

DOI: 10.7667/PSPC171217

基于小波与最小资源分配网络的超短期风电功率预测研究

杨杰¹, 霍志红¹, 何永生², 郭苏¹, 邱良², 许昌¹

(1. 河海大学能源与电气学院, 江苏 南京 211100; 2. 中国电建昆明勘测设计研究院有限公司, 云南 昆明 650051)

摘要: 针对风电场实际风速和风电功率序列的波动性、间歇性等特点以及 RBF 神经网络结构一旦确定隐节点个数就不可变等缺陷, 提出了基于小波分析和最小资源分配网络的超短期风电功率预测方法。首先将历史风速和风电功率序列进行小波去噪及多频分解, 得到多组高频信号和一组低频信号。然后对各频信号分别建立神经网络预测模型对未来 4 h 风电功率进行超短期预测。最后将各预测结果通过小波重构得到最终的超短期预测功率。实验结果证明, 该方法能有效提高预测精度。

关键词: 风电场; 神经网络; 小波分析; 最小资源分配网络; 超短期风电功率预测

Ultra-short-term wind power prediction based on wavelet and minimum resource allocation network

YANG Jie¹, HUO Zhihong¹, HE Yongsheng², GUO Su¹, QIU Liang², XU Chang¹

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China;

2. Power China Kunming Engineering Corporation Limited, Kunming 650051, China)

Abstract: Because the actual wind speed and wind power sequences are fluctuating, intermittent and the hidden node number of RBF neural network is unchangeable after the structure of RBF neural network is confirmed, a method of ultra-short-term wind power prediction based on wavelet and minimum resource allocation network is proposed. Firstly the historical wind speed and wind power sequences are denoised and multi frequency decomposed by wavelet transform, several high frequency signals and a low frequency signals are obtained. Then neural network prediction models of different frequency signals are built respectively to predict the wind power in the next 4 hours. Finally, the final ultra-short-term wind power prediction result is obtained from wavelet reconstruction of different components. The experimental results show that this method can effectively improve the prediction accuracy.

This work is supported by Sino-Dan International S & T Cooperation Program (No. 2014DFG62530), National Natural Science Foundation of China (No. 51507053), and Fundamental Research Funds for the Central Universities (No. 2017B42314).

Key words: wind farm; neural network; wavelet analysis; minimum resource allocation network; ultra-short-term wind power prediction

0 引言

近年来作为主要清洁能源的风电在我国飞速发展, 在电网中所占比重也越来越大^[1]。但由于风能具有波动性、间歇性和随机性等特点, 大规模的风电并网对电网安全稳定的运行和电能质量产生了不利影响, 同时近年来“三北”地区出现了严重的“弃

风限电”现象。准确的风电功率预测可以为电网运行调度提供可靠的依据和保障, 有利于电网和业主的经济效益最大化, 具有十分重要的实际应用价值, 为此有关学者在这方面做了大量的研究工作。

目前, 风电功率预测根据研究方法主要可以分为三种^[2]: 1) 物理方法。物理方法基于数值天气预报数据, 不需要风电场的历史运行数据, 适合新建风电场的预测。但预测精度受数值天气预报精度和周围地形因素影响较大, 同时因为数值天气预报更新频率低, 该方法不适合超短期风电功率预测^[3]。2) 统计方法。统计方法不需要求解物理方程, 计算

基金项目: 中丹国际科技合作专项项目资助(2014DFG62530); 国家自然科学基金项目资助(51507053); 中央高校基本科研业务费项目-科技发展前瞻性研究专项资助(2017B42314)

速度快, 预测精度高, 是当前风电功率预测领域主流的研究方法。统计方法主要有: 时间序列法^[4-6]、卡尔曼滤波法^[7-8]、神经网络法^[9-10]和支持向量机法^[11]等。其中, 神经网络学习规则简单, 对训练样本具有较强的自学习能力和非线性拟合能力, 是目前的主要研究热点之一, 本文选用 RBF 神经网络作研究。3) 空间相关性。随着物理方法和统计方法的研究日益成熟, 基于空间相关性的预测已成为继前两者之后的第三类研究方法^[12]。其主要通过不同空间位置处的风速或风电功率间的相关性特征, 通过物理或统计学方法, 建立合适的空间相关模型, 就可由若干已知区域的风速或风电功率预测未知区域的风速或风电功率^[13]。另外, 组合预测模型也在日益发展, 采用组合预测技术进行多种预测模型的互补优化, 降低单个模型的预测误差, 可以提高预测精度^[14]。

针对风电场实际风速和风电功率序列的波动性、间歇性等特点, 利用小波分析能去噪以及提取非线性、非平稳信号特征的能力, 对风速和风电功率序列进行去噪和多频分解, 可以获得多组高频信号和一组低频信号^[15]。针对 RBF 神经网络的隐节点个数不可变等缺陷, 可以引入最小资源分配网络对其改进^[16]。为此本文提出了采用小波分析和最小资源分配网络相结合的超短期风电功率预测方法, 并以西南某风电场为例进行验证, 对预测结果进行统计分析。

1 小波分析理论

为了克服傅里叶分析无法表述信号的时频局部性质的不足, 在傅里叶分析理论上发展出了小波分析^[17]。该算法具有多分辨率分析的特点, 在时域和频域都有表征信号局部信息的能力。小波变换分为连续小波变换和离散小波变换。

在小波分析中, $\psi(t)$ 为一个基本小波或母小波, 将母小波 $\psi(t)$ 做伸缩和平移得

$$\psi_{a,b}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad (1)$$

式中: $\psi_{a,b}(t)$ 为小波函数, 简称小波; a 为尺度因子; b 为平移因子。

对于 $f(t) \in L^2(\mathbb{R})$, 其连续小波变换为

$$WT_f(a,b) = |a_0|^{-\frac{m}{2}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (2)$$

式中: $a \neq 0$; b 、 t 为连续变量; $\psi^*(t)$ 为 $\psi(t)$ 的复共轭。

连续小波变换中的尺度因子和平移因子都是连续变化的实数, 在应用中需要计算连续积分, 在处理数字信号时很不方便。在实际问题的数值计算中常采用离散形式, 即离散小波变换(Discrete Wavelet Transform, DWT)。

将尺度因子 a 和平移因子 b 离散化, 即 $a=a_0^m$, $b=nb_0a_0^m$, 其中 $m, n \in \mathbb{Z}$ 代入式(1)中得到离散小波

$$\psi_{m,n}(t) = |a_0|^{-\frac{1}{2}} \psi(a_0^{-m}t - nb_0) \quad (3)$$

相应的离散小波变换为

$$WT_f(a,b) = |a_0|^{-\frac{m}{2}} \int_{-\infty}^{+\infty} f(t) \psi^*(a_0^{-m}t - nb_0) dt \quad (4)$$

小波变换通常将一个信号分解成一个低频信号和许多高频信号。小波重构是把通过分解得到的系数进行还原处理, 使之还原为原始信号。信号的分解与重构如图 1 所示, 图中 c_0 为原始信号, c_j 和 d_j 为分解出来的低频分量和高频分量, H 和 G 为一对互补的高低通滤波器, h 和 g 分别为其对偶算子。

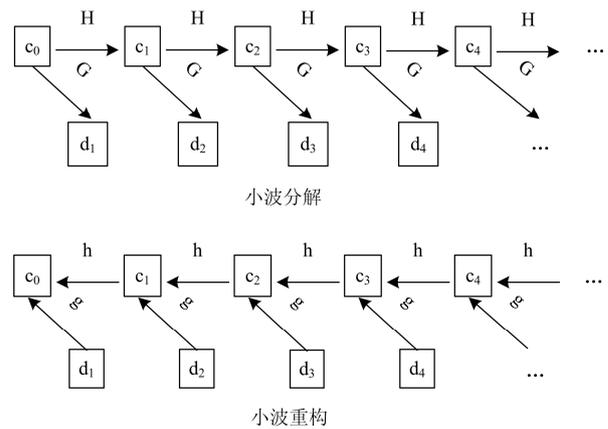


图 1 小波分解与重构示意图

Fig. 1 Diagram of wavelet decomposition and reconstruction

现实中的信号采集过程都伴随着高频随机噪声, 因此从噪声中恢复原始信号十分必要。当前, 小波去噪已成为信号去噪的主要方法之一, 小波去噪的基本方法有: 模极大去噪法, 小波系数相关性去噪法, 阈值去噪法等。

2 RBF 和 MRAN 神经网络

2.1 RBF 神经网络

径向基网络(RBF)是一种由输入层、隐含层和输出层构成的三层前馈式网络, 结构如图 2 所示。其具有拓扑结构紧凑、泛化能力强、收敛速度快和无局部极小点等优点^[18]。

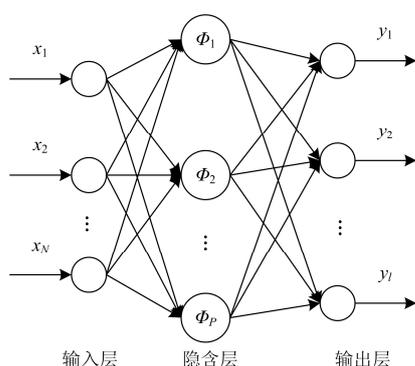


图2 RBF神经网络结构

Fig. 2 Structure of RBF neural network

2.2 最小资源分配网络(MRAN)

一般RBF网络隐节点数在学习开始后就不再变化, 经J. Platt^[19]、V. Kadirkamanathan和M. Niranjan^[20]改进为隐节点数在学习过程中可以按一定要求增加的资源分配网络(Resource Allocation Network, RAN)。Y. Lu^[21]改进了RAN的隐节点数只能增不能减的不足, 变为隐节点数也可按一定要求减少的最小资源分配网络(Minimal Resource Allocation Network, MRAN)。文献[16]将MRAN网络应用在电站锅炉预测氮氧化物中, 验证了该模型具有收敛速度快、隐节点自动调节和预测精度高等特点。文献[22]针对MRAN网络易过度估计网络误差和删减隐节点对网络结构影响大等缺点, 采用基于柯西误差函数的隐节点增删的判断依据, 验证了改进的MRAN预测精度略有提高、网络结构更加精简、预测速度显著提高。

3 基于小波与神经网络的预测模型

小波与神经网络预测模型流程图如图3所示。首先, 将历史风速序列和对应的风电功率序列利用

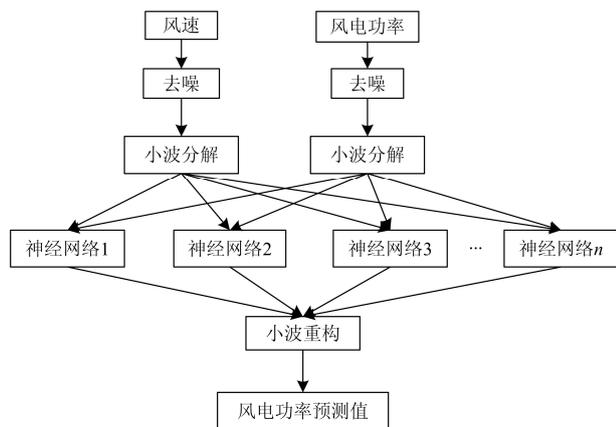


图3 预测模型的预测结构流程

Fig. 3 Prediction structure of the prediction model

小波对其去噪, 滤除扰动信号, 减小数据波动。其次, 将去噪后的风速序列和风电功率序列进行 n 层小波分解, 得到 n 个高频信号与一个低频信号。然后, 分别对不同频率上的风速和对应的风电功率建立神经网络模型, 并对未来4 h的风电功率进行预测。最后, 将各频率的风电功率预测结果通过小波重构得到最终的未来4 h的风电功率预测结果。

4 算例分析

4.1 数据来源及处理

本文算例中使用数据来自于中国西南某两个风电场, 风电场A装机容量为49.5 MW, 风电场B装机容量为40.5 MW, 共60台单机容量为1.5 MW的风力发电机组。以历史风速数据为输入量, 风电场输出的总功率为研究对象, 采样时间间隔为15 min, 选取风电场2015年12月的历史数据进行分析, 共有2496个样本数据。

首先, 对测风塔的气象数据和风机历史功率数据进行数据处理, 包括数据合理性分析、缺失数据的补充、错误数据订正等; 其次, 由于测风塔的气象数据不具有预测性, 通过大贤风格—能源气象平台获得测风塔处2015年12月70 m高度处的中尺度气象数据; 然后, 对中尺度数据与测风塔数据进行相关性分析, 根据相关性关系修正测风塔的风速数据使其时间上具有预测性; 最后, 结合风机历史功率数据建立样本数据。

本文选择 db_N 小波做去噪和多频分解, 引入皮尔逊积矩相关系数 R 作为选择 db_N 的评判标准。皮尔逊积矩相关系数是以两变量与各自平均值的离差为基础, 通过两个离差相乘来反映两变量之间的相关程度, 它的基本公式如式(5)所示。

$$R = \frac{\text{Cov}(X, Y)}{\sqrt{D(X)}\sqrt{D(Y)}} = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - E^2(X)}\sqrt{E(Y^2) - E^2(Y)}} \quad (5)$$

式中: $\text{Cov}(X, Y)$ 为变量 X 与 Y 之间的协方差; $D(X)$ 、 $D(Y)$ 为变量 X 、 Y 的方差; E 为变量的数学期望。

用 $N=2, 3, 4, 5$ 的 db_N 小波对2015年12月的风电功率进行3~6层分解, 并计算分解后的低频分量与实测数据的皮尔逊相关系数, 如表1所示。

当 $M \leq 5$ 时, 皮尔逊相关系数均大于0.9, 说明分解后的低频分量与实际数据具有很好的线性相关性; 当 $M=3$ 时, db_4 小波的 R 最大, 线性相关程度最好。故选取“ db_4 ”为母小波, 进行 $M=3$ 层分解。利用Matlab软件工具包对风速以及对应风电功率

表 1 皮尔逊相关系数

Table1 Pearson correlation coefficient

db _N	M			
	3	4	5	6
db ₂	0.980 0	0.956 7	0.918 6	0.834 7
db ₃	0.980 4	0.960 5	0.913 4	0.832 6
db ₄	0.981 4	0.965 3	0.912 4	0.842 2
db ₅	0.981 1	0.960 8	0.923 0	0.849 0

序列进行去噪处理, 根据对比发现当去噪等级为 1 级时, 风速以及对应风电功率序列变化更平滑同时细节损失小, 去噪前后对比如图 4 所示。风速和风电功率序列去噪前后有明显区别, 去噪前风速序列以及对应风电功率序列具有较强的波动性, 而通过小波去噪一定程度上消除了随机波动的噪声影响, 使风速序列和风电功率序列变得更为平滑, 同时去噪后的风速以及对应风电功率序列保持着原有序列的主要特性。

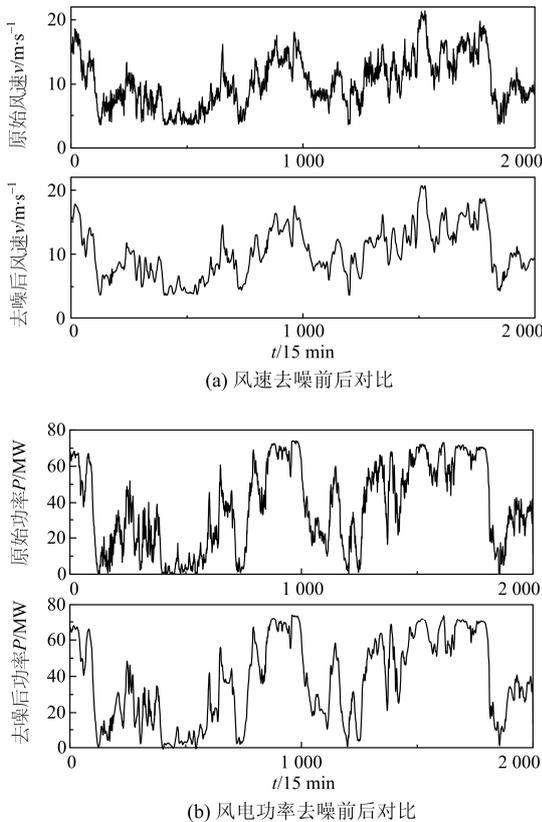


图 4 风速和风电功率去噪前后对比

Fig. 4 Comparison of wind speed and wind power before and after denoising

对去噪后的风速和对应风电功率序列进行 3 层分解, 分别得到一个低频信号 a_3 和三个高频信号 d_1 、 d_2 、 d_3 , 结果如图 5 所示。

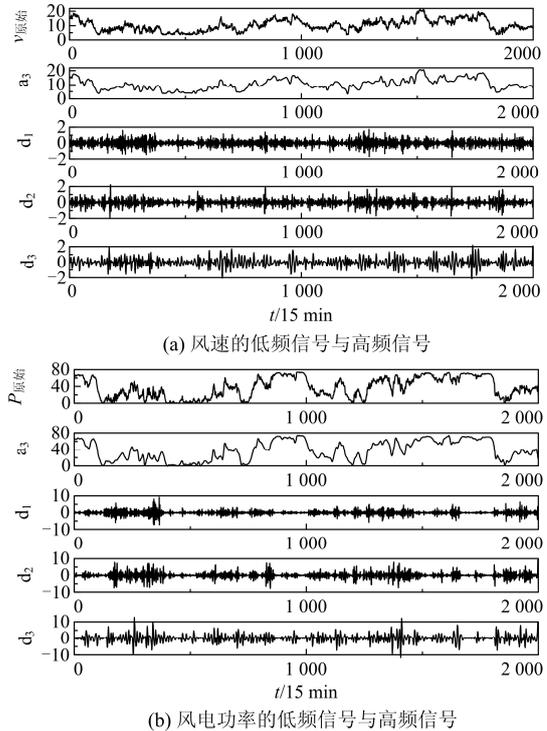


图 5 小波分解后风速和风电功率的低频信号与高频信号
Fig. 5 Low frequency and high frequency signals of wind speed and wind power after wavelet decomposition

对图 5 所示的不同频段的数据根据式(6)对样本数据进行归一化处理

$$b = \frac{a - a_{\min}}{a_{\max} - a_{\min}} \quad (6)$$

式中: a 为归一化前的值; b 为归一化后的值; a_{\max} 为某参数原始数据的最大值; a_{\min} 为某参数原始数据的最小值。

选取 2 020 个由风速和功率组成的归一化后的样本数据, 采用图 6 所示的数据结构, 由过去 $t_1=1$ h 的数据预测未来 $t_2=4$ h 的风电功率, 将其分成 2 000 组。其中学习样本为 1 550 组, 校验样本为 450 组, 每组数据间隔 15 min。

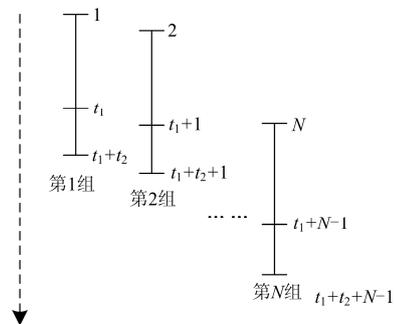


图 6 数据滚动预测结构
Fig. 6 Data rolling prediction structure

4.2 评价标准

本文参照《风电功率预测系统功能规范》NB/T 31046-2013 引入平均绝对误差 MAPE、均方根误差 RMSE 和合格率 Q 三个评价指标来衡量预测模型的效果, 各指标的表达式分别为

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left(\frac{|P_{mi} - P_{pi}|}{C_i} \right) \quad (7)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{|P_{mi} - P_{pi}|}{C_i} \right)^2} \quad (8)$$

$$Q = \frac{1}{n} \sum_{i=1}^n B_i \times 100\% \quad (9)$$

$$B_i = \begin{cases} 1, & (1 - \frac{|P_{mi} - P_{pi}|}{C_i}) \geq 0.75 \\ 1, & (1 - \frac{|P_{mi} - P_{pi}|}{C_i}) < 0.75 \end{cases} \quad (10)$$

式中: P_{mi} 为 i 时段的实际平均功率; P_{pi} 为 i 时段的预测功率; C_i 为 i 时段的开机总容量; n 为所有样本个数。

4.3 结果分析

本文分别建立了基于 RBF 神经网络与 MRAN 神经网络的两种预测模型, 并分别比较分析单个神经网络预测模型和基于小波与神经网络结合的预测模型的预测性能。表 2 为基于 RBF 和基于小波与 RBF 的两种预测模型的预测误差。

表 2 基于 RBF 和基于小波与 RBF 两种预测方法的误差

Table 2 Errors of two prediction models based on RBF and wavelet with RBF

预测模型	MAPE/%	RMSE/%	合格率/%
RBF	6.42	19.47	54.23
小波-RBF	8.59	14.23	92.44
小波-RBF-a3	1.79	6.69	96.67
小波-RBF-d1	0.29	1.44	99.56
小波-RBF-d2	0.40	1.50	99.78
小波-RBF-d3	0.51	1.86	99.33

从表 2 可以看到, 经过小波处理后的数据作为 RBF 神经网络的样本数据时, 数据波动得到改善, 预测误差减小; 而作为主要反映风电功率序列变化特征的低频信号的预测误差远小于重构后预测模型的预测误差, 这从侧面反映出高频信号分量对预测精度有较大的扰动。图 7 为采用 MRAN 神经网络的隐节点变化图, 表 3 为基于 MRAN 和基于小波与 MRAN 的两种预测模型的预测误差。

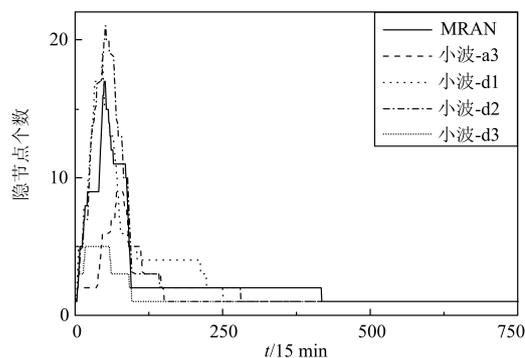


图 7 隐节点的变化

Fig. 7 Changes of hidden node

表 3 基于 MRAN 和基于小波与 MRAN 两种预测方法的误差

Table 3 Errors of two prediction methods based on MRAN and wavelet with MRAN

预测模型	MAPE/%	RMSE/%	合格率/%
MRAN	4.07	8.23	98.44
小波-MRAN	3.94	6.41	98.67
小波-MRAN-a3	2.81	4.42	99.78
小波-MRAN-d1	1.34	2.52	99.53
小波-MRAN-d2	2.71	4.42	99.78
小波-MRAN-d3	2.73	4.87	99.33

从表 3 可以看到, 经过小波处理后的数据作为 MRAN 神经网络的样本数据时, 预测误差较未经小波处理后的预测误差减小。从图 7 可以看到, 得益于 MRAN 神经网络的隐节点随着数据的输入可按特定规则自动增减, 网络结构更加精简, 泛化能力更强, 使得高频信号对预测模型产生的影响不是很大。因此, 基于 MRAN 神经网络的预测模型比基于 RBF 神经网络的预测模型具有更好的预测性能。

图 8 为基于 RBF、基于小波与 RBF、基于 MRAN 和基于小波与 MRAN 四种预测方法的预测结果比较。从图 8 可以看出基于 RBF 的风电功率预测值与实际风电功率值偏差较大, 当实际功率波动较大时预测精度大大下降; 而经过小波处理后的数据作为 RBF 神经网络的样本集时, 预测结果更加平滑, 能比较好地克服样本波动对预测精度的影响, 更好地追踪实际风电功率的变化规律。采用 MRAN 算法优化后的 RBF 神经网络预测模型, 由于隐节点可以自动增减, 使得网络结构更加精简, 泛化能力更强, 预测精度较 RBF 神经网络有显著提升。而基于小波与 MRAN 的预测模型, 由于数据经过小波去噪与多频分解, 消除了部分原始数据中的扰动噪声对预测模型精度的影响, 使得模型的预测精度相对基

于 MRAN 神经网络预测模型的预测精度略有提升。

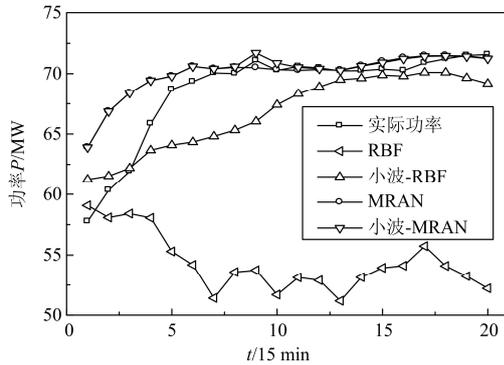


图 8 四种预测方法的预测结果

Fig. 8 Prediction results of four prediction methods

5 结论

本文提出了一种基于小波和 MRAN 神经网络的超短期风电功率预测方法。对风速序列和风电功率序列的非平稳特性,采用小波分析去噪和多尺度分解,得到一组低频信号和多组高频信号,分别对其建立神经网络预测模型,对未来 4 h 的风电功率进行预测,通过小波重构得到最终预测结果。通过实验发现,MRAN 神经网络较 RBF 神经网络结构更精简,收敛速度更快,预测精度更高;采用小波去噪及多频分解,能有效降低原始数据中噪声扰动对风电功率预测值的影响,预测精度得到了较好的提升。同时还发现预测模型的预测精度不仅仅与模型自身性能有关,很大程度上还受到样本数据中的高频信号扰动的影响。最后,本文通过实验验证了基于小波和最小资源分配网络的超短期风电功率预测方法的有效性。

参考文献

[1] 杨秀媛,肖洋,陈树勇. 风电场风速和发电功率预测研究[J]. 中国电机工程学报, 2005, 25(11): 1-5.
YANG Xiuyuan, XIAO Yang, CHEN Shuyong. Wind speed and generated power forecasting in wind farm[J]. Proceedings of the CSEE, 2005, 25(11): 1-5.

[2] 薛禹胜,郁琛,赵俊华,等. 关于短期及超短期风电功率预测的评述[J]. 电力系统自动化, 2015, 39(6): 141-151.
XUE Yusheng, YU Chen, ZHAO Junhua, et al. A review on short-term and ultra-short-term wind power prediction[J]. Automation of Electric Power Systems, 2015, 39(6): 141-151.

[3] 冯双磊,王伟胜,刘纯,等. 基于物理原理的风电场短期风速预测研究[J]. 太阳能学报, 2011, 32(5): 611-616.
FENG Shuanglei, WANG Weisheng, LIU Chun, et al.

Short term wind speed prediction based on physical principle[J]. Acta Energiæ Solaris Sinica, 2011, 32(5): 611-616.

[4] 田波,朴在林,郭丹,等. 基于改进 EEMD-SE-ARMA 的超短期风功率组合预测模型[J]. 电力系统保护与控制, 2017, 45(2): 72-79.
TIAN Bo, PIAO Zailin, GUO Dan, et al. Wind power ultra short-term model based on improved EEMD-SE-ARMA[J]. Power System Protection and Control, 2017, 45(2): 72-79.

[5] 杨茂,陈郁林. 基于 EMD 分解和集对分析的风电功率实时预测[J]. 电工技术学报, 2016, 31(21): 86-93.
YANG Mao, CHEN Yulin. Real-time prediction for wind power based on EMD and set pair analysis[J]. Transactions of China Electrotechnical Society, 2016, 31(21): 86-93.

[6] 陈昊,万秋兰,王玉荣. 基于厚尾均值广义自回归条件异方差族模型的短期风电功率预测[J]. 电工技术学报, 2016, 31(5): 91-98.
CHEN Hao, WAN Qiulan, WANG Yurong. Short-term wind power forecast based on fat-tailed generalized autoregressive conditional heteroscedasticity-in-mean type models[J]. Transactions of China Electrotechnical Society, 2016, 31(5): 91-98.

[7] 杨茂,黄宾阳. 基于灰色缓冲算子-卡尔曼滤波双修正的风电功率实时预测研究[J]. 可再生能源, 2017, 35(1): 101-109.
YANG Mao, HUANG Binyang. Wind power real-time prediction based on grey buffer operator-Kalman filter dual correction research[J]. Renewable Energy, 2017, 35(1): 101-109.

[8] 赵攀,戴义平,夏俊荣,等. 卡尔曼滤波修正的风电场短期功率预测模型[J]. 西安交通大学学报, 2011, 45(5): 47-51.
ZHAO Pan, DAI Yiping, XIA Junrong, et al. A Kalman filter based on correction model for short-term power prediction[J]. Journal of Xi'an Jiaotong University, 2011, 45(5): 47-51.

[9] 张颖超,王雅晨,邓华,等. 基于 IAFSA-BPNN 的短期风电功率预测[J]. 电力系统保护与控制, 2017, 45(7): 58-63.
ZHANG Yingchao, WANG Yachen, DENG Hua, et al. IAFSA-BPNN for wind power probabilistic forecasting[J]. Power System Protection and Control, 2017, 45(7): 58-63.

[10] LI Zhi, YE Lin, ZHAO Yongning, et al. Short-term wind power prediction based on extreme learning machine with error correction[J]. Protection and Control of

- Modern Power Systems, 2016, 1(1): 9-16. DOI: 10.1186/s41601-016-0016-y.
- [11] 柏丹丹, 和敬涵, 王小君, 等. 自适应粒子群支持向量机风速组合预测模型[J]. 太阳能学报, 2015, 36(4): 792-797.
BAI Dandan, HE Jinghan, WANG Xiaojun, et al. Combination model for forecasting wind speed based on adaptive PSO-SVM[J]. Acta Energiæ Solaris Sinica, 2015, 36(4): 792-797.
- [12] 薛禹胜, 陈宁, 王树民, 等. 关于利用空间相关性预测风速的评述[J]. 电力系统自动化, 2017, 41(10): 161-169.
XUE Yusheng, CHEN Ning, WANG Shumin, et al. Review on wind speed prediction based on spatial correlation[J]. Automation of Electric Power Systems, 2017, 41(10): 161-169.
- [13] 杨正瓴, 冯勇, 熊定方, 等. 基于季风特性改进风电功率预测的研究展望[J]. 智能电网, 2015, 3(1): 1-7.
YANG Zhengling, FENG Yong, XIONG Dingfang, et al. Research prospects of improvement in wind power forecasting based on characteristics of monsoons[J]. Smart Grid, 2015, 3(1): 1-7.
- [14] 马斌, 张丽艳, 郭成. 一种变权重风电功率最优组合预测模型[J]. 电力系统保护与控制, 2016, 44(5): 117-121.
MA Bin, ZHANG Liyan, GUO Chen. An optimal combination forecasting model with variable weight for wind power[J]. Power System Protection and Control, 2016, 44(5): 117-121.
- [15] 曹怀信, 郭志华. 小波分析基础[M]. 北京: 科学出版社, 2016: 48-163.
- [16] 许昌, 吕剑虹, 郑源. 最小资源分配网络及其在电站锅炉中的应用[J]. 中国电机工程学报, 2004, 24(11): 230-234.
XU Chang, LÜ Jianhong, ZHENG Yuan. Minimal resource allocation networks and application for a power station boiler[J]. Proceedings of the CSEE, 2004, 24(11): 230-234.
- [17] LIU Da, NIU Dongxiao, WANG Hui, et al. Short-term wind speed forecasting using wavelet transform and support vector machines optimized by genetic algorithm[J]. Renewable Energy, 2014, 62: 592-597.
- [18] SAIMERON M, ORTEGA J, PUNTONET C, et al. Improved RAN sequential prediction using orthogonal techniques[J]. Neuro-computing, 2001, 41(2): 153-172.
- [19] PLATT J. A resource allocating network for function interpolation[J]. Neural Computation, 1991, 3(2): 213-225.
- [20] KADIRKAMANATHAN V, NIRANJAN M. A function estimation approach to sequential learning with neural network[J]. Neural Computation, 1993, 5(6): 954-975.
- [21] LU Y, SUNDARARAJAN N, SARATCHANDRAN P. Performance evaluation of a sequential minimal radial basis function (RBF) learning algorithm[J]. IEEE Transactions on Neural Networks, 1998, 9(2): 308-318.
- [22] 魏媛, 郭颖, 许昌, 等. 最小资源分配网络在风电功率在线校正预测的应用[J]. 可再生能源, 2016, 34(3): 441-447.
WEI Yuan, GUO Ying, XU Chang, et al. Application on wind turbine power online correction prediction for minimum resource allocation[J]. Renewable Energy, 2016, 34(3): 441-447.

收稿日期: 2017-08-13; 修回日期: 2017-11-30

作者简介:

杨杰(1993—), 男, 硕士研究生, 研究方向为风电场功率预测; E-mail: 2539589098@qq.com

许昌(1972—), 男, 通信作者, 教授, 博导, 研究方向为风电场空气动力学和优化控制。E-mail: zhweifengxu@163.com

(编辑 张爱琴)