

基于小波分析法与滚动式时间序列法的风电场风速短期预测优化算法

刘辉, 田红旗, 李燕飞

(中南大学 交通运输工程学院, 轨道交通安全教育部重点实验室, 湖南 长沙, 410075)

摘要: 为实现风电场风速的超前多步高精度预测, 提出一种基于小波分析法与滚动式时间序列法混合建模的优化算法。该优化算法引入小波分析法对风电场实测非平稳风速序列进行分解重构计算, 将非平稳性原始风速序列转化为多层较平稳分解风速序列, 利用对传统时间序列分析法改进后的滚动式时间序列法对各分解层风速序列建立非平稳时序预测模型, 并通过模型方程实现超前多步滚动式预测计算。仿真结果表明: 该优化算法实现了风速的高精度短期多步预测, 将传统时间序列分析法对应超前1步、3步、5步的预测精度分别提高了54.22%, 26.44%和19.38%, 其预测的平均相对误差分别为1.14%, 3.06%和4.41%; 优化算法具有较强的细分与自学习能力。

关键词: 风速预测; 滚动式时间序列法; 小波分析法; 时间序列分析法; 优化算法

中图分类号: TK81

文献标志码: A

文章编号: 1672-7207(2010)01-0370-06

Short-term forecasting optimization algorithm for wind speed from wind farms based on wavelet analysis method and rolling time series method

LIU Hui, TIAN Hong-qi, LI Yan-fei

(Key Laboratory of Traffic Safety on Track, Ministry of Education, School of Traffic & Transportation Engineering, Central South University, Changsha 410075, China)

Abstract: In order to achieve high-precision multi-step ahead prediction for real-time wind speed data that sampled from wind farm, based on wavelet analysis method and rolling time series method, a forecast improved algorithm was proposed. Wavelet analysis method was used to make decomposition and reconstruction calculations for original wind speed series, and multi-layer more steady wind speed series was obtained. Then rolling time series method that was modified from traditional time series method was used to build unsteady prediction models for each layer, and corresponding equations were used to realize multi-step rolling forecast calculation. Simulation results show that the optimization algorithm attains high-precision multi-step ahead forecast results, improves forecast precision of one-step, three-step, five-step ahead forecast traditional time series method by 40.48%, 29.22%, 45.73%, respectively, and the mean relative error is only 1.72%, 3.61%, 7.12%, respectively. The optimization algorithm has respectively excellent subdivision and self-learning ability.

Key words: wind speed forecast; rolling time series method; wavelet analysis method; time series method; optimization algorithm

收稿日期: 2008-12-05; 修回日期: 2009-04-02

基金项目: 国家“十一五”科技支撑计划重点项目(2006BAC07B03); 国家留学基金资助项目(2009637066); 中南大学优秀博士学位论文扶植基金资助项目(CSU084201010)

通信作者: 刘辉(1983-), 男, 福建莆田人, 博士研究生, 从事列车空气动力学与降噪、风速预测、列车安全控制等研究; 电话: 13107428620; E-mail: liuhui8302@yahoo.com.cn

近年来, 风力发电作为一种新能源得到了世界各国的普遍重视, 发展异常迅速^[1]。在风力发电中, 较准确的未来风速预测结果对于电力部门预防瞬间极大风速对发电机组造成的冲击损害, 科学评价风能资源, 制定完善的发电调度计划, 衡量风电场的容量可信度和确定合适的风电上网价格具有重要的指导意义^[2-4]。同时, 风速预测结果也会影响未来新增风电机组的安装容量与安装位置。风速预测成为风电场规划设计中不可或缺的研究课题^[1]。风电场风速预测分为短期预测与中长期预测。短期预测一般为 10 h 以内的预测, 中长期预测一般为未来几天甚至几个月的预测^[2-4]。相对于中长期预测, 短期预测对所建模型的预测精度要求更高, 建模时间序列样本通常更加不平稳, 因此, 建模难度也更大。但随着风电项目的推广, 风电场风速短期预测成为亟待解决的关键课题^[3-4]。工程中常用的信号预测算法包括神经网络法、时间序列分析法、卡尔曼滤波法、遗传算法、灰色算法、小波分析法等^[2-17], 其中, 许多算法在电力领域的风电场风速短期预测研究^[2-6]和电力负荷预测研究^[7-13]中得到广泛应用。当前, 我国风电场风速短期预测研究水平不高, 存在的突出困难是所建模型无法实现超前多步预测或超前多步预测精度过低^[2-6]。造成这种现象的原因主要包括 2 个方面: (1) 所建模型自身获得的超前 1 步预测精度不高, 通过模型的多步迭代预测计算, 不断将上一步模型预测误差带入下一步计算, 使得获得的超前多步预测精度不断下降; (2) 所建模型的自学习能力较差, 无法根据最新的实测数据动态修正预测值或模型方程的关键参数。为此, 国内许多学者采用由几种预测算法混合建模的方法来提高模型的超前 1 步预测精度, 以求间接提高模型的超前多步预测精度^[2, 4, 13]。如杨秀媛等^[2]通过采用时间序列分析法与神经网络法混合建模的方法提高了所建模型的超前 1 步预测精度, 但是, 对模型的超前多步预测效果却没有进一步阐述, 同时, 神经网络法的黑箱性使得该混合算法无法获得预测模型显式方程, 难以在实际风速预警系统中应用。此外, 潘迪夫等^[4, 13]也没有系统地研究模型的超前多步预测问题。为此, 本文作者以我国某风电场为例, 研究风电场实测风速序列高精度超前 1 步和多步预测问题。从提高模型预测能力和提高模型自学习能力入手, 平衡考虑模型的预测精度和建模计算量, 提出基于小波分析法与滚动式时间序列法

混合建模的短期预测优化算法。该优化算法解决了非平稳时间序列在短期建模预测中普遍存在的超前多步预测精度低的难题。

1 优化算法建模原理

首先, 选择小波分析法的分解与重构算法对拟预测风速序列进行 n 层分解与重构计算, 实现将原始非平稳风速序列转化为多层较平稳风速序列。然后, 为使所建各层预测模型具备自学习功能, 利用提出的滚动式时间序列分析法对各层较平稳风速序列分别建立合适的时序预测模型。利用各层所建的时序预测模型对分解层风速序列进行超前多步预测计算。最终, 对各层风速预测值进行加权计算, 获取原始风速序列的预测值。

本文优化算法实现风速预测, 包括 3 个主要计算过程(如图 1 所示):

- (1) 将原始风速序列 $v(t)$ ($t=1, 2, 3, \dots$) 经小波分析法进行信号分解与重构, 分别获得高频风速序列 $v^n(t)$ ($n=1, 2, 3, \dots$) 和低频风速序列 $\omega(t)$;
- (2) 分别对序列 $v^n(t)$ ($n=1, 2, 3, \dots$) 和 $\omega(t)$ 运用滚动式时间序列法建模, 计算各分解层的超前 k 步预测值 $\hat{v}_i^n(k)$ 和 $\hat{\omega}_i(k)$ ($k=1, 2, 3, \dots$);
- (3) 对各分解层的超前 k 步预测值 $\hat{v}_i^n(k)$ 和 $\hat{\omega}_i(k)$ 进行加权计算, 输出最终风速预测值 $\hat{v}_i^n(k)$ 。

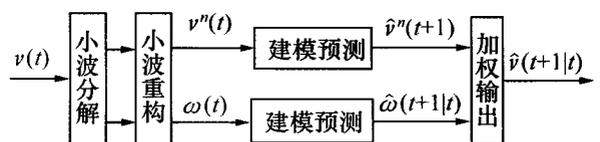


Fig.1 Calculation framework of prediction model

2 优化算法建模过程

运用本文提出的优化算法对我国某风电场测风站原始风速序列 $v(t)$ (每 3 min 测 1 个采样点) 进行建模与预测, 原始序列 $v(t)$ 如图 2 所示。取前 150 个数据建立预测模型, 后 50 个数据检验模型。由于电力系统指挥调度时间通常为 15 min, 因此, 本文重点研究非平稳风速超前 15 min (即超前 5 步) 预测。

2.1 小波分解与重构

选用 Daubechies 6 小波对原始序列 $v(t)$ 进行信号

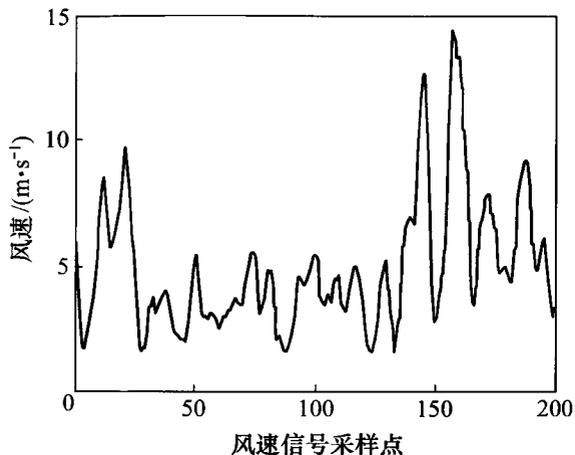


图 2 $v(t)$ 原始风速序列

Fig.2 $v(t)$ original wind speed series

分解, $n=3$ 。选用 Mallat 塔式算法对分解后的风速序列在不同尺度上进行信号重构。为了建模方便, 将第 1 层高频分量序列 $v^1(t)$ 记为序列 $\{X_{4t}\}$, 第 2 层高频分量序列 $v^2(t)$ 记为序列 $\{X_{3t}\}$, 第 3 层高频分量序列 $v^3(t)$ 记为序列 $\{X_{2t}\}$, 第 3 层低频分量序列 $\omega(t)$ 记为序列 $\{X_{1t}\}$ 。

2.2 滚动式时间序列法建模

2.2.1 滚动式算法设计

以第 3 层低频分量序列 $\{X_{1t}\}$ 为例, 说明滚动式时间序列法的算法计算步骤, 其他分解层风速序列的建模步骤可参照完成。取序列 $\{X_{1t}\}$ 前 150 个数据完成滚动式时间序列法建模, 并求出相对于采样点 $\{X_{1t}\}$ (150) 超前 3 步的预测风速 $\hat{X}'_{1t}(3)$, 具体算法计算步骤如下所示:

(1) 利用时间序列分析法对 $\{X_{1t}(1), X_{1t}(2), \dots, X_{1t}(150)\}$ 序列进行 Box-Jenkins 建模, 选择最小信息准则进行模型定阶, 选择矩估计进行模型参数估计。确定序列 $\{X_{1t}\}$ 前 150 个样本数据的合适模型为 ARIMA (6, 1, 0), 计算获得其对应的预测方程为:

$$X_1(t) = 2.754 0X_1(t-1) - 2.928 8X_2(t-2) + 1.767 4X_1(t-3) - 1.163 7X_1(t-4) + 1.035 4X_1(t-5) - 0.700 4X_1(t-6) + 0.236 2X_1(t-7) + a_t \quad (1)$$

利用模型方程(1)对风速序列 $\{X_{1t}\}$ 前 150 个样本数据进行超前 1 步预测迭代计算, 得到相对于采样点 $X_{1t}(150)$ 超前 1 步预测值 $\hat{X}'_{1t}(1)$ 。

(2) 保持步骤(1)所辨识的合适模型类别, 利用 $\{X_{1t}(2), X_{1t}(3), \dots, X_{1t}(200), \hat{X}'_{1t}(1)\}$ 序列对模型参数进行重新估计, 得到包含预测值 $\hat{X}'_{1t}(1)$ 信息特征的新

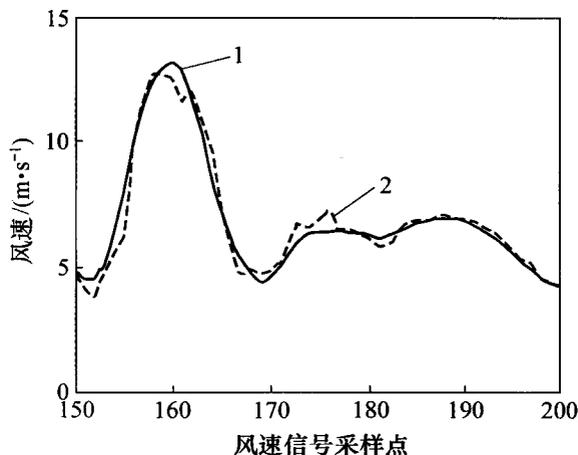
模型方程, 继续进行超前 1 步预测计算, 得到相对于采样点 $X_{1t}(150)$ 超前 2 步的预测值 $\hat{X}'_{1t}(2)$ 。

(3) 利用 $\{X_{1t}(3), X_{1t}(4), \dots, X_{1t}(200), \hat{X}'_{1t}(1), \hat{X}'_{1t}(2)\}$ 序列对模型重新参数估计, 得到包含预测值 $\hat{X}'_{1t}(1)$ 和 $\hat{X}'_{1t}(2)$ 信息特征的新模型方程, 继续进行超前 1 步预测, 得到相对于采样点 $X_{1t}(150)$ 超前 3 步的预测值 $\hat{X}'_{1t}(3)$ 。这就是滚动式时间序列法完成超前 3 步预测的 1 个完整计算周期。

(4) 当完成 1 个计算周期后, 再根据最新的实测风速序列重新开始滚动式预测计算, 获取采样点 $X_{1t}(151)$ 超前 3 步的预测值 $\hat{X}'_{1t}(3)$ 。

2.2.2 分解层风速序列滚动式预测

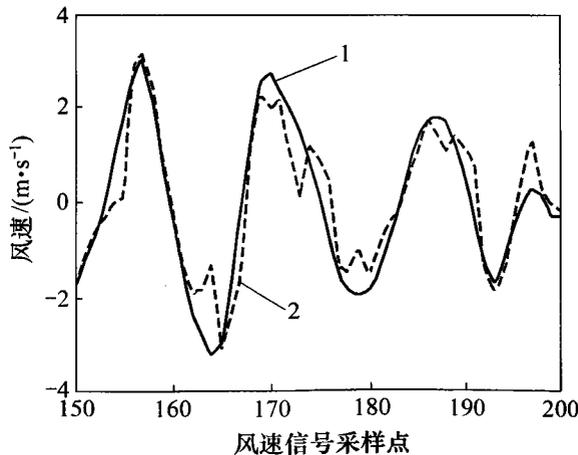
参考前面所述的滚动式时间序列法建模实例, 分别对序列 $\{X_{1t}\}, \{X_{2t}\}, \{X_{3t}\}$ 和 $\{X_{4t}\}$ 分别建立合适预测模型, 然后, 对各层风速序列的后 50 个数据依次进行超前 3 步预测计算, 结果如图 3~6 所示。



1—原始风速; 2—预测风速

图 3 $\{X_{1t}\}$ 序列超前 3 步预测结果

Fig.3 Three-step ahead forecasting results of $\{X_{1t}\}$ series



1—原始风速; 2—预测风速

图 4 $\{X_{2t}\}$ 序列超前 3 步预测结果

Fig.4 Three-step ahead forecasting results of $\{X_{2t}\}$ series

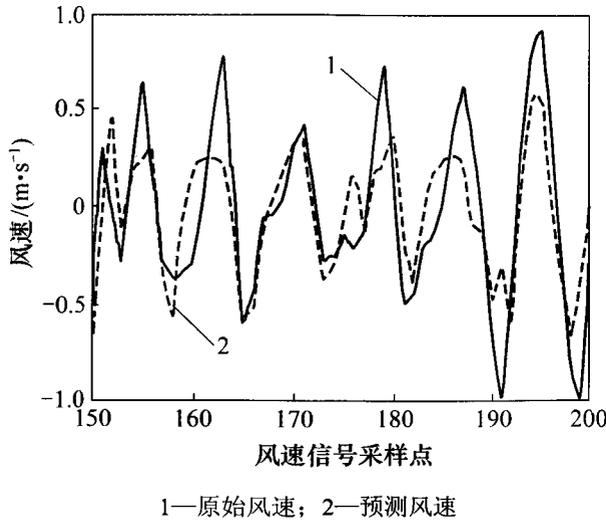


图5 $\{X_{3t}\}$ 序列超前3步预测结果

Fig.5 Three-step ahead forecasting results of $\{X_{3t}\}$ series

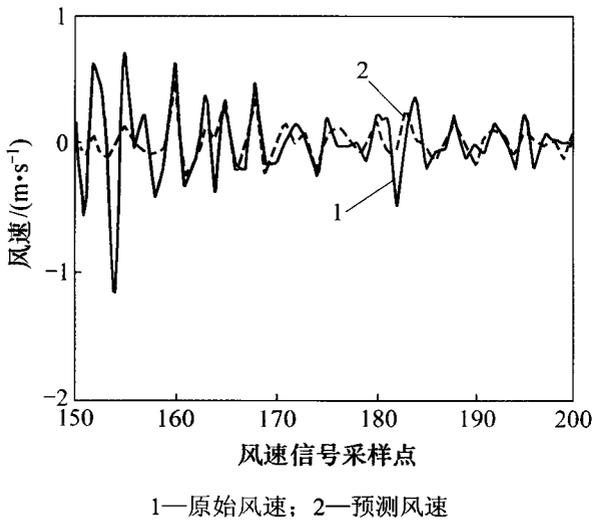


图6 $\{X_{4t}\}$ 序列超前3步预测结果

Fig.6 Three-step ahead forecasting results of $\{X_{4t}\}$ series

2.3 各分解层预测结果加权计算

当完成各分解层风速序列的预测计算后, 根据式(2), 对原始风速序列 $v(t)$ 后 50 个数据的超前 3 步预测值 $\hat{v}_i(3)$ 依次进行加权计算。本文取加权系数 $\rho_1 = \rho_2 = \rho_3 = 1$, 加权预测结果如图 7 所示。

同理, 依次分别计算原始序列 $v(t)$ 后 50 个数据的超前 1 步预测值 $\hat{v}_i(1)$ 、超前 5 步预测值 $\hat{v}_i(5)$, 结果如图 8 和图 9 所示。

$$\hat{v}_i(3) = \rho_1 \hat{X}_{1t}(3) + \rho_2 \hat{X}_{2t}(3) + \rho_3 \hat{X}_{3t}(3) + \rho_4 \hat{X}_{4t}(3) \quad (2)$$

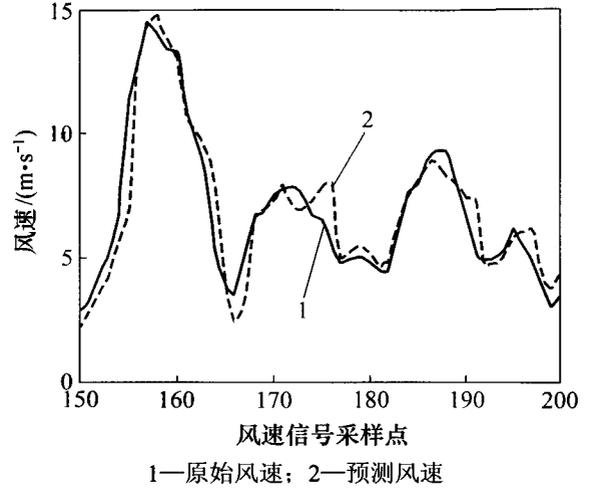


图7 $v(t)$ 序列超前3步预测结果

Fig.7 Three-step ahead forecasting results of $v(t)$ series

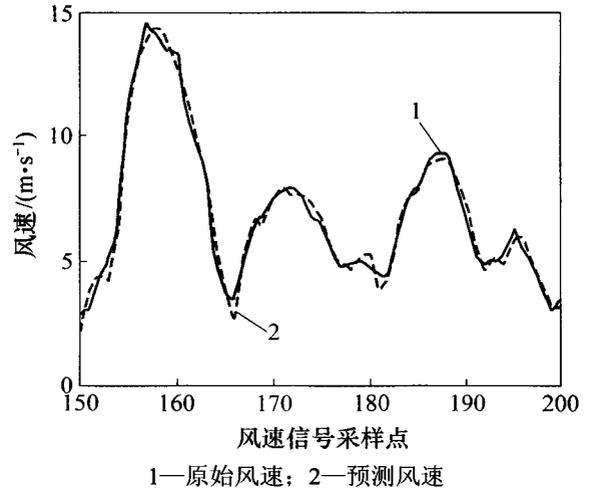


图8 $v(t)$ 序列超前1步预测结果

Fig.8 One-step ahead forecasting results of $v(t)$ series

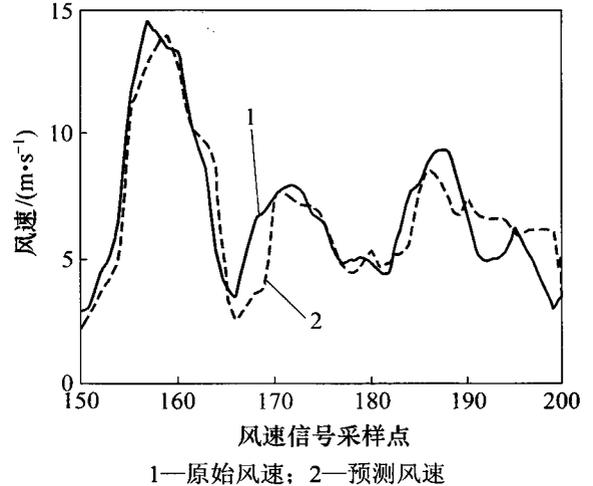


图9 $v(t)$ 序列超前5步预测结果

Fig.9 Five-step ahead forecasting results of $v(t)$ series

3 优化算法预测结果分析

采用平均误差 σ_1 、平均绝对误差 σ_2 、平均相对误差 σ_3 和均方根误差 σ_4 4 个预测精度评价指标对如图 7~9 所示预测结果进行评估, 式(3)~(6)为评价指标计算公式, 计算结果如表 1 所示。

表 1 优化算法预测结果

Table 1 Forecasting results by optimization algorithm

参数	优化算法		
	1 步	3 步	5 步
$\sigma_1/(\text{m}\cdot\text{s}^{-1})$	0.002 4	0.065 0	0.131 8
$\sigma_2/(\text{m}\cdot\text{s}^{-1})$	0.305 6	0.692 1	0.956 8
$\sigma_3/\%$	1.14	3.06	4.41
$\sigma_4/(\text{m}\cdot\text{s}^{-1})$	0.187 4	0.545 5	0.655 6

(1) 平均误差:

$$\sigma_1 = \frac{1}{N} \sum_{i=1}^N [X(i) - \hat{X}(i)] \quad (3)$$

(2) 平均绝对误差:

$$\sigma_2 = \frac{1}{N} \sum_{i=1}^N |X(i) - \hat{X}(i)| \quad (4)$$

(3) 平均相对误差:

$$\sigma_3 = \frac{1}{N} \sum_{i=1}^N \left| \frac{X(i) - \hat{X}(i)}{X(i)} \right| \quad (5)$$

(4) 均方根误差:

$$\sigma_4 = \sqrt{\frac{1}{N} \sum_{i=1}^N [X(i) - \hat{X}(i)]^2} \quad (6)$$

为了进一步显示所提出优化算法的良好性能, 利用传统的时间序列分析法直接对原始序列 $v(t)$ 的同一段风速样本进行建模, 然后, 分别进行超前 1 步、3 步、5 步预测计算, 其精度评价结果如表 2 所示。表 3 所示为优化算法相对于时间序列分析法的预测精度提高率。

通过分析表 1~3 可知: 优化算法所建模型的各项预测评价指标值均优于传统时间序列分析法的对应指标值。以模型超前 5 步预测为例, 模型平均误差下降 52.95%, 平均绝对误差下降 30.08%, 平均相对误差下降 19.38%, 均方根误差下降 40.61%。优化算法的超

表 2 时间序列分析法预测结果

Table 2 Forecasting results by time series method

参数	时间序列法		
	1 步	3 步	5 步
$\sigma_1/(\text{m}\cdot\text{s}^{-1})$	0.014 9	0.074 7	0.280 1
$\sigma_2/(\text{m}\cdot\text{s}^{-1})$	0.564 8	0.957 7	1.368 5
$\sigma_3/\%$	2.49	4.16	5.47
$\sigma_4/(\text{m}\cdot\text{s}^{-1})$	0.451 5	0.656 4	1.103 9

表 3 优化算法相对于时间序列分析法的预测精度提高率

Table 3 Percentage table of forecast precision improved by optimization algorithm

参数	预测精度提高率/%		
	1 步	3 步	5 步
σ_1	83.89	12.99	52.95
σ_2	45.89	27.73	30.08
σ_3	54.22	26.44	19.38
σ_4	58.49	16.89	40.61

前 5 步预测平均相对误差仅为 4.41%, 完全满足工程运用中通常不超过 5% 的高精度要求, 而传统时间序列分析法超前 5 步预测的平均相对误差达 5.47%。

4 结论

(1) 提出基于小波分析法与滚动式时间序列法的预测优化算法, 在很大程度上解决了风电场风速的较高精度短期超前多步预测难题。该优化算法吸收了小波分析法的细分功能, 方便地将非平稳原始风速转化为多层较平稳风速, 其平稳化处理效果比传统的差分处理法好。

(2) 优化算法所包含的滚动式时间序列法具备强大的自学习能力, 使得优化算法兼顾传统时间序列分析法建模简单的优点。

(3) 优化算法具备强大的细分和自学能力, 对风速跳跃点的追踪能力强, 实现了高精度的超前 1 步和多步预测。但是, 随着超前步数的增大, 优化算法提高预测精度的能力也依次降低, 符合超前步数越大、高精度预测难度也越大的客观事实。

(4) 优化算法与其他算法如时间序列分析法相比, 其混合建模过程没有明显增加计算难度和计算量, 通过借助相关高级语言, 容易编程实现其优化计算, 在工程中能够实时地获得超前风速预报值, 可在相关

风速预警系统中推广使用。

参考文献:

- [1] 谢建民, 邱毓昌. 大型风力发电场选址与风力发电机优化匹配[J]. 太阳能学报, 2001, 22(4): 466-472.
XIE Jian-min, QIU Yu-chang. Siting of large windfarm and optimum wind turbine-site matching[J]. Acta Energiæ Solaris Sinica, 2001, 22(4): 466-472.
- [2] 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 Xiu-yuan, XIAO Yang, CHEN Shu-yong. Wind speed forecast model for wind farms based on time series analysis[J]. Proceedings of the CSEE, 2005, 25(11): 1-5.
- [3] 丁明, 张立军, 吴义纯. 基于时间序列分析的风电场风速预测模型[J]. 电力自动化设备, 2005, 25(8): 32-34.
DING Ming, ZHANG Li-jun, WU Yi-chun. Wind speed forecast model for wind farms based on time series analysis[J]. Electric Power Automation Equipment, 2005, 25(8): 32-34.
- [4] 潘迪夫, 刘辉, 李燕飞. 基于时间序列分析和卡尔曼滤波算法的风电场风速预测优化模型[J]. 电网技术, 2008, 32(7): 82-86.
PAN Di-fu, LIU Hui, LI Yan-fei. A wind forecasting optimization model for wind farms based on time series analysis and Kalman filter algorithm[J]. Power System Technology, 2008, 32(7): 82-86.
- [5] Billinton R, CHEN Hua, Ghajar R. Time-series models for reliability evaluation of power systems including wind energy[J]. Microelectronics and Reliability, 1996, 36(9): 1253-1261.
- [6] Fonte P M, Silva G X, Quadrado J C. Wind speed prediction using artificial neural networks[J]. WSEAS Transactions on Systems, 2005, 4(4): 379-383.
- [7] 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): 5-10.
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): 5-10.
- [8] 吴宏晓, 侯志俭, 刘涌. 基于免疫聚类径向基函数网络模型的短期负荷预测[J]. 中国电机工程学报, 2005, 25(16): 53-56.
WU Hong-xiao, HOU Zhi-jian, LIU Yong. A short-term load forecasting approach based on immune clustering RBF network model[J]. Proceedings of the CSEE, 2005, 25(16): 53-56.
- [9] 陶文斌, 张粒子, 潘弘. 基于双层贝叶斯分类的空间负荷预测[J]. 中国电机工程学报, 2007, 27(7): 13-17.
TAO Wen-bin, ZHANG Li-zi, PAN Hong. Spatial electric load forecasting based on double-level bayesian classification[J]. Proceedings of the CSEE, 2007, 27(7): 13-17.
- [10] 金群, 李欣然. 遗传算法参数设置及其在负荷建模中的应用[J]. 电力自动化设备, 2006, 26(5): 23-27.
JIN Qun, LI Xin-ran. GA parameter setting and its application in load modeling[J]. Electric Power Automation Equipment, 2006, 26(5): 23-27.
- [11] 邵能灵, 侯志俭, 李涛, 等. 基于小波分析的电力系统短期负荷预测方法[J]. 中国电机工程学报, 2003, 23(1): 45-50.
TAI Neng-ling, HOU Zhi-jian, LI Tao, et al. New principle based on wavelet transform for power system short-term load forecasting[J]. Proceedings of the CSEE, 2003, 23(1): 45-50.
- [12] 崔旻, 顾洁. 电力系统中长期负荷预测的改进决策树算法[J]. 上海交通大学学报, 2004, 38(8): 1246-1250.
CUI Min, GU Jie. Improved decision tree method for mid-long term load forecasting of power system[J]. Journal of Shanghai Jiaotong University, 2004, 38(8): 1246-1250.
- [13] 袁明友, 肖先勇, 杨洪耕, 等. 基于灰色理论的供电系统负荷中长期预测模型及其应用[J]. 四川大学学报: 工程科学版, 2002, 34(4): 121-123.
YUAN Ming-you, XIAO Xian-yong, YANG Hong-geng, et al. The grey model of middle-long term load forecasting and its applications in the power supplying systems[J]. Journal of Sichuan University: Engineering Science Edition, 2004, 34(4): 121-123.
- [14] 徐科, 徐金梧, 班晓娟. 基于小波分解的某些非平稳时间序列预测方法[J]. 电子学报, 2001, 29(4): 566-568.
XU Ke, XU Jin-wu, BAN Xiao-juan. Forecasting of some non-stationary time series based on wavelet decomposition[J]. Acta Electronica Sinica, 2001, 29(4): 566-568.
- [15] 王军, 彭喜元, 彭宇. 一种新型复杂时间序列实时预测模型研究[J]. 电子学报, 2006, 34(12A): 2391-2394.
WANG Jun, PENG Xi-yuan, PENG Yu. A novel real time predictor for complex time series[J]. Acta Electronica Sinica, 2006, 34(12A): 2391-2394.
- [16] 邵拥军, 贺辉, 张贻舟, 等. 基于BP神经网络的湘西金矿成矿预测[J]. 中南大学学报: 自然科学版, 2007, 38(6): 1192-1198.
SHAO Yong-jun, HE Hui, ZHANG Yi-zhou, et al. Metallogenic prediction of Xiangxi gold deposit based on BP neural networks[J]. Journal of Central South University: Science and Technology, 2007, 38(6): 1192-1198.
- [17] 宋海鹰, 桂卫华, 阳春华, 等. 基于核偏最小二乘法的动态预测模型在铜转炉吹炼中的应用[J]. 中国有色金属学报, 2007, 17(7): 1201-1206.
SONG Hai-ying, GUI Wei-hua, YANG Chun-hua, et al. Application of dynamical prediction model based on kernel partial least squares for copper converting[J]. The Chinese Journal of Nonferrous Metals, 2007, 17(7): 1201-1206.

(编辑 刘华森)