

基于 WD-CS-SVM 的超短期风电功率组合预测

刘家敏, 李聪睿, 周志浩, 李升

(南京工程学院电力工程学院, 江苏 南京 211167)

摘要:为了提高风电场输出功率的预测精度,应用小波分析(WD)和布谷鸟优化支持向量机(CS-SVM)算法对风电功率进行超短期预测,对比于通过预测风速间接求得的风电功率更加直接且准确。首先,利用WD与重构,将风电功率模型分解成近似序列和细节序列,然后利用CS-SVM算法对每个序列进行预测,得到每个序列的预测结果,最后把各个序列的预测结果叠加,形成风电功率的最终预测值。算例计算结果表明,预测结果具有较高的精度,与SVM以及其他方法优化的SVM预测结果相比,文中使用的方法预测结果更加准确,具有较强的优越性和实用性。

关键词:小波分析;布谷鸟算法;支持向量机;风电功率;组合预测

中图分类号:TM614

文献标志码:A

文章编号:2096-3203(2019)05-0024-06

0 引言

近年来,随着生活水平的日益提高和工业的迅猛发展,全球的用电量快速增长,化石能源的大量使用导致其日渐枯竭,因此带来的环境污染也日益严重,所以现在迫切需要利用新能源来代替这些不可再生能源^[1]。在新能源中,风能具有很强的波动性、间歇性、不可控等特点,在风能大规模并网以后可能会造成电压的波动、频率的偏差等电能质量下降的问题,所以对超短期风电功率的精准预测显得格外的重要^[2]。

目前,国内外很多学者都对风电功率预测开展了研究,常用的风电功率预测方法包括持续法^[3]、时间序列法^[4]、卡尔曼滤波法^[5]、人工神经网络法^[6]、模糊逻辑法^[7]、支持向量机(support vector machine, SVM)^[8]、空间相关法^[9]、物理预测法^[10-11]等。其中,SVM在非线性问题和高维模式的应用能力更加突出,所以受到学者们的青睐,但其参数的选取还存在难点。由于风速的波动性很强,导致了风电功率呈现出巨大的变化性,上述各种预测方法的绝对平均误差在20%~45%,误差的范围较大,仍然没有达到令人满意的程度^[12]。

基于风速模型预测风电功率时,由于受到测量塔安装限制,加之风速和风电功率之间存在非线性关系,将产生较大的功率值误差。基于风电功率的预测方法不会受到其他因素的干扰,能够提高预测精度。SVM具有结构最小化的特点,在对数据进行预测时,不会使其陷入局部最小化。解决回归问题时,惩罚因子参数C和核函数参数 σ^2 的选取难以确

定,会造成较大的误差。因此,许多学者通过差分进化算法^[13]、粒子群算法(particle swarm optimization, PSO)或遗传算法^[14-16]等对SVM进行优化,优化后的预测准确率都有一定的提高。

基于此,文中采用小波分析和布谷鸟优化SVM(wavelet decomposition and cuckoo search optimized SVM, WD-CS-SVM)算法对风电功率进行超短期预测。首先对风电功率进行WD与重构,把风电功率分解为近似序列和细节序列,再通过CS优化SVM(CS optimized SVM, CS-SVM)算法对每个序列进行预测,最后再把每个序列的预测结果进行叠加,形成风电功率预测值^[17-21],以期提高预测精度。

1 WD原理

WD是由J.Morlet在1974年首先提出的,小波是由小波基函数构成的,可以描述信号时间(空间)和频率(尺度)域的局部特性^[22]。与傅里叶变换相比,能够更加准确地从原始信号中分解出所需的信息,其具有的多尺度的特点能够获取信号中的细节信息,解决了傅里叶变换不能解决的许多困难问题。WD的基本原理是利用多分辨率的思想把原始的非平稳的信号分解为多个不同频率的高频细节序列和一个低频细节序列,分解的过程如式(1)所示^[23]:

$$\begin{cases} a_{j+1} = H(a_j) \\ a_{j+1} = G(d_j) \end{cases} \quad j = 1, 2, \dots, J \quad (1)$$

式中: a_j, d_j 是原始信号在不同的频率成分上的信号,分别是其中的低频和高频信号; $H(\cdot), G(\cdot)$ 分别为低频和高频分解函数。

在信号的分解过程中,分解过后的信号长度会比原始信号长度减少,为原始信号长度的一半,所

为了使分解后的信号长度和原始信号长度一致, 需要采取二插值重构来使分解后的信号长度还原到原始信号长度, 还原过程如式(2)所示^[23]:

$$\begin{cases} A_j = (H^*)^j a_j \\ D_j = (H^*)^{j-1} G^* d_j \end{cases} \quad j = 1, 2, \dots, J \quad (2)$$

式中: H^* 为 H 的对偶算子; G^* 为 G 的对偶算子。对 d_1, d_2, \dots, d_J 和 a_J 重构后, 得到细节序列 D_1, D_2, \dots, D_J 和近似序列 A_J , 其长度与原始风速序列相同。

利用 WD 对原始的信号进行分解, 能够提取出信号的重要特征, 在对其进行预测时能够减小误差, 分解风电功率时一般选择 db3 小波基把信号分解成 3 层。

2 基于 WD-CS-SVM 的风电功率预测模型

2.1 基于 CS-SVM 参数优化

2.1.1 CS 原理

CS 是基于布谷鸟的寄生性育雏行为, 该算法能够通过莱维 (Levy) 飞行来使结果更加精确。研究表明, 该算法在一些情况下会比遗传算法、PSO 等算法预测的效果更好^[24]。CS 采用的 Levy 飞行这种搜索方式既能够有效地缩短局部搜索的时间, 又能够使其在搜索的过程中不会陷入局部最优解, 所以 CS 算法能够快速有效地找到 SVM 的最优参数^[25-26]。

CS 算法有 3 条理想化的规则:

- (1) 每只布谷鸟每次只生一个卵, 随机放入一个鸟巢;
- (2) 放有最好卵的鸟巢将会带到下一代;
- (3) 鸟巢数量是固定的为 n , 且布谷鸟卵被发现的概率为固定值 P_a 。

假设已知 $x_{k,i}$, 则采用 Levy 飞行随机游走方法生成新的解 $x_{k+1,i}$ 的过程如式(3)所示^[17]:

$$x_{k+1,i} = x_{k,i} + \alpha_0 \frac{\Phi\mu}{|v|^{\frac{1}{\lambda}}} (x_{k,i} - x_{k,\text{best}}) \quad (3)$$

式中: $x_{k,i}$ 为第 k 代第 i 个解; $\alpha_0(x_{k,i} - x_{k,\text{best}})$ 为步长, 来确定在搜索过程中的范围大小, α_0 取 0.01;

$x_{k,\text{best}}$ 为第 k 代最优解; $\frac{\Phi\mu}{|v|^{\frac{1}{\lambda}}}$ 为 Levy 随机搜索的路径, μ, v 服从标准正态分布, $\lambda = 1.5$, Φ 的取值如式(4)所示^[17]:

$$\Phi = \left\{ \frac{\Gamma(1 + \lambda) \sin \frac{\pi\lambda}{2}}{\Gamma\left[2^{\frac{\lambda-1}{2}} \left(\frac{1+\lambda}{2}\right) \lambda\right]} \right\}^{\frac{1}{\lambda}} \quad (4)$$

式中: Γ 是标准的 Gamma 函数。根据布谷鸟卵发现

概率 P_a 舍掉一部分解, 并按照式(5)产生同样多的新解^[27-28]:

$$x_{k+1,j} = x_{k,j} + \gamma(x_{k,j} - x_{k,e}) \quad (5)$$

式中: γ 是缩放因子, 服从 $(0, 1)$ 区间均匀随机分布; $x_{k,j}, x_{k,e}$ 为第 k 代的 2 个随机解。

2.1.2 CS-SVM 参数流程

CS-SVM 参数 c, σ^2 的过程如下。

步骤一: 随机生成 n 个寄生鸟巢的初始位置, 同时设定其中的参数;

步骤二: 根据生成鸟巢位置计算每个寄生鸟巢的适应度值, 同时使每个鸟巢的适应度值最佳;

步骤三: 所有寄生鸟巢根据式(5)开始调整;

步骤四: 比较调整前后两代鸟巢的适应度值, 选取适应度较理想的寄生鸟巢;

步骤五: 生成随机数 r , 把随机数 r 和寄生鸟巢宿主发现外来鸟蛋的淘汰概率 P_a 作对比, 若 $r > P_a$, 则丢弃差的位置, 用产生的新的位置替代丢弃的位置, 并比较调整前后适应度值, 选取好的鸟巢和适应度值;

步骤六: 判断是否满足结束条件(适应度值较为理想, 或最优解停止不变, 或达到最大允许迭代次数或收敛精度), 如果满足, 则停止搜索, 输出最优解及位置; 否则转向步骤二再次进行计算。

2.2 WD-CS-SVM 风电功率预测

2.2.1 原始数据处理

对从风电场获取的风电功率的数据进行归一化处理, 主要是可以减小异常数据对预测结果的影响, 还可以大大加快算法的训练速度和收敛速度, 能够以更短的时间得到预测的结果。文中采用 mapminmax 函数进行归一化, 如式(6)所示:

$$y = \frac{(y_{\max} - y_{\min})(x_t - x_{\min})}{x_{\max} - x_{\min}} + y_{\min} \quad (6)$$

式中: x_t 为第 t 点的风电功率值; x_{\max} 为风电功率的最大值; x_{\min} 为风电功率的最小值; y_{\max} 为归一化的最大值; y_{\min} 为归一化的最小值。

2.2.2 WD-CS-SVM 风电功率预测模型搭建

由于风速的波动性和间歇性, 导致了风机发出功率的不规则性, 所以用单一的算法来预测风电功率很难取得较好的结果, 文中采用了 WD-CS-SVM 的组合预测方法来预测风电功率^[29]。首先对数据进行 WD 和重构, 得到细节序列和近似序列; 再对得到的数据进行归一化处理; 然后针对各序列的特点采用 CS 算法选取预测模型的惩罚因子参数和核函数参数, 分别建立各自合适的 SVM 模型; 最后将各个分量预测值进行叠加得到最后的风电功率预测

值。具体预测步骤如下：

- (1) 利用 WD 对原始风电功率序列进行分解得到 a_3, d_1, d_2, d_3 , 再进行小波重构得到近似序列 A_3 和细节序列 D_1, D_2, D_3 ;
- (2) 对得到的序列进行归一化处理;
- (3) 分别对各序列建立 SVM 回归预测模型, 采用 CS 寻找最优惩罚因子参数和核函数参数, 即用 CS-SVM 得到各序列预测值;
- (4) 对各个预测序列进行叠加获得最终的风电功率预测数据;
- (5) 与实际的风电功率数据对比, 进行功率预测误差分析。

具体流程如图 1 所示。

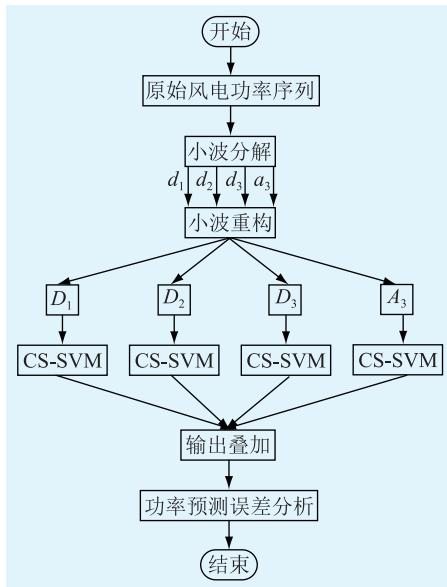


图 1 WD-CS-SVM 预测模型

Fig.1 WD-CS-SVM prediction model

3 算例分析

以某实际风电场为例, 采集了该风电场 2017 年 10 月 31 日 17 点到 11 月 5 日 21 点 45 分的实际输出功率数据(Elia 网站 www.elia.be 获取的风电功率数据), 共采集 500 组, 采集时间间隔为 15 min, 用前 463 组数据进行训练, 对最后的 35 个点进行提前 15 min 的预测, 原始风电功率如图 2 所示。

对原始风电功率数据选择 db3 小波基进行 3 层分解和重构, 得到一个近似序列 A_3 和 3 个细节序列 D_3, D_2, D_1 如图 3 所示。

为了证实所提出的方法的有效性, 分别与 SVM、CS-SVM、PSO 优化 SVM(PSO optimized SVM, PSO-SVM)、WD 和 PSO 优化 SVM(WD and PSO optimized SVM, WD-PSO-SVM)进行对比分析, 并采用

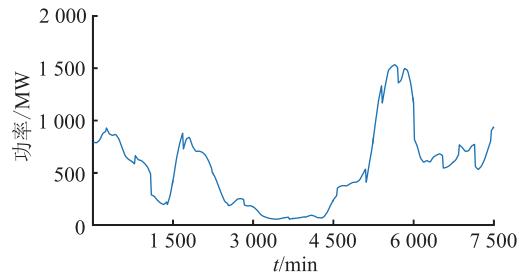


图 2 原始风电功率数据

Fig.2 Original wind power data

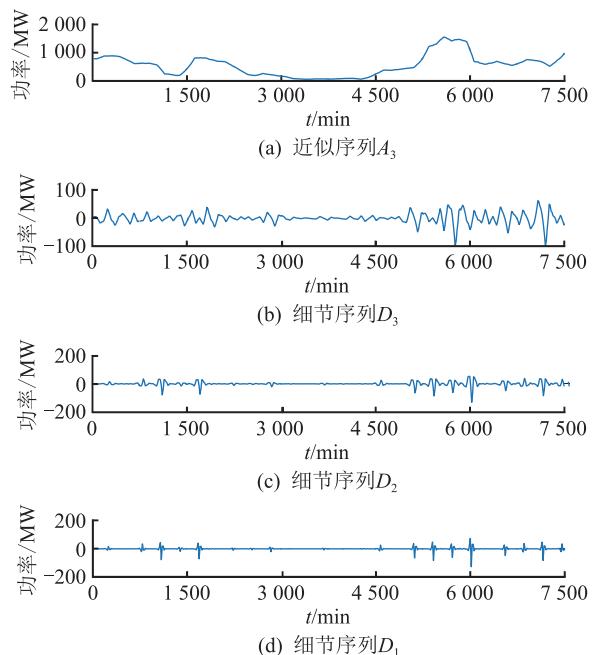


图 3 原始风电功率小波分解

Fig.3 Original wind power waveletdecomposition

平均绝对误差(MAE)、平均相对误差(MAPE)及均方根误差(RMSE) 3 种分析指标对预测的数据进行分析比较, 其表达式如式(7)—式(9)所示:

$$e_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |\hat{y}_t - y_t| \quad (7)$$

$$e_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_t - y_t}{y_t} \right| \quad (8)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_t - y_t)^2} \quad (9)$$

式中: y_t 为功率的实际值; \hat{y}_t 为功率的预测值; N 为样本的个数。

CS 中有多个参数, 除了种群规模 n 之外, 还有布谷鸟卵被发现的概率 P_a , 步长缩放因子 α 和 Levy 指数 λ , 通过改变它们的值, 发现在大多数问题中我们可以设置 $\lambda=1.5$ 和 $\alpha=0.01$, 在模拟中发现 n 从 15 到 40 和 $P_a=0.25$ 对于大多数的问题其优化效果是较为理想的。运用 CS 对文中的数据进行预

测时, 取 $\lambda = 1.5$, $\alpha = 0.01$, $n = 15$, $P_a = 0.25$, 使用 Matlab 进行仿真, 得到采用不同预测方法的风电功率预测对比图和风电功率预测误差对比图, 如图 4、图 5 所示。

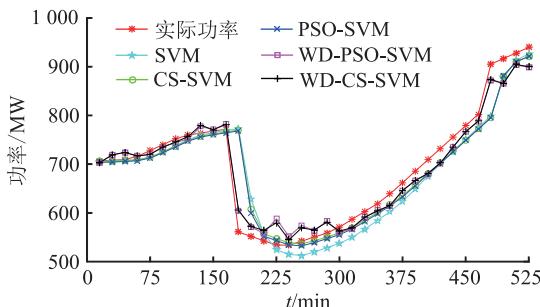


图 4 不同方法风电功率预测对比

Fig.4 Different methods of wind power prediction comparison chart

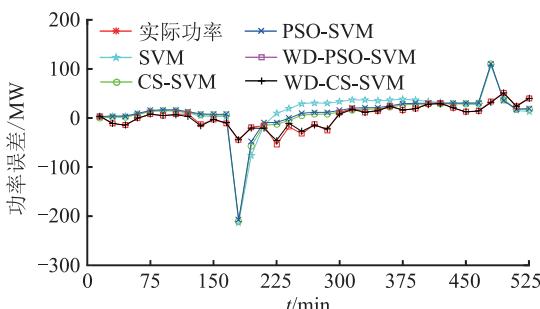


图 5 不同方法风电功率预测误差对比

Fig.5 Comparison of different methods of wind power prediction error

5 种不同方法预测风电功率的评价指标对比如表 1 所示。

表 1 不同方法风电功率预测指标对比

Table 1 Comparison of wind power prediction indicators of different methods

预测方法	e_{MAE}/MW	e_{RMSE}/MW	$e_{MAPE}/\%$
SVM	30.794 9	48.424 9	4.76
PSO-SVM	25.914 0	44.640 3	3.86
CS-SVM	24.932 4	44.646 5	3.72
WD-PSO-SVM	19.348 6	23.331 6	2.88
WD-CS-SVM	18.527 9	22.281 8	2.75

由图 4、图 5 及表 1 可得, 文中提出的 WD-CS-SVM 预测方法较其他的方法更加的优越, 可以看出, 未经优化的 SVM 的预测效果最不理想, 文中的方法比 PSO-SVM 和 CS-SVM 有明显的改善, 其主要是在于对风电功率序列通过 WD 与重构, 得到了近似序列和细节序列, 然后再针对各个序列采用算法进行预测。说明 WD 的多分辨率分解对于提高预测精度有着很大的改善。文中的方法也略好于 WD-

PSO-SVM, 也证明了 CS 算法在参数寻优方面的表现更好。

4 结论

风电功率具有间歇性和随机波动性, 在预测时会存在较大的误差。为了提高预测精度, 应用了一种基于 WD-CS-SVM 的组合预测方法, 得到结论如下:

(1) 由于 WD 具有多分辨率的特点, 能够把原始的风电功率数据分解为具有一定规律的高频细节和低频细节, 更容易获取风电功率的规律, 使其具有更强的预测性。

(2) 对 WD 后的不同风电功率序列用 SVM 分别建立各自的模型, 这样能够针对每个序列的特点, 设定不同的惩罚因子参数和核函数参数, 建立合适的预测模型, 使得预测的结果更加准确。

(3) 采用优化效果较好的 CS 来寻找 SVM 的惩罚因子参数和核函数参数, 这样能够更快更准确地找到最优的参数。仿真结果表明, 和 SVM、PSO-SVM、CS-SVM、WD-PSO-SVM 相比, WD-CS-SVM 能够更好的循迹风电功率的规律, 有效地提高风电功率的预测精度。

(4) 在对电力系统进行稳定性判别和控制方面, 需要在较短的时间内得出风力发电机出力的数据, 所以文中对风电功率进行提前 15 min 的超短期预测在这方面具有实际意义, 更具应用价值。

参考文献:

- [1] 史宇伟, 潘学萍. 计及历史气象数据的短期风速预测 [J]. 电力自动化设备, 2014, 34(10): 75-80.
SHI Yuwei, PAN Xueping. Short-term wind speed forecasting considering historical meteorological data [J]. Electric Power Automation Equipment, 2014, 34(10): 75-80.
- [2] 钱政, 裴岩, 曹利宵, 等. 风电功率预测方法综述 [J]. 高压技术, 2016, 42(4): 1047-1060.
QIAN Zheng, PEI Yan, CAO Lixiao, et al. Review of wind power forecasting methods [J]. High voltage technology, 2016, 42(4): 1047-1060.
- [3] RAJAGOPALAN S, SANTOSO S. Wind power forecasting and error analysis using the autoregressive moving average modeling [J]. Power & Energy Society General Meeting, PES: IEEE, 2009: 1-6.
- [4] 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.
- [5] 修春波,任晓,李艳晴,等.基于卡尔曼滤波的风速序列短期预测方法[J].*电工技术学报*,2014,29(2):253-259.
XIU Chunbo, REN Xiao, LI Yanqing, et al. Short-term prediction method of wind speed series based on kalman filtering fusion [J]. Transactions of China Electrotechnical Society, 2014, 29 (2) : 253-259.
- [6] 张宜阳,严欢.基于分段分层相似日搜索和自适应脊波神经网络的风电功率多步预测[J].*电网与清洁能源*,2015,31(4):124-131.
ZHANG Yiyang, YAN Huan. Multi-step wind power forecasting based on subsection and layer searching for similar day and adaptive ridgelet neural network [J]. Power System and Clean Energy, 2015, 31 (4) : 124-131.
- [7] 刘兴杰,岑添云,郑文书,等.基于模糊粗糙集与改进聚类的神经网络风速预测[J].*中国电机工程学报*,2014,34(19):3162-3169.
LIU Xingjie, CEN Tianyun, ZHENG Wenshu, et al. Neural network wind speed prediction based on fuzzy rough set and improved clustering [J]. Proceedings of the CSEE, 2014, 34 (19) : 3162-3169.
- [8] 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 Chunhua, LIU Gang, SUN Huijuan. Wind speed forecasting based on wavelet decomposition and differentialevolution-support vector machine for wind farms [J]. Electric Power Automation Equipment, 2012, 32 (1) : 9-13.
- [9] 叶林,赵永宁.基于空间相关性的风电功率预测研究综述[J].*电力系统自动化*,2014,38(14):126-135.
YE Lin, ZHAO Yongning. A review on wind power prediction based on spatial correlation approach [J]. Automation of Electrical Power Systems, 2014, 38 (14) : 126-135.
- [10] 程启明,陈路,程尹曼,等.基于EEMD和LS-SVM模型的风电功率短期预测方法[J].*电力自动化设备*,2018,38(5):27-35.
CHENG Qiming, CHEN Lu, CHENG Yinman, et al. Short-term wind power forecasting method based on EEMD and LS-SVM model [J]. Electric Power Automation Equipment, 2018, 38 (5) : 27-35.
- [11] 陶玉波,陈昊,秦晓辉,等.短期风电功率预测概念和模型与方法[J].*电力工程技术*,2018,37(5):7-13.
TAO Yubo, CHEN Hao, QIN Xiaohui, et al. A review of the short-term wind power forecasting theory, model and approach [J]. Electric Power Engineering Technology, 2018, 37 (5) : 7-13.
- [12] 乔颖,鲁宗相,闵勇.提高风电功率预测精度的方法[J].*电网技术*,2017,41(10):3261-3268.
QIAO Ying, LU Zongxiang, MIN Yong. Research&application of raising wind power prediction accuracy [J]. Power System Technology, 2017, 41 (10) : 3261-3268.
- [13] 刘增良,周松林,周同旭.基于IDE-WNN的短期风电功率预测及概率评估[J].*系统仿真学报*,2016,28(2):476-482.
LIU Zengliang, ZHOU Songlin, ZHOU Tongxu. Short-term prediction of wind power based on IDE-WNN and probabilistic evaluation [J]. Journal of System Simulation, 2016, 28 (2) : 476-482.
- [14] 杨锡运,关文渊,刘玉奇,等.基于粒子群优化的核极限学习机模型的风电功率区间预测方法[J].*中国电机工程学报*,2015,35(1):146-153.
YANG Xiyun, GUAN Wenyuan, LIU Yuqi, et al. Prediction intervals forecasts of wind power based on PSO-KELM [J]. Proceedings of the CSEE, 2015, 35 (1) : 146-153.
- [15] 肖迁,李文华,李志刚,等.基于改进的小波-BP神经网络的风速和风电功率预测[J].*电力系统保护与控制*,2014,42(15):80-86.
XIAO Qian, LI Wenhua, LI Zhigang, et al. Wind speed and power prediction based on improved wavelet-BP neural network [J]. Power System Protection and Control, 2014, 42 (15) : 80-86.
- [16] LI Sheng, WEI Zhinong, MA Yanan, et al. Prediction and control of Hopf bifurcation in a large-scale PV grid-connected system based on an optimised support vector machine [J]. The Journal of Engineering, 2017 (14) : 2666-2671.
- [17] 李燕青,袁燕舞,郭通.基于AMD-ICSA-SVM的超短期风电功率组合预测[J].*电力系统保护与控制*,2017,45(14):113-120.
LI Yanqing, YUAN Yanwu, GUO Tong. Combination ultra-short-term prediction of wind power based on AMD-ICSA-SVM [J]. Power System Protection and Control, 2017, 45 (14) : 113-120.
- [18] 陈梅森,江岳文.考虑风电功率短期预测值偏差的日前市场经济调度[J].*供用电*,2017,34(5):69-75.
CHEN Meisen, JIANG Yuewen. Renewable energy sources day-ahead market economic dispatch considering short-term wind power forecast error [J]. Distribution & Utilization, 2017,34(5):69-75.
- [19] 王玉婷,陈福锋,薛明军,等.适用于双馈风电场并网的自适应距离保护[J].*供用电*,2017,34(8):74-78.
WANG Yuting, CHEN Fufeng, XUE Mingjun, et al. An adaptive distance protection for DFIG wind farms [J]. Distribution & Utilization, 2017,34(8):74-78.
- [20] 茅靖峰,吴博文,吴爱华,等.风力发电系统最大功率跟踪自适应鲁棒控制[J].*电力系统保护与控制*,2018,46(22):80-86.
MAO Jingfeng, WU Bowen, WU Aihua, et al. Maximum power tracking adaptive robust control for wind power systems [J]. Power System Protection and Control, 2018, 46 (22) : 80-86.
- [21] 田中大,李树江,王艳红,等.基于小波变换的风电场短期风速组合预测[J].*电工技术学报*,2015,30(9):112-120.
TIAN Zhongda, LI Shujiang, WANG Yanhong, et al. Short-term wind speed combined prediction for wind farms based on

- wavelet transform [J]. Transactions of China Electrotechnical Society, 2015, 30(9) : 112-120.
- [22] 汪小明, 肖猛, 杨楠, 等. 基于小波分解和极限学习机的短期风速组合预测研究 [J]. 可再生能源, 2015, 33(8) : 1159-1163.
- WANG Xiaoming, XIAO Meng, YANG Nan, et al. A hybrid short-term wind speed forecasting model based on wavelet decomposition and extreme learning machine[J]. Renewable Energy Resources, 2015, 33(8) : 1159-1163.
- [23] 方必武, 刘涤尘, 王波, 等. 基于小波变换和改进萤火虫算法优化 LSSVM 的短期风速预测 [J]. 电力系统保护与控制, 2016, 44(8) : 37-43.
- FANG Biwu, LIU Dichen, WANG Bo, et al. Short-term wind speed forecasting based on WD-CFA-LSSVM model[J]. Power System Protection and Control, 2016, 44(8) : 37-43.
- [24] 颜晓娟, 龚仁喜, 张千峰. 优化遗传算法寻优的 SVM 在短期风速预测中的应用 [J]. 电力系统保护与控制, 2016, 44(9) : 38-42.
- YAN Xiaojuan, GONG Renxi, ZHANG Qianfeng. Application of optimization SVM based on improved genetic algorithm in short-term wind speed prediction[J]. Power System Protection and Control, 2016, 44(9) : 38-42.
- [25] 张雨金, 杨凌帆, 葛双治, 等. 基于 Kmeans-SVM 的短期光伏发电功率预测 [J]. 电力系统保护与控制, 2018, 46(21) : 118-124.
- ZHANG Yujin, YANG Lingfan, GE Shuangye, et al. Short-term photovoltaic power prediction based on Kmeans-SVM[J]. Power System Protection and Control, 2018, 46 (21) : 118-124.
- [26] 李欣民. 清洁能源发电技术及市场现状研究 [J]. 电力需求侧管理, 2017, 19(6) : 29-32.
- LI Xinmin. Research on clean energy power generation technology and market status [J]. Power Demand Side Management, 2017, 19 (6) : 29-32.
- [27] 文凌锋, 党广宇, 田伟, 等. 基于多时间尺度风储协同的微电网能量管理策略研究 [J]. 电力工程技术, 2018, 37(3) : 123-128.
- WEN Lingfeng, DANG Guangyu, TIAN Wei, et al. Research on micro-grid energy management system based on multi-time scale[J]. Electric Power Engineering Technology, 2018, 37 (3) : 123-128.
- [28] 胡智强, 黄南天, 王文婷, 等. 基于布谷鸟搜索优化支持向量机的短期负荷预测 [J]. 水电能源科学, 2016, 34(12) : 209-212.
- HU Zhiqiang, HUANG Nantian, WANG Wenting, et al. Cuckoo search based optimized support vector machine for short-term load forecasting[J]. Water Resources and Power, 2016, 34(12) : 209-212.
- [29] 董振斌, 李义容, 李海思. 考虑风电功率与需求响应不确定性的备用容量配置 [J]. 电力需求侧管理, 2017, 19(1) : 29-34, 44.
- DONG Zhenbin, LI Yirong, LI Haisi. Reserve capacity configuration considering uncertainty of wind power and demand response [J]. Power Demand Side Management, 2017, 19 (1) : 29-34, 44.

作者简介:



刘家敏

刘家敏(1994),男,硕士在读,研究方向为新能源并网运行与控制(E-mail: liujamin_nj@163.com);

李聪睿(1994),男,硕士,研究方向为新能源并网运行与控制;

周志浩(1997),男,学士,研究方向为新能源并网系统稳定与控制。

Combination ultra-short-term prediction of wind power based on WD-CS-SVM

LIU Jiamin, LI Congrui, ZHOU Zhihao, LI Sheng

(School of Electric Power Engineering, Nanjing Institute of Technology, Nanjing 211167, China)

Abstract: In order to improve the prediction accuracy of wind farm output power, wavelet analysis (WD) and cuckoo optimization support vector machine(CS-SVM) algorithm are used to predict wind power in ultra-short term, which is more direct and accurate than indirect wind power obtained by predicting wind speed. Firstly, the wind power model is decomposed into approximate sequence and detail sequence by using wavelet decomposition and reconstruction. Then, the support vector machine optimized by cuckoo algorithm is used to predict each sequence, and the prediction results of each sequence are obtained. Finally, the prediction results of each sequence are superimposed to form the final prediction value of wind power. The results of numerical examples show that the prediction results have high accuracy, and the method used in this paper is more accurate, superior and practical than the support vector machine and other methods optimized support vector machine prediction results.

Keywords: wavelet analysis; cuckoo algorithm; support vector machine; wind power; combination prediction

(编辑 钱悦)