

DOI: 10.7667/PSPC160483

基于 IAFSA-BPNN 的短期风电功率预测

张颖超^{1,2}, 王雅晨¹, 邓华^{1,2}, 熊雄², 陈浩¹

(1. 南京信息工程大学信息与控制学院, 江苏 南京 210044;
2. 南京信息工程大学气象灾害预报预警与评估协同创新中心, 江苏 南京 210044)

摘要: 为提高短期风电功率预测精度, 提出一种基于 IAFSA-BPNN 的短期风电功率预测方法。该方法通过改进的人工鱼群算法来优化 BP 神经网络的权值和阈值, 从而提高 BP 神经网络的收敛速度和泛化能力。利用 2014 年上海某风场实测数据对新算法进行检验。试验结果表明, 改进的人工鱼群算法一定程度上克服了原算法后期搜索的盲目性较大, 收敛速度减慢, 搜索精度变低的缺陷。IAFSA-BPNN 混合算法在预测的稳定性和精度、收敛速度等方面优于 BPNN、AFSA-BPNN 算法。IAFSA-BPNN 算法不仅能提高短期风电功率预测的精度, 而且改善了预测结果稳定性。

关键词: 短期风电功率预测; 人工鱼群算法; BP 神经网络; IAFSA-BPNN

IAFSA-BPNN for wind power probabilistic forecasting

ZHANG Yingchao^{1,2}, WANG Yachen¹, DENG Hua^{1,2}, XIONG Xiong², CHEN Hao¹

(1. School of Information and Control, Nanjing University of Information Science & Technology, Nanjing 210044, China;
2. Collaborative Innovation Center on Forecast and Evaluation of Meteorological Disasters,
Nanjing University of Information Science & Technology, Nanjing 210044, China)

Abstract: A method based on Improvement Artificial Fish Swarm Algorithm (IAFSA)-BP neural network algorithm is presented for improving the accuracy of short-term wind power forecasting. It optimizes the weights and thresholds of BPNN and improves the BPNN generalization capacity and the rate of convergence. By using the historical data of a wind farm of Shanghai in 2014, IAFSA is proposed to overcome the defects of traditional Artificial Fish Swarm Algorithm such as the blindness of searching, slow convergence speed and low searching precision at the later stage. The simulation result compared with BP neural network and AFSA-BPNN algorithm shows that the IAFSA-BPNN algorithm can not only improve the prediction accuracy and stability, but also shorten the model's rate of convergence, and improve the precision and stability in short-term wind power forecasting.

This work is supported by National Natural Science Foundation of China (No. 41675156), and Prior Discipline Construction Project of Jiangsu Universities (No. PAPD), and Jiangsu Six Major Talents Peaks Project (No. WLW-021).

Key words: short-term wind power prediction; AFSA; BPNN; IAFSA-BP

0 引言

随着全球气候变暖和石油、天然气等不可再生资源的枯竭, 对于清洁、可再生能源的开发和利用日益受到世界各国的高度重视。风能作为一种高效清洁的可再生资源, 得到了广泛的开发和利用。截至 2015 年上半年, 全球风力发电总装机容量已经达

到 392.93 GW, 占全球总发电量的 4%, 我国的装机容量已经达到 124.710 GW^[1]。然而, 风具有间歇性、波动性等特点, 决定了风力发电的不稳定性, 是制约风电大规模并网的关键原因。准确的短期风功率预测是解决这一矛盾的关键手段。国外从 20 世纪 90 年代初, 就开始了短期风电功率预测方法的研究^[2], 我国风电功率预测起步较晚, 在预测精度、可靠性和对不同风场的适应性方面仍然有许多不足。因此, 对短期风电功率预测的研究对于我国风电行业的发展具有重要意义, 已经成为相关研究人员的研究热点^[3-5]。

基金项目: 国家自然科学基金项目 (41675156); 江苏省高校优势学科建设工程资助项目 (PAPD) 与江苏省六大人才高峰项目 (WLW-021) 共同资助

目前短期风电功率预测方法有: 基于数值天气预报的物理模型预测方法; 统计预测方法^[6]; 空间相关性方法^[7]等。其中, 统计预测方法又分为传统统计方法、人工智能方法、复杂逻辑方法以及高斯过程方法等^[8-10]。

随着人工智能技术的发展, 人工神经网络在短期风电功率预测中的应用最为广泛。其中, 又以误差反向传播(Back Propagation, BP)神经网络运用最广^[11-13]。BPNN 具有很强的非线性映射能力, 且灵活性较大。但是 BP 算法存在容易陷入局部极小值、收敛速度慢、迭代时间长等一些固有缺陷, 虽然有了一些优化算法与神经网络结合, 在精度和收敛速度方面均有提高, 但是仍然存在局部收敛及优化时间较长的问题。因此, 寻求更高效的优化算法是提高神经网络预测精度的关键步骤之一。

人工鱼群算法(Artificial Fish Swarm Algorithm, AFSA)是一种模拟鱼群行为的随机搜索优化算法, 具有收敛速度快、精确度高、操作简单、易于与其他方法融合的特点^[14-15], 已经广泛运用到智能算法的参数优化中。但算法后期搜索盲目性大, 收敛速度较慢, 通过改进步长、视野; 添加拥挤因子、竞争机制、淘汰机制^[16]等方式, 可以克服以上问题的存在。本文对 AFSA 进行了改进, 并用来优化 BP 神经网络的权值和阈值, 从而提高 BP 神经网络短期风电功率预测的精度, 即 IAFSA-BPNN 短期风电功率预测法。

1 改进人工鱼群算法

1.1 人工鱼群算法及其改进

AFSA 优化算法是利用鱼的基本行为特点, 从构造单独一条鱼的底层行为做起, 通过鱼群中个体的局部寻优, 实现全局最优值在群体中突现出来的目的。主要包含觅食行为、聚群行为和追尾行为。其中觅食行为是人工鱼根据当前的适应值随机移动的行为, 而聚群和追尾行为则是在保证不与种群中其他个体过于拥挤并且与临近个体的平均移动方向一致的情况下向群体极值处移动的行为。算法的运算过程就是人工鱼群个体的活动过程。由此可见, 人工鱼群在寻优过程中充分利用自身信息和环境信息来调整自身的搜索方向, 从而最终到达食物浓度最高的地方, 即全局极值。

但该算法存在下列问题: 1) 容易陷入局部最优; 2) 觅食行为是随机进行的, 存在迂回搜索的问题, 难获取精确解, 使用随机选择的方法, 没有充分利用已经得到的有利信息; 3) 人工鱼群算法运行后期搜索的盲目性较大, 收敛速度减慢, 搜索精度变低。

本文针对上述问题提出了一种新的改进人工鱼群算法(Improvement Artificial Fish Swarm Algorithm, IAFSA)。

假设某一条人工鱼的当前位置为 $X = (x_1, x_2, \dots, x_n)$, 它的视野范围为 $visual$, 位置 $X_v = (x_1^v, x_2^v, \dots, x_n^v)$ 是其在某一时刻视觉所在的位置, 如果该处的食物浓度 $fc(\bullet)$ 的值高于当前位置, 则考虑向该位置方向移动一步, 即到达位置 X_{next} ; 如果视觉 X_v 处的食物浓度 $fc(\bullet)$ 的值不高于前位置, 则继续寻找视野内的其他位置。搜索的次数越多, 对视野内的食物状态了解越全面, 即对周围环境有一个全方位的认知, 有助于做出全局性的判断。

该过程可以表示为

$$x_i = x_i + visual \cdot r, \quad i = 1, 2, \dots, n \quad (1)$$

$$X_{next} = \frac{X_v - X}{\|X_v - X\|} \cdot Step \cdot r \quad (2)$$

式中: r 为 $[-1, 1]$ 之间均匀分布的伪随机数; $visual$ 是人工鱼的视野; $Step$ 是人工鱼的步长。

本文通过引入调整因子 $g(k), k = 1, 2, \dots, n$, 调整第 $k+1$ 和第 k 次视野和步长的关系, 改进人工鱼群的视野范围和步长。调整方式如式(3)。

$$\begin{cases} visual_{k+1} = g(k) \times visual_k + visual \min \\ Step_{k+1} = g(k) \times Step_k + Step \min \end{cases} \quad (3)$$

式中: $visual_{k+1}$ 和 $visual_k$ 分别为第 $k+1$ 和第 k 次搜索视野; $Step_{k+1}$ 和 $Step_k$ 分别为第 $k+1$ 和第 k 次搜索步长; $g(k)$ 为调整因子, 即

$$g(k) = -\frac{1}{2} \tan \text{sig}\left(\frac{m \times (\frac{k}{n} - 0.5)}{2} + 1\right) \quad (4)$$

值域为 $[0, 1]$, m 为调整因子的调整幅度, 函数图像如图 1 所示。

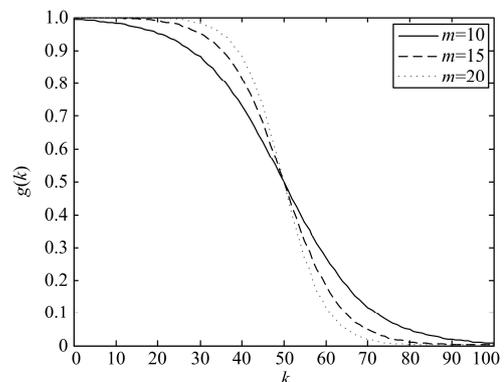


图 1 调整因子 $g(k)$ 的函数图像

Fig. 1 Function image of adjustment factors $g(k)$

$g(k)$ 随着迭代次数的增加, 逐步减小人工鱼群的视野和步长, 由全局搜索逐步演化为局部搜索。在最优解附近区域后进行精细搜索, 能加快算法的收敛速度, 提高局部搜索能力, 进而提高算法的精确度。

而整个鱼群的每一次迭代, 人工鱼群中的最优个体如果没有改变, 则将其保持不变; 发生改变, 就需要更新状态。这样既可以较好地利用当前的有利信息, 又可以探索新的领域, 即较好地保持了算法在寻优过程中的平衡。

1.2 IAFSA 算法评估

采用非线性二元函数 Schaffer 函数来验证 IAFSA 算法的性能。函数如式(5)所示。

$$\min f(x, y) = 0.5 + \frac{(\sin \sqrt{x^2 + y^2})^2 - 0.5}{(1 + 0.001(x^2 + y^2))^2} \quad (5)$$

式中, $-10.0 \leq x, y \leq 10.0$ 。Schaffer 函数具有无数个极小值, 在 (0,0) 点处取得最小值 0。

分别用 AFSA 和 IAFSA 对该函数进行测试仿真。对测试函数进行 100 次试验, AFSA 的适应度平均值为 0.0073, IAFSA 的适应度平均值为 0.0009, 试验结果如图 2 所示。可以看出, 本文所提出的 IAFSA 算法在搜索精度和收敛速度上, 均优于传统 AFSA 算法。尤其 IAFSA 算法在 20 次迭代后, 精度就已经比较高了, 而传统 AFSA 算法要在接近 60 次迭代后, 才能达到较高的精度。

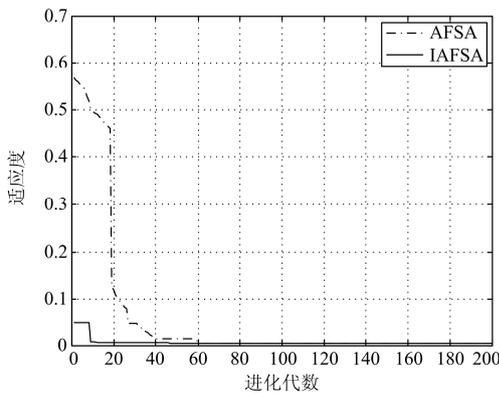


图 2 AFSA 与 IAFSA 收敛情况对比
Fig. 2 Convergence condition contrast between AFSA and IAFSA

2 IAFSA-BPNN 混合算法

本文采用具有单隐含层的 BPNN, 隐含层采用 S 型激活函数, 输出层采用线性激活函数, 其网络结构可以表示为图 3。

输入向量和输出向量为

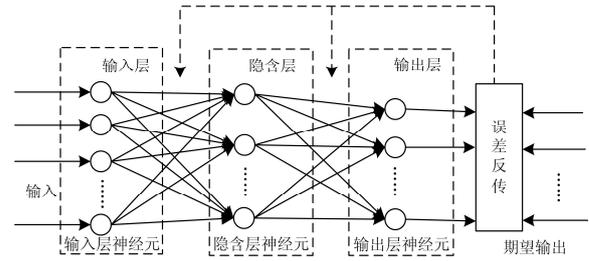


图 3 BPNN 结构图

Fig. 3 Schematic diagram of typical BP networks

$$I_i = [I_{i1}, I_{i2}, \dots, I_{iM}] \quad (6)$$

$$y = F(I_i) \quad (7)$$

本文建立了 IAFSA-BPNN 混合算法。流程如图 4 所示, 左侧为人工鱼群算法部分, 右侧为神经网络部分。首先设定 IAFSA 的参数; 然后随机产生人工鱼初始群体, 以后各代人工鱼的状态根据它的行为状态函数随觅食、聚群及追尾状态变化而决定; 接着, 用 IAFSA 反复优化 BP 网络的权值和阈值, 直至适应度函数即食物浓度函数不再有意义地增加为止。在此基础上, 再用 BP 网络对所得网络参数进一步优化, 直至搜索到最优网络参数, 此时即可得到最优权值和阈值。BP 神经网络的均方误差函数的倒数即为食物浓度如式(8)。

$$E = 1/fc = \frac{1}{N} \sum_{p=1}^n \sum_{k=1}^R (Y_k^p - h_k^p)^2 \quad (8)$$

式中: N 为样本总数; R 为输出节点数; h_k^p 为输出节点 k 在样本 p 作用时的输出; Y_k^p 为在样本 p 作用时输出节点 k 的目标值; $fc(\cdot)$ 为人工鱼当前位置的食物浓度。

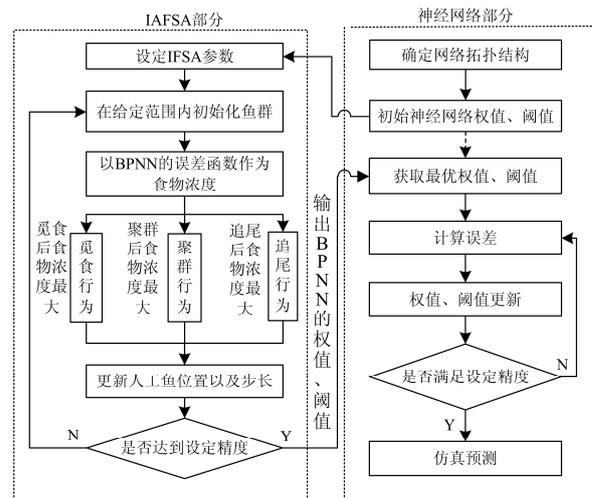


图 4 IAFSA-BPNN 流程图

Fig. 4 Prediction process of neural network model optimized by IAFSA

3 IAFSA-BPNN 在短期风电功率中的应用

3.1 试验数据及模型参数的选取

本文数据采用上海某风电场 2014 年 30 台风机的实际发电功率和风机监测系统采集的风速数据, 时间分辨率为 15 min, 以及 2014 年全年的测风塔数据, 时间分辨率为 15 min。30 台风机型号相同, 其切入风速为 3 m/s, 额定风速 12 m/s, 切出风速 25 m/s, 额定功 2 MW, 风轮直径 93 m, 扫风面积 6 793 m²。因为该风电场处于季风区, 具有明显的季节特征, 为此将试验数据分为春、夏、秋、冬四个季节分别进行试验, 并且在 30 台风机中选取该季度未出现脱网、故障、检修的风机的功率数据。

由于风速是影响风电功率的最主要因素, 因此本文仅将风速作为单一神经网络输入。根据 Kolmogorov 定理^[17]确定隐含层节点数, 并在此基础上采用试验法逐渐增加隐含层神经元个数, 从而得到最佳隐含层神经元个数为 20。输出层只有一个节点即预测模型的预测功率。故本文共有 40 个权值、

21 个阈值共 61 个待优化参数。

IAFSA 的初始参数分别为: 人工鱼数目为 100, 人工鱼群为一个 61×100 的矩阵, 最大迭代次数为 100 次, 最大试探次数为 100 次, 初始视野为 1, 初始移动步长 0.1, 拥挤度为 0.618, 调整因子 m 的幅值为 10。

3.2 方法评估及误差分析

将每个季度最后一天的数据作为测试集, 该季度中其他天数的数据作为训练样本集。首先通过以下两种指标来评价预测效果, 分别是均方根误差 (RMSE) 和绝对平均误差 (MAE), 其中, RMSE 用来衡量误差的分散程度, MAE 衡量预测误差的平均幅度。为评价 IAFSA-BPNN 算法的预测效果, 将通过上述的训练样本分别用 BPNN, AFSA-BPNN 以及 IAFSA-BPNN 预测模型训练, 并用同一样本检验。为了避免单次训练结果的偶然性, 分别对模型进行 10 次训练, 取 10 次预测结果的平均值作为最终的预测功率, 得出相应的风电功率均方根误差 (RMSE) 和绝对平均误差 (MAE)^[18] 结果如表 1 所示。

表 1 几种预测算法预测精度对比

Table 1 Normalized absolute mean error and root mean square error of different models

时间	BPNN		AFSA-BPNN		IAFSA-BPNN	
	MAE/kW	RMSE/kW	MAE/kW	RMSE/kW	MAE/kW	RMSE/kW
春季	26.832	38.165	25.474	36.823	25.211	37.026
夏季	41.019	61.253	40.451	59.376	39.384	58.391
秋季	29.867	42.237	28.683	41.52	28.133	40.757
冬季	35.939	53.825	33.929	51.177	32.005	50.281
均值	33.414	48.87	32.134	47.224	31.183	46.613

从表1可以看出, 在每组数据试验下, IAFSA-BPNN的输出结果较BPNN, AFSA-BPNN的MAE以及RMSE都有减小, 相比较前三个季度的试验结果, 冬季的预测结果在RMSE和MAE上提高最多, 验证了IAFSA-BPNN算法在风电功率预测中的合理性。

图 5 为 BP 神经网络在使用 AFSA 和 IAFSA 算法优化前后收敛特性的对比, 从图中可以清晰地看出, 使用 AFSA 算法优化的 BP 神经网络收敛速度要明显快于传统 BP 神经网络, 而 IAFSA-BPNN 算法的收敛速度又明显快于 AFSA-BPNN。

为了更好地说明本文所提出算法的有效性, 从上述试验中抽取 2014 年冬季的训练结果, 运用相对误差和误差概率分布^[19]对三种模型的预测效果进行评估。

图 6 为 BPNN、AFSA-BPNN 和 IAFSA-BPNN 的预测相对误差比较图。由图可知, 在大多数时间点上, IAFSA-BPNN 算法预测的相对误差较 BPNN、

AFSA-BPNN 都有减小, 说明其预测结果比其他预测模型的预测结果更接近实际风电功率输出数据, 预测效果最好。

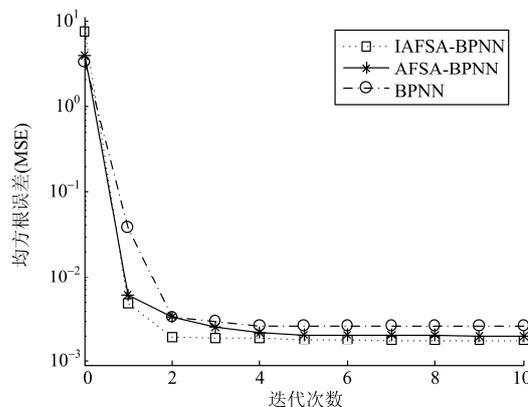


图 5 BPNN 优化前后收敛情况对比

Fig. 5 Comparison of convergence condition before and after neural network optimization

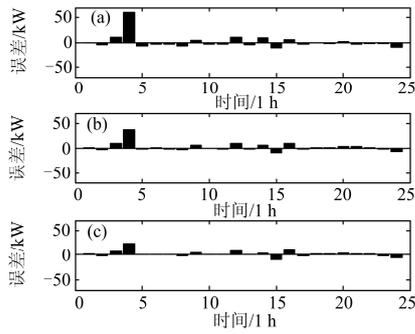


图 6 BPNN, AFSA-BPNN, IAFSA-BPNN 三种预测模型的相对误差比较(a~c)

Fig. 6 Relative error of BPNN, AFSA-BPNN, IAFSA-BPNN models at each time point (a~c)

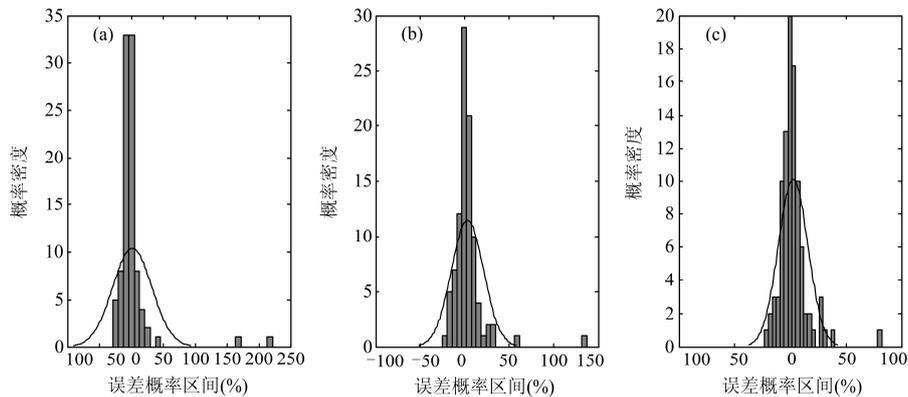


图 7 BPNN, AFSA-BPNN, IAFSA-BPNN 三种预测模型误差概率分布比较(a~c)

Fig. 7 Histogram of error frequency distribution of BPNN, AFSA-BPNN and IAFSA-BPNN models (a~c)

4 结论

本文提出了一种新的风电功率预测算法 IAFSA-BPNN 混合算法, 对 2014 年上海某风场的数据进行试验, 并与 BPNN, AFSA-BPNN 算法进行比较, 利用 4 项性能指标 MAE, RMSE, RE 以及误差概率分布来评估其性能, 试验表明 IAFSA-BPNN 算法具有更快的收敛速度以及更好的稳定性, 为短期风电功率预测提供了一种科学、有效的方法。通过不同的试验可以得到以下结论:

1) 改进的人工鱼群算法(IAFSA)改善了传统人工鱼群算法(AFSA)运行后期搜索的盲目性较大, 收敛速度减慢, 搜索精度变低的缺陷。

2) IAFSA-BPNN 混合算法较 BPNN、AFSA-BPNN 算法在各组试验的 MAE、RMSE 中均有减小, 表明预测精度有所提高。同时, IAFSA-BPNN 混合算法的收敛速度也优于 AFSA-BPNN 和 BPNN。

3) IAFSA-BPNN 混合算法的误差概率分布更加集中, 说明 IAFSA-BPNN 混合算法的粗大误差较 BPNN, AFSA-BPNN 算法明显减少, 预测结果更加

图 7 为 BPNN, AFSA-BPNN 和 IAFSA-BPNN 的预测误差概率分布直方图。其中横坐标为误差区间, 纵坐标为对应概率区间上的误差的概率密度。可以看出几种预测方法误差的拟合分布曲线从形态上有从“矮胖”型到“高瘦”型的变化趋势, 说明 IAFSA-BPNN 算法的粗大误差较 BPNN, AFSA-BPNN 算法明显减少, 误差分布更加集中, 预测结果更加稳定, 预测数据更有利于电力系统的调度和运营^[20]。因此, 本文提出的 IAFSA-BPNN 预测模型是稳定的、实用的, 适用于风电功率的短期预测。

稳定, 预测数据更有利于电力系统的调度和运营。

IAFSA 算法完善了 AFSA 算法的一些缺陷, 同时 IAFSA-BPNN 混合算法为 BP 神经网络的权值和阈值的选择提供了一种新的、可行有效的优化方法, 改善了 BP 神经网络的泛化能力。以上只是新算法在短期风电功率预测的初步研究, 该算法对于其他优化算法以及其他预测算法是否具有优越性还有待进一步深入研究。

参考文献

- [1] World Wind Energy Association. World wind energy report 2015[J]. WWEA: 2015.
- [2] COSTA A, CRESPO A, NAVARRO J, et al. A review on the young history of the wind power short-term prediction[J]. Renewable and Sustainable Energy Reviews, 2008, 12(6): 1725-1744.
- [3] WANG J, BOTTERUD A, BESSA R, et al. Wind power forecasting uncertainty and unit commitment[S]. Apply Energy, 2011, 88(11): 4014-4023.
- [4] 杨志凌. 风电场功率短期预测方法优化的研究[D]. 北京: 华北电力大学, 2011.
YANG Zhiling. Optimization for short-term wind power

- prediction method[D]. Beijing: North China Electric Power University, 2011.
- [5] 薛禹胜, 雷兴, 薛峰, 等. 关于风电不确定性对电力系统影响的评述[J]. 中国电机工程学报, 2014, 34(29): 5029-5040.
XUE Yusheng, LEI Xing, XUE Feng, et al. A review on impacts of wind power uncertainties on power systems[J]. Proceedings of the CSEE, 2014, 34(29): 5029-5040.
- [6] BILLINTON R, CHEN H, GHAJAR R. A sequential simulation technique for adequacy evaluation of generating systems including wind energy[J]. IEEE Transactions on Energy Conversion, 1996, 11(4): 728-734.
- [7] JUNG J, BROADWATER R P. Current status and future advances for wind speed and power forecasting[J]. Renewable and Sustainable Energy Reviews, 2014, 31: 762-777.
- [8] 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.
- [9] FOLEY A M, LEAHY P G, MARVUGLIA A, et al. Current methods and advances in forecasting of wind power generation[J]. Renewable Energy, 2012, 37(1): 1-8.
- [10] 张颖超, 郭晓杰, 叶小岭, 等. 一种短期风电功率集成预测方法[J]. 电力系统保护与控制, 2016, 44(7): 90-95.
ZHANG Yingchao, GUO Xiaojie, YE Xiaoling, et al. An integrated forecasting method of short-term wind power[J]. Power System Protection and Control, 2016, 44(7): 90-95.
- [11] TASICIKARAOGLU A, UZUNOGLU M. A review of combined approaches for prediction of short-term wind speed and power[J]. Renewable and Sustainable Energy Reviews, 2014, 34: 243-254.
- [12] 肖迁, 李文华, 李志刚, 等. 基于改进的小波-BP 神经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.
- [13] 范高锋, 王伟胜, 刘纯. 基于人工神经网络的风电功率短期预测系统[J]. 电网技术, 2008, 32(22): 72-76.
FAN Gaofeng, WANG Shengwei, LIU Chun. Artificial neural network based wind power short term prediction system[J]. Power System Technology, 2008, 32(22): 72-76.
- [14] 李晓磊, 邵之江, 钱积新. 一种基于动物自治体的寻优模式: 鱼群算法[J]. 系统工程理论与实践, 2002, 22(11): 32-38.
LI Xiaolei, SHAO Zhijiang, QIAN Jixin. An optimizing method based on autonomous animals: fish-swarm algorithms[J]. Systems Engineering-theory and Practice, 2002, 22(11): 32-38.
- [15] 李晓磊, 钱积新. 基于分解协调的人工鱼群优化算法研究[J]. 电路与系统学报, 2003, 8(1): 1-6.
LI Xiaolei, QIAN Jixin. Studies on artificial fish swarm optimization algorithm based on decoma position and coordination techniques[J]. Journal of Circuits and Systems, 2003, 8(1): 1-6.
- [16] 王永翔, 陈国初. 基于改进鱼群优化支持向量机的短期风电功率预测[J]. 电测与仪表, 2016, 53(3): 80-84.
WANG Yongxiang, CHEN Guochu. Short-term wind power prediction based on IAFSA optimization SVM[J]. Electrical Measurement and Instrumentation, 2016, 53(3): 80-84.
- [17] 刘耦耕, 贺素良. BP 神经网络结构参数的计算机自动确定[J]. 计算机工程与应用, 2004, 40(13): 72-74.
LIU Ougeng, HE Suliang. Determining automatically structure parameters of BP artificial neural network by a computer[J]. Computer Engineering and Applications, 2004, 40(13): 72-74.
- [18] 徐曼, 乔颖, 鲁宗相. 短期风电功率预测误差综合评价方法[J]. 电力系统自动化, 2011, 35(12): 20-26.
XU Man, QIAO Ying, LU Zongxiang. A comprehensive error evaluation method for short-term wind power prediction[J]. Automation of Electric Power Systems, 2011, 35(12): 20-26.
- [19] 刘立阳, 吴军基, 孟绍良. 短期风电功率预测误差分布研究[J]. 电力系统保护与控制, 2013, 41(12): 65-70.
LIU Liyang, WU Junji, MENG Shaoliang. Research on error distribution of short-term wind power prediction[J]. Power System Protection and Control, 2013, 41(12): 65-70.
- [20] 林卫星, 文劲宇, 艾小猛, 等. 风电功率波动特性的概率分布研究[J]. 中国电机工程学报, 2012, 32(1): 38-46.
LIN Weixing, WEN Jinyu, AI Xiaomeng, et al. Probability density function of wind power variations[J]. Proceedings of the CSEE, 2012, 32(1): 38-46.

收稿日期: 2016-04-07; 修回日期: 2016-06-29

作者简介:

张颖超(1960-), 男, 教授, 博士生导师, 研究方向为复杂系统建模与评估、灾害评估与损失预测、气象服务效益研究、风电功率预测、气象数据质量控制等;

王雅晨(1989-), 女, 通信作者, 硕士研究生, 主要研究方向为短期风电功率预测. E-mail: yachenw0608@163.com

(编辑 魏小丽)