1.0562	0.7899	1.2676	0.9557	1.3894	1.0648	1.5061	1.1590	1.6151	1.2559
	$c_3 d_3$	<b>0.6371</b>	<b>0.4796</b>	<b>0.8366</b>	<b>0.6279</b>	1.0715	0.8147	1.2869	0.9858	1.4566	1.1335	1.5743	1.2298
	$c_3$	0.8253	0.6240	0.9103	0.6925	<b>1.0180</b>	<b>0.7812</b>	<b>1.1361</b>	<b>0.8801</b>	<b>1.2570</b>	<b>0.9789</b>	<b>1.3749</b>	<b>1.0718</b>
4	$c_4 d_4 d_3 d_2 d_1$	0.8836	0.6702	1.1430	0.8598	1.3000	0.9869	1.4505	1.1066	1.5627	1.2038	1.6432	1.2849
	$c_4 d_4 d_3 d_2$	0.6880	0.5121	1.0562	0.7899	1.2676	0.9557	1.3894	1.0648	1.5061	1.1590	1.6151	1.2559
	$c_4 d_4 d_3$	<b>0.6371</b>	<b>0.4796</b>	<b>0.8366</b>	<b>0.6279</b>	1.0715	0.8147	1.2869	0.9858	1.4566	1.1335	1.5743	1.2298
	$c_4 d_4$	0.8253	0.6240	0.9103	0.6925	<b>1.0180</b>	<b>0.7812</b>	1.1361	0.8801	1.2570	0.9789	1.3749	1.0718
	$c_4$	0.9583	0.7347	0.9828	0.7573	1.0224	0.7913	<b>1.0756</b>	<b>0.8368</b>	<b>1.1401</b>	<b>0.8882</b>	<b>1.2135</b>	<b>0.9446</b>
5	$c_5 d_5 d_4 d_3 d_2 d_1$	0.8836	0.6702	1.1430	0.8598	1.3000	0.9869	1.4505	1.1066	1.5627	1.2038	1.6432	1.2849
	$c_5 d_5 d_4 d_3 d_2$	0.6880	0.5121	1.0562	0.7899	1.2676	0.9557	1.3894	1.0648	1.5061	1.1590	1.6151	1.2559
	$c_5 d_5 d_4 d_3$	<b>0.6371</b>	<b>0.4796</b>	<b>0.8366</b>	<b>0.6279</b>	1.0715	0.8147	1.2869	0.9858	1.4566	1.1335	1.5743	1.2298
	$c_5 d_5 d_4$	0.8253	0.6240	0.9103	0.6925	<b>1.0180</b>	<b>0.7812</b>	1.1361	0.8801	1.2570	0.9789	1.3749	1.0718
	$c_5 d_5$	0.9583	0.7347	0.9828	0.7573	1.0224	0.7913	<b>1.0756</b>	<b>0.8368</b>	<b>1.1401</b>	<b>0.8882</b>	<b>1.2135</b>	<b>0.9446</b>
	$c_5$	1.1090	0.8590	1.1303	0.8701	1.1595	0.8876	1.1959	0.9147	1.2387	0.9473	1.2869	0.9820

表 4 不同风场不同时段的最佳预测分量比较

Table 4 Optimal components combination of different wind farm in different time ranges

数据来源	预测步数及最佳分量组合					
	1	2	3	4	5	6
STH1 时段 A	$c_4 d_4 d_3$	$c_4 d_4 d_3$	$c_4 d_4$	$c_4$	$c_4$	$c_4$
STH1 时段 B	$c_4 d_4 d_3$	$c_4 d_4$	$c_4 d_4$	$c_4$	$c_4$	$c_4$
CTY1 时段 C	$c_4 d_4 d_3$	$c_4 d_4 d_3$	$c_4 d_4$	$c_4$	$c_4$	$c_4$

## 5 结论

基于小波的信号分解-重构实现短期风速多步预测采用了三种策略:(1) 全部高频-低频分量预测;(2) 部分高频-低频分量预测;(3) 低频分量预测。研究了不同小波分解层数及不同分量组合的预测性能。通过实际数据预测实验得出以下结论:

(1) 针对短期风速多步预测, 全部高频-低频分量预测模型不能有效提高预测精度, 在风速时间序列趋势项与干扰项的提取上效果不是十分明显, 此种方法具有应用局限性。

(2) 部分高频-低频分量预测模型, 通过选择合适的部分高频分量和低频分量组合, 可以有效地提高多步预测的精度, 与全部高频-低频分量预测模型

相比, 效果明显。这主要是由于小波分解-重构过程中, 干扰项提取不完整, 使得高频分量扰动量大于扰动量预测误差, 因此剔除部分高频分量, 可以有效地改进预测结果。

(3) 在小波分解-重构过程中, 分解的层数以及剔除高频分量的个数并没有理论指导。根据经验, 一般选择分解层数为 3 层, 然而在实验中, 可以看出 3 层分解所得的结果并不是最优的解。在多步预测中, 增加分解层数可以提高预测精度。合适的分解层数以及在不同的多步预测中所剔除的高频分量, 一般呈现出一定的规律, 对于具体问题可以通过实验确定。但基于本文的实验结果, 我们可以得出如下的一般规律: 对于 1 步预测和 2 步预测, 基本可以进行 4 层分解, 最佳组合是低频  $c_4$  和高频  $d_3$ 、 $d_4$  分量; 对于 3 步预测, 基本可以进行 4 层分解, 最佳组合是低频  $c_4$  和高频  $d_4$  分量; 对于 4 步预测及其以上步数的预测, 基本可以进行 4 层分解, 最佳预测分量是只使用低频分量  $c_4$ 。以上结论可以这样解释: 预测步数越多, 主要趋势项越重要, 而高频分量由于包含更多的随机和干扰信息, 对于多步预测效果并不好。

## 参考文献

[1] 罗文, 王莉娜. 风场短期风速预测研究[J]. 电工技术学

- 报, 2011, 26(7): 68-74.
- LUO Wen, WANG Li-na. Short-term wind speed forecasting for wind farm[J]. Transactions of China Electrotechnical Society, 2011, 26(7): 68-74.
- [2] 冬雷, 王丽婕, 高爽, 等. 基于混沌时间序列的大型风电场发电功率预测建模与研究[J]. 电工技术学报, 2008, 23(12): 125-129.
- DONG Lei, WANG Li-jie, GAO Shuang, et al. Modeling and analysis of prediction of wind power generation in the large wind farm based on chaotic time series[J]. Transactions of China Electrotechnical Society, 2008, 23(12): 125-129.
- [3] 杨洪, 古世甫, 崔明东, 等. 基于遗传优化的最小二乘支持向量机风电场风速短期预测[J]. 电力系统保护与控制, 2011, 39(11): 44-48.
- YANG Hong, GU Shi-fu, CUI Ming-dong, et al. Forecast of short-term wind speed in wind farms based on GA optimized LS-SVM[J]. Power System Protection and Control, 2011, 39(11): 44-48.
- [4] 栗然, 陈倩, 徐宏锐. 考虑相关因素的最小二乘支持向量机风速预测方法[J]. 电力系统保护与控制, 2010, 38(21): 146-151.
- LI Ran, CHEN Qian, XU Hong-rui. Wind speed forecasting method based on LS-SVM considering the related factors[J]. Power System Protection and Control, 2010, 38(21): 146-151.
- [5] TURBELIN G, NGAË P, GRIGNON M. Wavelet cross-correlation analysis of wind speed series generated by ANN based models[J]. Renewable Energy, 2009, 34(4): 1024-1032.
- [6] LIU D, NIU D, WANG H, et al. Short-term wind speed forecasting using wavelet transform and support vector machines optimized by genetic algorithm[J]. Renewable Energy, 2014, 62(2): 592-597.
- [7] 刘兴杰, 米增强, 杨奇逊, 等. 一种基于 EMD 的短期风速多步预测方法[J]. 电工技术学报, 2010, 25(4): 165-170.
- LIU Xing-jie, MI Zeng-qiang, YANG Qi-xun, et al. A novel multi-step prediction for wind speed based on EMD[J]. Transactions of China Electrotechnical Society, 2010, 25(4): 165-170.
- [8] 王韶, 杨江平, 李逢兵, 等. 基于经验模式分解和神经网络的短期风速组合预测[J]. 电力系统保护与控制, 2012, 40(10): 6-11.
- WANG Shao, YANG Jiang-ping, LI Feng-bing, et al. Short-term wind speed forecasting based on EMD and ANN[J]. Power System Protection and Control, 2012, 40(10): 6-11.
- [9] CATALÃO J P S, POUSINHO H M I, MENDES V M F. Short-term wind power forecasting in Portugal by neural networks and wavelet transform[J]. Renewable Energy, 2011, 36(4): 1245-1251.
- [10] 陈盼, 陈皓勇, 叶荣, 等. 基于小波包和支持向量回归的风速预测[J]. 电网技术, 2011, 35(5): 177-182.
- CHEN Pan, CHEN Hao-yong, YE Rong, et al. Wind speed forecasting based on combination of wavelet packet analysis with support vector regression[J]. Power System Technology, 2011, 35(5): 177-182.
- [11] 彭春华, 刘刚, 孙惠娟. 基于小波分解和微分进化支持向量机的风电场风速预测[J]. 电力自动化设备, 2012, 32(1): 9-13.
- PENG Chun-hua, LIU Gang, SUN Hui-juan. Wind speed forecasting based on wavelet decomposition and differential evolution-support vector machine for wind farms[J]. Electric Power Automation Equipment, 2012, 32(1): 9-13.
- [12] 罗文, 王莉娜. 基于小波分解与遗传算法和支持向量机的短期风速预测[J]. 太阳能学报, 2012, 33(8): 1327-1333.
- LUO Wen, WANG Li-na. Short-term wind speed forecasting based on wavelet decomposition and genetic algorithm as well as support vector machine[J]. Acta Energiae Solaris Sinica, 2012, 33(8): 1327-1333.
- [13] LIU H, TIAN H, CHEN C, et al. An experimental investigation of two wavelet-MLP hybrid frameworks for wind speed prediction using GA and PSO optimization[J]. International Journal of Electrical Power & Energy Systems, 2013, 52: 161-173.
- [14] 陈德生. 基于小波变换的短期风速预测综合模型的研究 [D]. 长沙: 湖南大学, 2012.
- CHEN De-sheng. Study on integrated models of short-term wind speed forecasting based on wavelet transform[D]. Changsha: Hunan University, 2012.
- [15] LIU H, TIAN H, PAN D, et al. Forecasting models for wind speed using wavelet, wavelet packet, time series and artificial neural networks[J]. Applied Energy, 2013, 107: 191-208.
- [16] BILGILI M, SAHIN B, YASAR A. Application of

- artificial neural networks for the wind speed prediction of target station using reference stations data[J]. *Renewable Energy*, 2007, 32: 2350-2360.
- [17] SFETSOS A. A comparison of various forecasting techniques applied to mean hourly wind speed time series [J]. *Renewable Energy*, 2000, 21(1): 23-35.
- [18] SALCEDO-SANZ S, ORTIZ-GARCIA E G, PÉREZ-BELLIDO A M, et al. Short term wind speed prediction based on evolutionary support vector regression algorithms[J]. *Expert Systems with Applications*, 2011, 38(4): 4052-4057.
- [19] 孙延奎. 小波分析及其应用[M]. 北京: 机械工业出版社, 2005.
- SUN Yan-kui. *Wavelet analysis and its applications*[M]. Beijing: China Machine Press, 2005.
- [20] CHELLALI F, KHELLAF A, BELOUHRANI A. Wavelet spectral analysis of the temperature and wind speed data at Adrar, Algeria[J]. *Renewable Energy*, 2010, 35(6): 1214-1219.
- [21] MALLAT S G. A theory for multi-resolution signal decomposition: the wavelet representation[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 1989, 11(7): 674-693.
- [22] CHANG Y Q, Lü Z, WANG F L, et al. Soft sensing modeling based on stacked least square-support vector machine and its application[C] // *The Sixth World Congress on Intelligent Control and Automation*, 2006, 1: 4846-4850.
- [23] 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): 60-64.
- YANG Yan-xi, LIU Ding. Short term load forecasting based on wavelet transform and LS-SVM[J]. *Power System Technology*, 2005, 29(13): 60-64.
- [24] DU T, WANG X, WANG X. A combined model of wavelet and neural network for short term load forecasting[J]. *IEEE Trans on Power Systems*, 2002, 16(4): 2331-2335.
- [25] NIWA Client Report. Multi-year ten-minute synthetic wind speed time-series for 15 actual or proposed New Zealand wind farm[R]. New Zealand, 2009.
- 
- 收稿日期: 2013-07-25; 修回日期: 2013-09-24
- 作者简介:
- 王东风(1971-), 男, 博士, 教授, 从事热力系统建模、控制和故障诊断等方面的研究; E-mail: wangdongfeng@ncepubd.edu.cn
- 王富强(1983-), 男, 博士研究生, 从事风电场风速预测研究;
- 牛成林(1980-), 女, 博士, 讲师, 从事热力系统建模与控制研究。