

基于虚拟预测与小波包变换的风电功率组合预测

孟安波, 陈育成

(广东工业大学, 广东 广州 510006)

摘要: 为了提高风电功率的预测精度, 针对风机功率不稳定性和非线性强的特点, 使用小波包变换将风机出力分解成多个频率的子序列, 然后运用组合预测方法分别对各子序列进行提前 24 h 预测, 叠加各子序列的预测值, 得出实际预测结果。其中组合预测方法权系数是通过虚拟预测的方法由方差倒数法确定。选择广东某风电场实测数据作为案例, 对连续 7 天风电功率进行了预测。结果表明: 小波包变换能有效把握风电功率变化规律, 对小波包变换后的各子序列的预测结果表明组合预测效果优于单一预测方法。

关键词: 风电功率; 虚拟预测; 小波包变换; 方差倒数法; 组合预测

Wind power combination forecasting based on wavelet packet transform and virtual forecasting method

MENG An-bo, CHEN Yu-cheng

(Guangdong University of Technology, Guangzhou 510006, China)

Abstract: Considering the instability and strong nonlinearity of wind power, in order to improve the accuracy of wind power forecasting, the original wind power sequence is decomposed into a series of sub-sequences. Then each sequence is forecasted 24 h ahead by combination forecasting model. And the weight coefficients of each sequence are identified using variance reciprocal method through a virtual forecasting method. Consequently, all the subsequence forecasting outputs are superposed to obtain the final forecasted results. At the end, a wind farm in Guangdong is chosen to validate the feasibility of the proposed model. Through seven consecutive days of forecasting of the wind power, the results indicate that the wavelet packet transform can grasp the variation law of wind power effectively, and the combination forecasting method can obtain a better forecasting result than single method.

Key words: wind power; virtual forecasting; wavelet packet transform; variance reciprocal method; combination forecasting

中图分类号: TM619 文献标识码: A 文章编号: 1674-3415(2014)03-0071-06

0 引言

目前全球风电接入量逐年增加, 但因风电的间歇性和随机性强的特点, 其大规模并入电网以后对电网调度和安全运行带来困难^[1-2]。风电功率预测使电力调度部门能提前根据风电功率及时调整调度计划, 保证电能质量, 减少系统的备用容量, 降低运行成本。因此提高风电功率预测的精度具有重要意义。

在预测方法中, 持续法简单快捷, 但时效较长时预测精度有限, 无法满足实际需要, 常作为评价标准用于与新提出的算法比较。时间序列法是目前得到广泛应用的一种预测方法, 文献[3]通过巧妙的

数据选取, 利用时间序列法在提前 72 h 的风电功率预测上取得一定突破, 但该方法存在时间序列法模型推广的问题, 需建立多预测模型, 工作量大且结果未必稳定。文献[4]使用主成分分析和神经网络提前 3 h 预测, 误差为 12.26%。文献[5]使用基于数值天气预报系统和神经网络结合的方法对光伏发电系统进行提前 24 h 预测, 但这种方法严重依赖于数值天气预报的准确度, 而且目前国内数值天气预报系统还没有建立体系, 其实际应用受到限制。文献[6]使用遗传优化的最小二乘支持向量机使未来 12 h 风速预测绝对平均误差在 8.32%以内, 但风速进一步转换成风电功率时误差的放大使得实际功率预测效果变差。

从数据处理和预测方法进行改进能提高预测准确率。在风电功率时间序列处理方面, 文献[7]使用

基金项目: 广东省产学研结合项目(2009B090300030); 广东省教育厅电力节能与新能源技术重点实验室资助项目(IDSYS200701)

小波分解后将数据处理后用支持向量机进行提前 1 h 预测, 然后重构出预测结果, 其相对百分比误差可以达到 10.39%。文献[8]使用小波包分解和支持回归向量对风速进行提前 1~6 h 预测, 提前 6 h 预测时误差为 6.12%, 文献[9]使用经验模态分解分解风速时间序列后使用神经网络进行风速预测, 平均百分比误差达到 3.08%, 但文献[8-9]的方法同文献[6]面临同样的问题。组合预测法自 1969 年由 J.M.Bates 和 C.WJ.Granger 提出后发展迅速。其思想是通过各种预测算法组合, 优化预测数据从而提高预测精度。文献[10]使用组合方法对短期负荷进行预测, 文献[11]和文献[12]分别使用组合方法对风电功率和电价进行预测, 均表明预测效果较单一预测方法有所提高。

针对风电预测特点, 本文提出了一种基于小波包变换与虚拟预测的风电功率组合预测方法, 并对某实际风电场进行了提前 24 h 预测, 取得了良好的预测效果。

1 小波包变换原理

小波包变换和小波分析均由傅里叶变换发展而来, 实质为信号分解, 也可理解为新建的分解, 根据多分辨分析的空间分解理论, 有 $L^2(R) = \bigoplus_{j \in Z} W_j$, 即按照不同的尺度因子把空间 $L^2(R)$ 分解为小波函数 $\{\psi_{j,k}\}_{k \in Z}$ 的小波子空间的直和, 其中小波空间 W_j 为小波函数 $\{\psi_{j,k}\}_{k \in Z}$ 的小波子空间。小波包变换则进一步划分 W_j :

$$W_j = U_j^1 = U_{j+P}^{2^p} \oplus U_{j+P}^{2^{p+1}} \oplus \dots \oplus U_{j+P}^{2^{p+1}-1} = \sum_{q=0}^{2^p-1} U_{j+P}^{2^p+q} \quad (1)$$

$j=1,2,\dots; p=1,2,\dots,j$

式中, $U_{j+P}^{2^p+q}$ 为新的子空间序列。

小波分解的 Mallat 算法中, W_j 对应的是信号的低频分量, 小波包分解则是在小波分解的基础上对高频系数进行相同形式的分解, 形成一个完整二叉树结构, 分解结果是将原信号映射至 2^j 个小波包子空间中, 如图 1 所示。

小波包分解和重构算法如下。
分解算法

$$\begin{cases} d_l^{j,2n} = \sum_k h_{k-2l} d_k^{j-1,n} \\ d_l^{j,2n+1} = \sum_k g_{k-2l} d_k^{j-1,n} \end{cases} \quad (2)$$

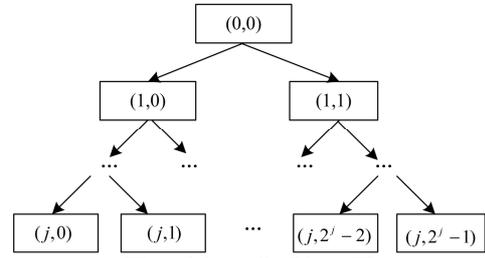


图 1 小波包分解结构图

Fig. 1 Structure of wavelet packet decomposition

重构算法

$$d_k^{j-1,n} = \sum_k [\tilde{h}_{l-2k} d_k^{j,2n} + \tilde{g}_{l-2k} d_k^{j,2n+1}] \quad (3)$$

式中: h_n 、 g_n 分别为低通和高通分解滤波器系数; 而 \tilde{h}_n 、 \tilde{g}_n 分别为低通和高通重构滤波器系数。

2 基于小波包变换与虚拟预测的风电功率组合预测方法

2.1 预测模型

本文使用的小波包-组合预测模型的预测过程是通过将风电功率数据进行小波包分解重构, 形成一系列不同频率的独立子序列, 然后对各单支子序列使用组合预测模型进行预测, 得出每个子序列预测结果, 叠加得出实际预测结果。流程简图如图 2 所示。

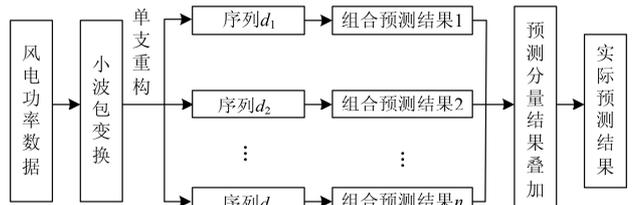


图 2 基于小波包变换与虚拟预测的风电功率组合预测模型

Fig. 2 Flow chart of WPT-wind power combination forecasting method

图 2 中, 组合预测是利用多个单一预测方法进行预测得到不同预测结果, 综合利用各种方法提供的信息将单一预测方法进行适当组合得出组合预测结果, 因而比单一预测模型更系统和全面, 能有效提高预测精度。组合法有不变权重组合法和变权重组合法。区别在于在预测过程中其组合权系数是否发生变化。因为每种预测方法在预测过程中其预测效果表现不同, 一般认为变权重系数法更科学。

因为风电功率各时间子序列预测过程相同, 结合图 2, 以第 k 层为例说明。此子序列各单项预测结果可表示成矩阵 Y_k : $Y_k = U(d_k, P_1, P_2, \dots, P_m)$; 其

中 d_k 为风电功率第 k 层子序列, P_j 为第 j 种预测方法, $1 \leq j \leq m$, U 表示利用子序列 d_k 和 m 个单项预测方法生成单项预测结果矩阵。假设预测时长为 t , 则

$$Y_k = \begin{bmatrix} y_{11} & y_{12} & \cdots & y_{1m} \\ y_{21} & y_{22} & \cdots & y_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ y_{n1} & y_{n2} & \cdots & y_{nm} \end{bmatrix} = [\gamma_1, \gamma_2, \cdots, \gamma_m] \quad (4)$$

式中, y_{ij} 表示 i 时刻第 j 种预测方法的预测值。

相应建立第 k 层权系数矩阵 W_k :

$W_k = V(d_k, P_1, P_2, \cdots, P_m, \theta(h))$, d_k 、 P_j 与前定义相同, $\theta(h)$ 表示利用历史 h 次预测进行权系数确定的方法。 V 表示权系数矩阵生成方法, 本文使用方法在 2.2 节说明。同式(4)设预测时长为 t , 则

$$W_k = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1m} \\ w_{21} & w_{22} & \cdots & w_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ w_{n1} & w_{n2} & \cdots & w_{nm} \end{bmatrix} = [\omega_1, \omega_2, \cdots, \omega_m] \quad (5)$$

式中, w_{ij} 表示 i 时刻第 j 种预测方法的权重系数。

第 k 层预测结果为

$$R_k = [\gamma_1^T \cdot \omega_1, \gamma_2^T \cdot \omega_2, \cdots, \gamma_m^T \cdot \omega_m]^T \quad (6)$$

最终预测结果 R 为

$$R = \sum_{k=1}^n R_k \quad (7)$$

式中, n 为风电功率子序列个数。

2.2 虚拟预测生成权系数矩阵

虚拟预测是指用已经建立的预测模型对已知历史数据进行“预测”, 目的是对预测模型的性能进行评价; 一般情况下进行虚拟预测时所用到的历史数据在建立预测模型时未经使用。可作如式(8)定义。

$$(\mu_1, \mu_2, \cdots, \mu_n) = f(\theta_1, \theta_2, \cdots, \theta_n, (a_1, b_1), (a_2, b_2), \cdots, (a_m, b_m)) \quad (8)$$

其中: θ_i 表示第 i 种预测方法, $i \geq 1$; (a_j, b_j) 表示第 j 组用于执行虚拟预测评价的数据, a_j 为虚拟预测所用历史数据, b_j 为对比数据, $j \geq 1$; f 为评价指标判定方法, 一般评价指标为“预测结果”与实际数据的误差, 如绝对误差(和), 均方差(和)等; μ_i 为预测方法 θ_i 的评价结果。例如: f 取绝对误差和为评价标准, 要得到 μ_i , 使用 θ_i 和 (a_j, b_j) ($1 \leq j \leq m$) 得 $b_j^* = \theta_i(a_j)$, b_j^* 为虚拟预测结果, 则 $\mu_i = \sum_{j=1}^m (|b_j^* - b_j|)$ 。

虚拟预测在预测时间序列上表示如图 3。

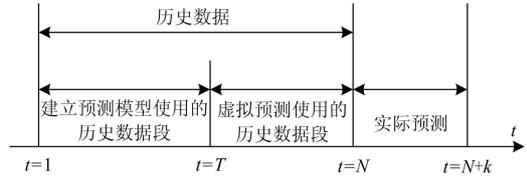


图 3 虚拟预测时段示意图
Fig. 3 Period of virtual forecasting

组合预测模型通过利用各单一预测模型进行虚拟预测得到各单一模型的预测效果, 利用评价指标形成组合预测模型中单一模型的权系数。

方差倒数法是一种常用的权系数生成方法, 通过使用预测误差平方和反应预测模型预测精度, 通过对预测时段前的历史若干次等时长虚拟预测, 同时刻 t 预测误差平方和较小则认为单项模型在 t 时刻预测效果较好, 此单项预测模型在 t 时刻被赋予较大的加权系数, 如式(9)。

$$\omega_{i,t} = \frac{E_{i,t}^{-1}}{\sum_{i=1}^n E_{i,t}^{-1}} \quad (9)$$

$$t = 1, 2, \cdots, n; \quad i = 1, 2, \cdots, m$$

其中: $\sum_{i=1}^m \omega_{i,t} = 1$; $E_{i,t}$ 表示第 i 个单项预测模型进行的历史预测在 t 时刻的误差平方和; m 是预测方法个数; n 是预测时间长度。权系数生成过程中使用的是实际预测时段前的多次虚拟预测数据, 因此随着预测时段改变其使用的虚拟预测数据也随着改变, 故权系数也会发生改变, 形成滚动权系数。

对于权系数矩阵 W 的形成, 假设使用 m 种预测模型对预测时间段前进行前 b 个时间段虚拟预测, 预测时间长度为 t , 对于矩阵 W 中元素 $W(i, j)$ 有

$$W(i, j) = \frac{\sum_{l=1}^b (a_l^*(i, j) - a_l(i, j))^{-2}}{\sum_{i=1}^m \sum_{l=1}^b (a_l^*(i, j) - a_l(i, j))^{-2}} \quad (10)$$

其中: i, j 分别表示预测方法和预测时刻, 所以同式(5), $1 \leq i \leq m, 1 \leq j \leq t$; l 表示历史预测次数, 所以 $1 \leq l \leq b$ 。其中 $a_l^*(i, j)$ 、 $a_l(i, j)$ 分别表示在第 l 天 j 时刻第 i 种预测方法的预测值与实际值。该权系数矩阵随预测时间改变而改变, 形成滚动权系数矩阵。

3 仿真研究

3.1 预测过程

本文分别选取时间序列法、神经网络法和支向量机三种预测原理不同的预测算法进行方差倒数法组合。这三种方法预测原理差异大,能利用数据从不同角度挖掘其中的信息。

可以得到完整的小波包-组合预测模型的完整框架如图4。

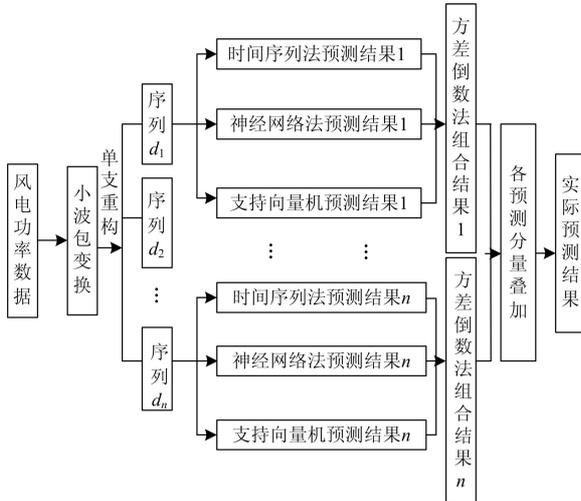


图4 基于小波包变换与虚拟预测的风电功率组合预测实例

Fig. 4 A practical structure of WPT-wind power combination forecasting method

结合框架图说明详细预测步骤如下:

1) 将原始风电功率序列进行小波包分解,得到 n 组小波系数,分别单支重构得到 n 个子序列 $d_1 \sim d_n$ 。

2) 对以上 n 个子序列分别建立时间序列法、神经网络法和支向量机三种预测模型。

3) 对各子序列使用式(2)中建立的模型对预测时段前数个历史时段进行模拟预测并利用式(9)分别形成权重系数矩阵。

4) 使用三种预测模型对预测时段进行实际预测每个子序列得到三个预测结果。

5) 对于单支子序列,使用步骤(3)中建立的权重系数矩阵和步骤(4)中得到的实际数据,通过式(6)、式(7)得到组合预测。

6) 将各子序列 $d_1 \sim d_n$ 的组合预测结果叠加,得到实际风电功率预测结果。

使用广东某风电场的风电功率作为数据,因为条件限制,该风电场目前不同步采集温度、风向等资料,故仅使用风电功率作为实验数据。风电场 1 h 平均风电功率作为小时风电功率,共有 350×24 个数据点。利用历史数据对未来 24 h 风电功率进行预

测,分辨率为 1 h。

使用小波包对风电功率进行分解时,分解层次太少,各子序列随机性仍较强,预测方法不能有效捕捉其波动特性;分解层次过多,虽然单个子序列预测误差较小,但子序列预测误差叠加影响结果综合误差;综上本论文使用 db6 母小波对风电功率序列进行 4 层分解并重构,共得 2^4 个子序列,每个子序列进行提前 24 h 预测,最后重构出预测结果。

在预测过程中,通过使用贝叶斯算法增强 BP 神经网络的泛化能力,改善预测效果。支持向量回归预测则使用 LS-SVM 工具箱;LS-SVM 用最小二乘线性系统作为损失函数取代支持向量机中的二次规划问题,处理大数据能力更强^[13]。单支子序列组合预测结果由方差倒数法确定,其中权重系数矩阵由前 10 天预测功率与实际功率方差经式(10)确定。

为证明本文所提方法的有效性,分别采用如下方法进行预测并比较:1) 直接利用 BP 神经网络对风电功率进行预测(BP 神经网络法,简称 BP)。2) 对风电功率进行小波包分解后利用 BP 神经网络进行预测(小波包-神经网络法,简称 WP-BP)。3) 对风电功率进行小波包分解后利用最小二乘支持向量机(LSSVM)预测(小波包-支持向量机法,简称 WP-SVM)。4) 本文提出的对风电功率进行小波包分解后利用变系数方差倒数法组合方法进行预测(小波包-组合预测法,简称 WP-C)。

为有效评价各预测方法的预测准确率,采用平均绝对百分比误差(M_{APE})进行评价。

$$M_{APE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{x_t - \hat{x}_t}{x_t} \right| \quad (11)$$

式中: x_t 均表示实际风电功率值; \hat{x}_t 表示预测风电功率值。

3.2 预测结果

对风电场进行连续 7 天的预测,取前两天预测结果如图 5、图 6 所示。

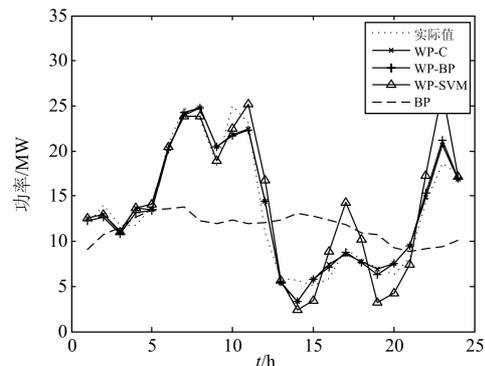


图5 第1天预测效果图

Fig. 5 Forecasting result of the first day

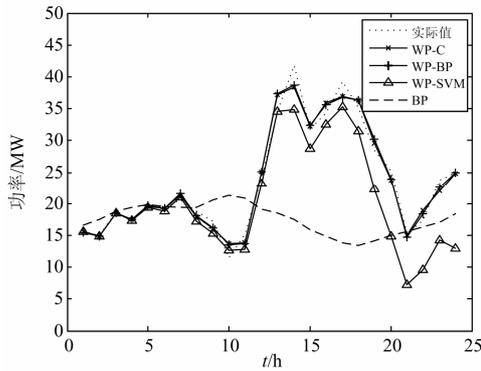


图 6 第 2 天预测效果图

Fig. 6 Forecasting result of the second day

连续 7 天各方法预测结果误差如表 1 所示。

表 1 预测误差对比表

Table 1 Percentage error of four forecasting methods

时间/天	误差/%			
	BP	WP-BP	WP-SVM	WP-C
1	47.12	11.08	21.34	10.88
2	29.20	4.65	14.88	4.63
3	23.74	4.14	4.77	3.99
4	20.54	14.57	13.74	12.07
5	43.06	11.13	8.36	6.02
6	32.72	6.37	9.56	5.75
7	40.42	10.16	20.45	9.61

WP-C 预测相对百分比误差如图 7 所示。

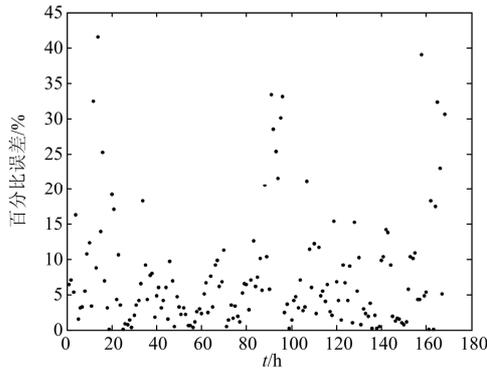


图 7 WP-C 方法 7 天预测百分比误差分布图

Fig. 7 Percentage error of WP-C method in 7 days

在连续 7 天共 168 个预测点中,共有 15 个点预测误差在 20%以上,占总数的 9%, 153 个点预测误差在 20%以内,占总数的 91%, 而其中误差在 10%以内的点共 127 个,占总数的 75.6%, 误差在 5%以内的点共 84 个,占总数的 50%。分析其中误差较大的点知其均分布于风电功率绝对值小的位置,这是因为使用单一误差评价方法不能全面反映预测结果所致,而实际预测误差绝对值仍较小。以第 14 个和第 34 个预测点为例说明:第 14 个预测点实际功

率为 5.72 MW, 预测值为 3.347 6 MW, 实际误差为 2.372 4 MW, 平均绝对百分比误差为 41.48%; 第 34 个预测点实际功率为 11.54 MW, 预测值为 13.65 MW, 实际误差为 2.11 MW, 平均绝对百分比误差为 18.28%; 两个点虽然实际预测误差相近,但是因为实际功率相差较远,使用式(11)计算得到的百分比误差计算结果相差悬殊;因为连续 7 天预测中,第 1、4、7 天发电功率绝对值较小的点较其余 4 天多,也是造成表 1 这 3 天预测结果误差较大的原因。

小波包分解重构前, BP 神经网络平均预测误差为 33.83%; 而小波包-BP 神经网络法预测误差为 8.87%, 预测效果改进明显。

连续 7 天预测结果显示: WP-SVM 平均预测误差为 13.3%, WP-BP 预测平均误差为 8.87%, WP-C 预测平均误差为 7.56%。组合预测方法的预测误差小于各单一预测方法。

4 结论

1) 通过小波包变换分解并重构风电功率时间序列能将原始风电功率分解为一系列规律性和相关性强的子序列进行处理, 可以提高预测精度, 特别是其中的高频分量。

2) 在组合预测模型中, 提出了一种虚拟预测方法用于解决单一预测模型的权系数的确定问题。仿真结果表明: 基于该方法的组合预测方法较组合模型中的任一单项预测方法而言, 具有更好的预测效果。

参考文献

- [1] 吴义纯, 丁明, 李生虎. 风电场对发输电系统可靠性影响的评估[J]. 电工技术学报, 2004, 19(11): 72-76.
WU Yi-chun, DING Ming, LI Sheng-hu. Reliability assessment of wind farms in generation and transmission systems[J]. Transactions of China Electrotechnical Society, 2004, 19(11): 72-76.
- [2] Alexiadis M, Dokopoulos P, Sahsamanoglou H, et al. Short term forecasting of wind speed and related electrical power[J]. Solar Energy, 1998, 63(1): 61-68.
- [3] 孙春顺, 王耀南, 李欣然. 小时风速的向量自回归模型及应用[J]. 中国电机工程学报, 2008, 28(14): 112-117.
SUN Chun-shun, WANG Yao-nan, LI Xin-ran. A vector auto regression model of hourly wind speed and its applications in hourly wind speed forecasting[J]. Proceedings of the CSEE, 2008, 28(14): 112-117.
- [4] 何东, 刘瑞叶. 基于主成分分析的神经网络动态集成

- 风功率超短期预测[J]. 电力系统保护与控制, 2013, 41(4): 50-54.
- HE Dong, LIU Rui-ye. Ultra-short-term wind power prediction using ANN ensemble based on the principal components analysis[J]. Power System Protection and Control, 2013, 41(4): 50-54.
- [5] 陈昌松, 段善旭, 殷进军. 基于神经网络的光伏阵列发电预测模型的设计[J]. 电工技术学报, 2009, 24(9): 153-158.
- CHEN Chang-song, DUAN Shan-xu, YIN Jin-jun. Design of photovoltaic array power forecasting model based on neural network[J]. Transactions of China Electrotechnical Society, 2009, 24(9): 153-158.
- [6] 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.
- [7] 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.
- [8] 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.
- [9] 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.
- [10] 张志明, 金敏. 基于灰关联分段优选组合模型的短期电力负荷预测研究[J]. 电工技术学报, 2009, 24(6): 115-120.
- ZHANG Zhi-ming, JIN Min. Research on short-term electrical load forecasting based on optimized combination model of grey correlation segmentation[J]. Transactions of China Electrotechnical Society, 2009, 24(6): 115-120.
- [11] 张国强, 张伯明. 基于组合预测的风电场风速及风电机组功率预测[J]. 电力系统自动化, 2009, 33(18): 92-95.
- ZHANG Guo-qiang, ZHANG Bo-ming. Wind speed and wind turbine output forecast based on combination method[J]. Automation of Electric Power Systems, 2009, 33(18): 92-95.
- [12] YANG Hong-ming, DUAN Xian-zhong. Chaotic characteristics of electricity price and its predicting model[C] // IEEE CCECE 2003, Montreal, Canada: 659-662.
- [13] 邓乃扬, 田英杰. 支持向量机理论、算法与拓展[M]. 北京: 科学出版社, 2009.
- DENG Nai-yang, TIAN Ying-jie. The support-vector's theory, algorithm and expanding[M]. Beijing: Science Press, 2009.

收稿日期: 2013-05-02; 修回日期: 2013-08-12

作者简介:

孟安波(1971-), 男, 博士, 副教授, 主要研究方向为电力系统自动化、系统分析与集成;

陈育成(1987-), 男, 通讯作者, 硕士研究生, 主要研究方向为智能算法在电力系统中的应用。E-mail: 117279946@qq.com