

DOI: 10.19783/j.cnki.pspc.181254

基于 ISMC-PSO 的风电爬坡输出功率预测系统的研究

李永馨, 王 鸿, 王致杰, 王海群

(上海电机学院, 上海 201306)

摘要: 目前风电场都是使用单一的功率爬坡预测模型, 其泛化能力较差, 预测精度低。通过分析支持向量机和极限学习机两种单一功率的爬坡预测模型, 研究了这两种模型的权值选取方法, 提出了一种组合功率爬坡预测模型。该模型使用基于粒子群算法的改进算法对上述两种单一模型的权值进行权重优化, 形成了一种新的高精度的预测系统。然后对该系统进行建模仿真。仿真结果验证了该预测模型的有效性, 其预测精度较之单一的预测模型有了很大的提高。

关键词: 粒子群算法; 风场功率爬坡; 组合预测; 建模仿真

Research on ISMC-PSO based wind uphill power output prediction system

LI Yongxin, WANG Hong, WANG Zhijie, WANG Haiqun

(Shanghai Dianji University, Shanghai 201306, China)

Abstract: At present, wind farms use a single power ramp prediction model, which has poor generalization ability and low prediction accuracy. By analyzing the two single-power ramp-up prediction models of support vector machine and extreme learning machine, the weight selection methods of these two models are studied, and a combined power hill-climbing prediction model is proposed. The model uses the improved algorithm based on particle swarm optimization algorithm to optimize the weights of the above two models, and forms a new high-precision prediction system. Then the system is modeled and simulated. The simulation results verify the effectiveness of the prediction model, and its prediction accuracy is greatly improved compared with the single prediction model.

This work is supported by Open Project of Key Laboratory of Control of Power Transmission and Conversion, Ministry of Education (No. 2016AB14) and National Natural Science Foundation of China (No. 51477099).

Key words: particle swarm optimization; wind power uphill; combination forecast; modeling and simulation

0 引言

近年来, 随着全球能源的日益紧缺, 我国开始大力发展新能源, 风能是目前发展形势较好且利用率较高的一种新型能源, 因此, 越来越多的风电场被建造, 但由于技术的原因, 大量风电在并网时出现了一系列问题, 这些问题之一便是对风电场功率爬坡的预测精度较低^[1]。目前风电场一般使用单一的功率爬坡预测模型, 但单一模型的泛化能力比较差, 所以很难做出精准的预测^[2-4]。本文首先介绍了支持向量机和极限学习机这两种单一功率爬坡预测模型, 通过对这两种模型的权值选取, 提出了一种组合功率爬坡预测模型, 该模型使用基于粒子群算

法的改进算法对上述两种单一模型的权值进行权重优化, 使测量精度大为提高。

1 功率爬坡组合模型的预测算法

目前, 一般的单一功率爬坡预测模型如支持向量机和极限学习机等, 因为权值选取的原因导致测量精度较低^[5], 而若是将两种结合起来形成一个组合预测模型, 通过对其中单一模型的权值进行优化调节, 则能够使整个系统的测量精度有显著的提高。组合模型的表达式为

$$y = \sum_{i=1}^N \omega_i y_i \quad (1)$$

式中: N 表示组合模型组单一模型的数量; y 表示组合模型的预测值; y_i 表示第 i 个单一模型的预测值; ω_i 为第 i 个单一模型的权重系数。

目前现有的传统预测法和智能预测法是较为主

基金项目: 电力传输与功率变换控制教育部重点实验室开放课题资助(2016AB14); 国家自然科学基金项目资助(51477099)

流的两种预测方法。传统预测法中一般包括最优权重系数法和等权平均组合预测法等，其中：最优权重系数法是传统预测法中较为成熟的一种，有着良好的稳定性；而等权平均组合预测法可以将单一预测模型得出的权值平均组合，使预测风险能够得到明显的下降^[4-6]。智能组合预测法是利用鱼群算法和粒子群等智能算法确定每一个单一模型中的权重系数，并且进行组合计算得到最终的预测结果。智能组合预测法能够有效地将不同单一预测方法得出的预测结果进行拟合，降低了确定权重系数的难度，是一种可进一步发展研究的组合预测方法。下面本文介绍了两种常用的权值确定法。

1) 等权重组合预测方法

该方法通过平均各单一模型的预测结果，得出精度相对较高的结果，是一种较为简单的组合预测方法，该预测方法的计算公式为

$$y = \frac{1}{N} \sum_{i=1}^N y_i \quad (2)$$

这种方法通过将单一模型的预测结果组合起来，并取平均值，相对提高了预测精度，降低了单一模型的预测风险，但依旧对各结果利用不充分，不能达到最优效果。

2) 协方差优选权重组合预测方法

该方法的计算公式如式(1)，式中：

$$\sum_{i=1}^N \omega_i = 1 \quad (3)$$

协方差优选权重组合预测方法是一种比较常见的组合模型预测法。其在确定权重系数后，保持权重值不变，这就导致该方法风险变高，且使用门槛较高。

本文为了提高功率爬坡预测的精度，提出了一种智能组合预测方法，该方法通过使用改进过的粒子群算法，对单一预测模型中的权重系数进行优化，降低了单一模型的预测风险，提高了组合预测模型的精度。

2 支持向量机

功率爬坡预测的常用单一模型为支持向量机，该方法还用于模式识别和非线性回归预测，是一种较为流行的预测工具^[7-9]，其优点如下：

- 1) 具有良好的泛化能力，通过降低训练数据的误差，使其达到独立预测且误差较小的目的。
- 2) 通过凸优化的求解方式，降低求解复杂度，即得到的局部最优解便是求解结果。
- 3) 降低求解难度，通过转为线性问题来求解答案。
- 4) 鲁棒性较好，分类间隔大。

设 $\{(x_g, y_g), g = 1, 2, \dots, m\}$ 为训练样本， x_g 为支持向量机的第 g 个样本输入向量， y_g 为第 g 个样本的输出向量^[10]，通过式(4)实现回归拟合：

$$f(x) = \omega \Phi(x) + b \quad (4)$$

式中： $\Phi(x)$ 为非线性映射函数； ω 为加权向量； b 为常数。该训练样本通过对 ξ_g 和 ξ_g^* 的引入，设其在精度 ε 下拟合时无误差，式(4)介绍了如何寻找 ω 和 b 。

$$\begin{cases} \min_{\omega, \xi} \Phi(\omega, \xi) = \frac{1}{2} \|\omega\|^2 + C \sum_{g=1}^m (\xi_g + \xi_g^*) \\ \text{s.t.} \begin{cases} y_g - \omega \Phi(x_g) - b \leq \varepsilon + \xi_g \\ \omega \Phi(x_g) + b - y_g \leq \varepsilon + \xi_g^* \\ \xi_g, \xi_g^* \geq 0 \end{cases} \end{cases} \quad (5)$$

其中： C 为惩罚因子； ε 为回归函数的误差要求，如果 ε 的值越小，则回归函数的误差越小。

再引入拉格朗日函数，可将式(4)转换为求解对偶问题，即

$$\begin{cases} \max_{\mu, \mu^*} \left[-\frac{1}{2} \sum_{g=1}^m \sum_{q=1}^m (\mu_g - \mu_g^*)(\mu_q - \mu_q^*) K(x_g, x_q) - \sum_{g=1}^m (\mu_g + \mu_g^*) \varepsilon + \sum_{g=1}^m (\mu_g - \mu_g^*) y_g \right] \\ \text{s.t.} \begin{cases} \sum_{g=1}^m (\mu_g - \mu_g^*) = 0 \\ 0 \leq \mu_g, \mu_g^* \leq C \end{cases} \end{cases} \quad (6)$$

式中： $K(x_g, x_q) = \Phi(x_g) \Phi(x_q)$ 为核函数；求得的最优解为 $\mu = [\mu_1, \mu_2, \dots, \mu_m]$ 和 $\mu^* = [\mu_1^*, \mu_2^*, \dots, \mu_m^*]$ 。

则回归函数表示为

$$f(x) = \sum_{g=1}^m (\mu_g - \mu_g^*) K(x_g, x) + b \quad (7)$$

其中只有部分 $(\mu_g - \mu_g^*)$ 参数不为 0，其对应的样本 x_g 即为问题中的支持向量。

支持向量机的模型结构如图 1 所示。

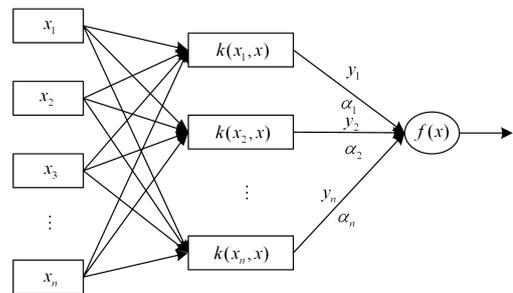


图 1 支持向量机模型结构

Fig. 1 Wind power forecasting structure by support vector machine

常用的核函数如下所示, 其中 K 代表核函数。

1) 线性核函数:

$$K(x, x_i) = x^T x_i$$

2) 多项式核函数:

$$K(x, x_i) = (\gamma x^T x_i + r)^p, \gamma > 0$$

3) 径向基核函数:

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{\gamma}\right), \gamma > 0$$

4) 两层感知器核函数:

$$K(x, x_i) = \tanh(\gamma x^T x_i + r)$$

其中, γ 、 r 、 p 为核心参数。本文核函数选择最常用的径向基函数。

3 基于改进粒子群的风场功率爬坡组合预测

3.1 组合预测建模

通过上述的介绍可以看出支持向量机在风场功率爬坡的预测上有着非常明显的优势, 而另一种极限学习机则是通过单层前馈神经网络设计算法, 其隐含层节点可以是随机的, 也可以是给定且不需要调整的, 具有学习效率高, 泛化能力强等优点^[11-14]。本文通过组合这两种单一模型, 提出了一种新型的风场功率爬坡组合预测模型, 该模型通过改进过的粒子群算法对上述两个单一模型的预测结果进行权重寻优, 从而提高预测结果的精确度。

上述组合预测模型通过如下步骤求解:

1) 通过上述的两个单一模型对风场功率爬坡进行预测。

2) 得到前 20 个 ASTFA-ELM 的预测数据 $a_i (i = 1, 2, \dots, 20)$ 、ASTFA-SVM 的预测数据 $b_i (i = 1, 2, \dots, 20)$ 和实际数据 $c_i (i = 1, 2, \dots, 20)$, 通过下式进行绝对平均误差的求解, 得到初始权值^[15-21]:

$$d_1 = \frac{\sum_{i=1}^{10} |a_i - c_i|}{20} \quad (8)$$

$$d_2 = \frac{\sum_{i=1}^{10} |b_i - c_i|}{20} \quad (9)$$

$$\omega_1 = 1/d_{10} \quad (10)$$

$$\omega_2 = 1/d_{20} \quad (11)$$

其中, ω_1 和 ω_2 分别为在组合预测模型中极限学习机和支持向量机所占的权重, 满足 $\sum_{i=1}^2 \omega_i = 1$ 。

3) 通过对上面所得的初始权值进行 50 次范围为 [0,1] 的扰动, 得到相应的预测值和扰动权值。接

下来, 使用改进的粒子群算法优化得到的扰动权值, 从这些扰动权值中找出平均误差最小的一组作为接下来预测点 ($j = 21$) 中 ASTFA-ELM 和 ASTFA-SVM 的权值 ω_1 和 ω_2 ^[21-23]。

4) 通过加权组合上述得到的权值便可以得出点 ($j = 21$) 的预测值。利用同样的方法使用式(8)和式(9)得到上述 ($j = 22$) 的模型权值, 重复上述步骤, 得出最终的组合模型预测结果。算法流程如图 2。

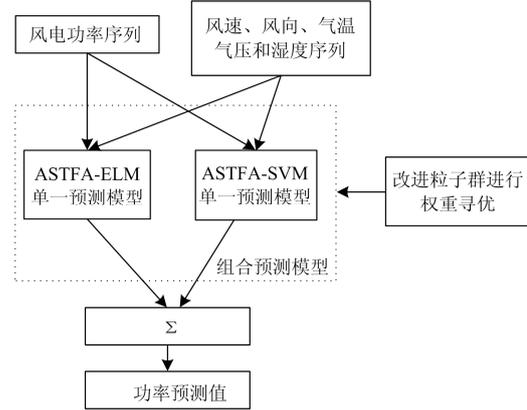


图 2 算法流程图

Fig. 2 Flow chart of algorithm

3.2 算例分析

上文介绍了爬坡预测的组合模型的工作原理和特点, 接下来, 本文采用了华能江苏启东风电场 2014 年 4 月份的实际测量数据对上述模型进行仿真分析, 以此来验证该模型的可行性和准确性^[24]。该仿真数据采用 30 min 的时间间隔的 550 组数据, 其中选取前 500 组作组合预测模型训练, 再对后 50 组数据预测, 从图 3 中可以看出, 组合预测模型预测的范围是 12:00 后 25 小时的这段时间。最后, 将得出的结果再与支持向量机和极限学习机这两个单一预测模型的预测信息进行对比。

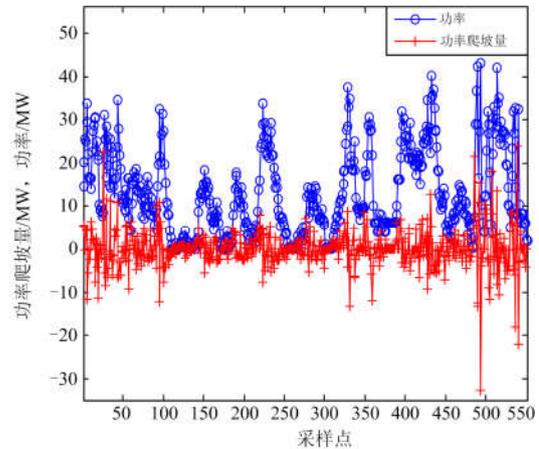


图 3 启东风电场的功率和爬坡量曲线

Fig. 3 Wind power and ramp data of Qidong Wind Plant

图 4 为上述两种单一预测模型的预测结果与组合预测模型预测结果的对比, 而表 1 则是两种单一预测模型与传统 ANN 预测模型的误差同组合预测模型误差的对比。

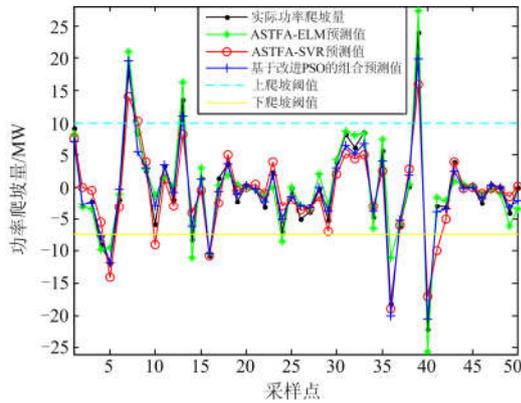


图 4 启东风电场的爬坡量预测结果

Fig. 4 Wind power ramp forecasting of Qidong Wind Plant

表 1 三种模型预测误差比较

Table 1 Forecasting error comparison of three models

| 网络模型 | 预测误差 | |
|---------------------|-------|------|
| | MRE | NMSE |
| ASTFA-ELM 预测模型 | 11.79 | 9.76 |
| ASTFA-SVR 预测模型 | 12.33 | 9.34 |
| ANN 预测模型 | 11.98 | 9.59 |
| 基于 ISMC-PSO 的组合预测模型 | 10.41 | 8.58 |

通过上面的表格可以看出, 本文提出的组合预测模型相比于单一模型, 传统 ANN 预测模型, 其预测结果精度更高, 具有一定的优越性。

表 2 为该组合模型对风场机组功率爬坡的部分预测信息。

表 2 风电功率爬坡事件的预测信息

Table 2 Forecasting information of wind power ramp event

| 爬坡时间 | 13:30—14:15 | | 13:30—14:15 | |
|-----------------|-------------|--------|-------------|--------|
| | 下爬坡 | | 上爬坡 | |
| 爬坡趋势 (剧烈/平缓) | 13:30— | 14:05— | 14:50— | 15:05— |
| | 14:05 | 14:15 | 15:05 | 15:25 |
| | 剧烈 | 平缓 | 剧烈 | 平缓 |
| 爬坡时间 | 18:00—18:10 | | 19:25—19:50 | |
| | 下爬坡 | | 上爬坡 | |
| 爬坡趋势 (剧烈/平缓) | 18:00— | 18:05— | 19:25— | 19:05— |
| | 18:05 | 18:10 | 19:05 | 19:50 |
| | 剧烈 | 平缓 | 剧烈 | 平缓 |

图 5、图 6 为 ASTFA-ELM 预测模型对启东风电场的爬坡预测。

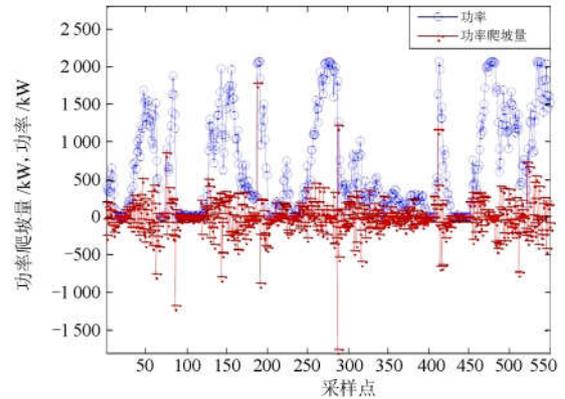


图 5 启东风电场的功率和爬坡量曲线

Fig. 5 Wind power and ramp data of Qidong Wind Plant

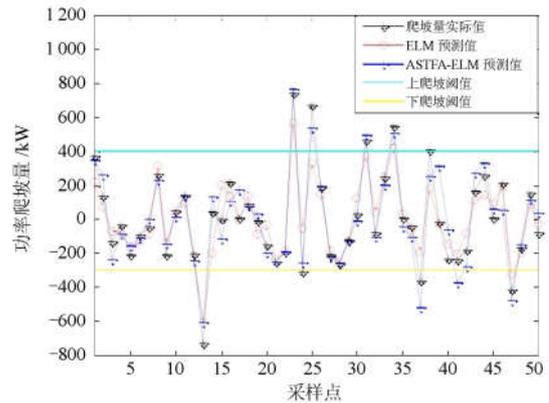


图 6 启东风电场的爬坡量预测结果

Fig. 6 Wind power ramp forecasting of Qidong Wind Plant

表 3 为 ASTFA-ELM 预测模型对风场机组功率爬坡的部分预测信息。

表 3 风电功率爬坡事件的预测信息

Table 3 Forecasting information of wind power ramp event

| 爬坡时间 | 11:25—11:50 | | 14:30—14:40 | |
|-----------------|-------------|--------|-------------|--------|
| | 下爬坡 | | 上爬坡 | |
| 爬坡趋势 (剧烈/平缓) | 11:25— | 11:35— | 14:30— | 14:35— |
| | 11:35 | 11:50 | 14:35 | 14:40 |
| | 剧烈 | 平缓 | 剧烈 | 平缓 |
| 爬坡时间 | 15:45—16:05 | | 17:05—17:40 | |
| | 下爬坡 | | 上爬坡 | |
| 爬坡趋势 (剧烈/平缓) | 15:45— | 15:55— | 17:05— | 17:25— |
| | 15:55 | 16:05 | 17:25 | 17:40 |
| | 剧烈 | 平缓 | 剧烈 | 平缓 |

可以看出 ASTFA-ELM 预测模型预测爬坡量的幅值和爬坡事件的时间区间相对比较准确, 但较之 ISMC-PSO 组合预测模型, 仍有不足。因此可以看出, 基于改进的粒子群优化算法的组合预测模型可

以更准确地预测出功率爬坡的趋势, 明显优于支持向量机和极限学习机这两种单一模型的性能。

4 结论

本文首先提出了建立大型风场功率爬坡的组合预测模型的概念, 通过对 ASTFA-ELM 和 ASTFA-SVM 这两个单一模型使用粒子群算法优化其预测权值, 从而使得组合预测的模型精度提高。最后, 通过对实际数据的设计与仿真, 证明了本文所提的组合预测模型可以正常预测功率爬坡, 并且有着更高的预测精度。

参考文献

- [1] 李如意, 黄明山, 周东国, 等. 基于粒子群算法搜索的非侵入式电力负荷分解方法[J]. 电力系统保护与控制, 2016, 44(8): 30-36.
LI Ruyi, HUANG Mingshan, ZHOU Dongguo, et al. Non-intrusive power load decomposition method based on particle swarm optimization algorithm[J]. Power System Protection and Control, 2016, 44(8): 30-36.
- [2] LIANG J J, QIN A K, SUGANTHAN P N, et al. Comprehensive learning particle swarm optimizer for global optimization of multimodal functions[J]. IEEE Transactions on Evolutionary Computation, 2006, 10(3): 281-295.
- [3] 田蓓, 于珍, 李旭涛, 等. 考虑多风电场功率相关性的概率潮流联合分布计算[J]. 中国电力, 2017, 50(10): 71-77.
TIAN Bei, YU Zhen, LI Xutao, et al. The probabilistic flow joint distribution calculation considering the power correlation of multiple wind farms[J]. Electric Power, 2017, 50(10): 71-77.
- [4] 沈同, 王通通, 宋汉梁. 大规模风电经柔直并网时的系统稳态控制策略[J]. 电网与清洁能源, 2017, 33(12): 109-114, 122.
SHEN Tong, WANG Tongtong, SONG Hanliang. Steady-state control strategy of large-scale wind power connected by soft and straight grid[J]. Power System and Clean Energy, 2017, 33(12): 109-114, 122.
- [5] LI X. Niching without niching parameters: particle swarm optimization using a ring topology[J]. IEEE Transactions on Evolutionary Computation, 2010, 14(1): 150-169.
- [6] BRITS R, ENGELBRECHT A P, VAN DEN BERGH F. A niching particle swarm optimizer[C] // Proceedings of the 4th Asia-Pacific Conference on Simulated Evolution and Learning, Singapore: Orchid Country Club, 2002: 692-696.
- [7] 程声烽, 程小华, 杨露. 基于改进粒子群算法的小波神经网络在变压器故障诊断中的应用[J]. 电力系统保护与控制, 2014, 42(19): 37-42.
CHENG Shengfeng, CHENG Xiaohua, YANG Lu. Application of wavelet neural network based on improved particle swarm optimization algorithm in transformer fault diagnosis[J]. Power System Protection and Control, 2014, 42(19): 37-42.
- [8] 程宇旭. 基于改进粒子群算法的微电网能量优化调度研究及实现[D]. 长沙: 中南大学, 2013.
CHENG Yuxu. Research and implementation of energy optimization scheduling for microgrid based on improved particle swarm optimization algorithm[D]. Changsha: Central South University, 2013.
- [9] ZHAN Z H, ZHANG J, LI Y, et al. Adaptive particle swarm optimization[J]. IEEE Transactions on, Systems, Man, and Cybernetics, Part B: Cybernetics, 2009, 39(6): 1362-1381.
- [10] 高尚. 线性组合预测的推广[J]. 中南大学学报(自然科学版), 2013, 44(增刊 2): 178-182.
GAO Shang. The extension of linear combination forecasting[J]. Journal of Central South University (Science and Technology), 2013, 44(S2): 178-182.
- [11] 牛晨光, 游晓科, 赵震云, 等. 风电场发电功率短期预测组合模型研究[J]. 华北电力大学学报(自然科学版), 2012, 39(3): 29-34.
NIU Chenguang, YOU Xiaoke, ZHAO Zhenyun, et al. Study on short-term predictive combination model of wind farm power generation[J]. Journal of North China Electric Power University (Natural Science), 2012, 39(3): 29-34.
- [12] 刘代刚, 周峥, 杨楠, 等. 基于最小二乘支持向量机的风功率短期预测[J]. 陕西电力, 2014, 42(10): 18-21.
LIU Daigang, ZHOU Zheng, YANG Nan, et al. Short-term prediction of wind power based on least squares support vector machine[J]. Shaanxi Electric Power, 2014, 42(10): 18-21.
- [13] 刘晓春, 李国华, 武梦龙. 基于主成分分析和支持向量机的结构损伤识别研究[J]. 工程建设, 2018(3): 15-20.
LIU Xiaochun, LI Guohua, WU Menglong. Study on structural damage identification based on principal component analysis and support vector machine[J]. Engineering Construction, 2018(3): 15-20.
- [14] 张东英, 代悦, 张旭, 等. 风电爬坡事件研究综述及展望[J]. 电网技术, 2018, 42(6): 1783-1792.
ZHANG Dongying, DAI Yue, ZHANG Xu, et al. Summary and prospect of wind power hill climb event research[J]. Power System Technology, 2018, 42(6): 1783-1792.

- [15] 孔亚伟. 大规模风电接入系统爬坡风险决策研究[D]. 济南: 山东大学, 2017.
KONG Yawei. Study on the decision-making of climbing risk of large-scale wind power access system[D]. Jinan: Shandong University, 2017.
- [16] 杨家然. 计及风力发电的电力系统优化调度研究[D]. 大连: 大连海事大学, 2017.
YANG Jiaran. Study on power system optimization scheduling considering wind power generation[D]. Dalian: Dalian Maritime University, 2017.
- [17] LINK R J, ZIMMERMAN D C. Structural damage diagnosis using frequency response functions and orthogonal matching pursuit: theoretical development[J]. Structure Control & Health Monitoring, 2015, 22(6): 889-902.
- [18] 余立武, 李浩然, 刘岩. 考虑分布式电源出力随机性的配电网无功优化策略[J]. 电网与清洁能源, 2017, 33(12): 91-98.
YU Liwu, LI Haoran, LIU Yan. Reactive power optimization strategy for distribution network considering the randomness of distributed power output[J]. Power System and Clean Energy, 2017, 33(12): 91-98.
- [19] 杨茂, 杜刚. 基于 t Location-Scale 分布的风电功率概率预测研究[J]. 中国电力, 2017, 50(1): 140-145.
YANG Mao, DU Gang. Study on wind power probability prediction based on t location-scale distribution[J]. Electric Power, 2017, 50(1): 140-145.
- [20] 杨茂, 马剑, 李大勇, 等. 超短期风电功率爬坡事件检测和统计分析[J]. 电力系统保护与控制, 2018, 46(6): 62-68.
YANG Mao, MA Jian, LI Dayong, et al. Detection and statistical analysis of ultra-short-term wind power hill climb event[J]. Power System Protection and Control, 2018, 46(6): 62-68.
- [21] 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. A short-term wind power combination forecast based on AMD-ICSA-SVM[J]. Power System Protection and Control, 2017, 45(14): 113-120.
- [22] 孙莹. 风电功率爬坡事件预测方法研究[D]. 北京: 华北电力大学, 2017.
SUN Ying. Study on prediction method of wind power climbing event[D]. Beijing: North China Electric Power University, 2017.
- [23] KOMATY A, BOUDRAA A O, NOLAN J P, et al. On the behavior of EMD and MEMD in presence of symmetrical α -stable noise[J]. IEEE Signal Processing Letters, 2015, 22(7): 818-822.
- [24] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.

收稿日期: 2018-10-10; 修回日期: 2018-12-27

作者简介:

李永馨(1995—), 女, 硕士研究生, 研究方向为分布式发电并网技术。E-mail: 751090538@qq.com

(编辑 葛艳娜)