

DOI: 10.11830/ISSN.1000-5013.201906031



# 自适应变异粒子群优化 BP 的 短期风电功率预测模型

王 粟, 邱春辉, 曾 亮

(湖北工业大学 太阳能高效利用及储能运行控制湖北省重点实验室, 湖北 武汉 430068)

**摘要:** 针对反向传播(BP)神经网络预测模型在风电预测中预测精度低、输入变量多的问题,提出一种基于互信息的自适应变异粒子群优化 BP 的短期风电功率预测模型. 首先,采用互信息筛选出原始数据中与输出功率相关度较大的影响因素,减少冗余信息;然后,引入具有自适应惯性权重系数和变异因子思想的粒子群算法对预测模型进行优化. 结果表明:与传统预测模型相比,该预测模型具有收敛速度快、预测精度高等特点.

**关键词:** 短期风电预测; 互信息; 自适应惯性权重系数; 变异因子; 反向传播神经网络

**中图分类号:** TM 614; TP 183      **文献标志码:** A      **文章编号:** 1000-5013(2020)01-0090-06

## Short-Term Wind Power Prediction Model of Adaptive Mutation Particle Swarm Optimization BP

WANG Su, QIU Chunhui, ZENG Liang

(Hubei Key Laboratory for High-Efficiency Utilization of Solar Energy and Operation Control of  
Energy Storage System, Hubei University of Technology, Wuhan 430068, China)

**Abstract:** Aiming at the problem that back propagation (BP) neural network prediction model has low prediction accuracy and large input variables in wind power prediction, a short-term wind power prediction model based on mutual information of the adaptive mutation particle swarm optimization BP is proposed. Firstly, the mutual information is used to screen out the influencing factors of the original data with high correlation in the output power, and the redundant information is reduced. Then, the particle swarm algorithm based on the idea of adaptive inertia weight coefficient and variation factor is introduced to optimize the prediction model. The results show that compared with the traditional prediction model, the proposed model has the characteristics of fast convergence and high prediction accuracy.

**Keywords:** short-term wind power prediction; mutual information; adaptive inertia weight coefficient; variation factor; back propagation neural network

风能的不可控制性使准确预测其输出功率的难度较大<sup>[1-3]</sup>. 采用反向传播(BP)神经网络预测模型能够较好地预测基于影响因素的输出功率,但其预测精度低、运行速度慢,需要进行改进<sup>[4-5]</sup>. 文献[6]提出一种在传统的 BP 神经网络中加入更有利于处理非线性误差和大噪声的最大熵准则(MCC)算法,与传统的均值误差执行功能相比,MCC 算法预测精度更高,但该模型的网络结构过于复杂. 文献[7]针对传统的神经网络风电预测模型较为复杂且预测精度低等问题,通过平均影响值计算出某个影响因素与

**收稿日期:** 2019-06-25

**通信作者:** 曾亮(1980-),男,教授,博士,主要从事机器视觉与人工智能、优化计算方法、复杂系统建模、调度与优化的研究. E-mail: zengliang@hbut.edu.cn.

**基金项目:** 国家自然科学基金资助项目(41601394); 湖北工业大学博士科研启动基金资助项目(BSQD2017008)

输出功率的关系值, 选出与输出功率关系较大的变量, 建立预测模型, 但该模型易陷入局部极值. 文献 [8] 采用改进的人工鱼群算法对 BP 神经网络进行优化, 克服了传统 BP 神经网络预测误差较高、易陷入局部极值等缺点, 在短期风电输出功率预测方面具有良好的效果, 但其收敛速度较慢. 本文采用组合预测的方法, 提出一种基于互信息的自适应变异粒子群优化 BP 的短期风电功率预测模型(互信息-改进粒子群算法-反向传播(MI-IPSO-BP)预测模型).

# 1 风电场输出功率影响因素的确定

## 1.1 各因素对风电场输出功率的影响

风电场输出功率, 即风力机的输出功率  $P$  为

$$P = C_p S \rho v^3 / 2. \tag{1}$$

式(1)中:  $C_p$  为功率系数;  $S$  为风力机扫过的面积,  $\text{m}^2$ ;  $\rho$  为空气密度,  $\text{kg} \cdot \text{m}^{-3}$ ;  $v$  为风速,  $\text{m} \cdot \text{s}^{-1}$ . 某风电场风速与输出功率的关系, 如图 1 所示. 在风电场的实际运行过程中, 只有当风速在某个限定区间时, 随着风速的增加, 风力机的输出功率随之增加, 之后趋于稳定; 当低于或高于该风速区间时, 风力机的输出功率为零<sup>[9]</sup>.

不同空气密度下输出功率的变化, 如图 2 所示. 由图 2 可知: 其他环境条件一致, 当  $3 \text{ m} \cdot \text{s}^{-1} \leq v \leq 12 \text{ m} \cdot \text{s}^{-1}$  时, 输出功率随着空气密度的增大而增大; 当  $v > 12 \text{ m} \cdot \text{s}^{-1}$  时, 输出功率保持不变<sup>[10]</sup>.

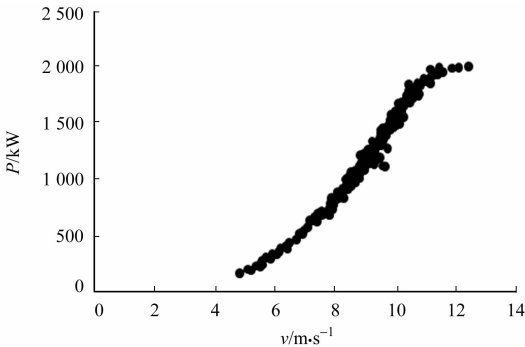


图 1 风电场风速与输出功率的关系

Fig. 1 Relationship between wind speed and output power of wind farms

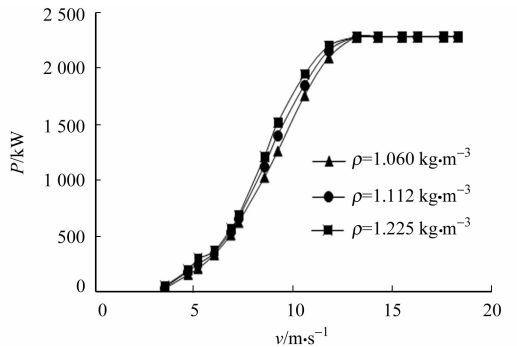


图 2 不同空气密度下输出功率的变化

Fig. 2 Changes in output power at different air densities

风力机的输出功率受到风速和空气密度的影响, 但无法直接判断出其他因素与输出功率的关系. 若将所有影响因素作为模型的输入, 则会增大计算的复杂度; 若人为选取某些因素作为模型的输入, 则难以保证预测精度. 因此, 需要采用一些方法对原始数据中的影响因素进行筛选.

## 1.2 互信息对影响因素的筛选

互信息(MI)表示两个或多个变量间的相关性<sup>[11]</sup>. 假设有两个变量  $X, Y$ , 二者间的相关度表示为

$$MI = \frac{1}{N} \sum_{j=1}^N \ln \left( \frac{F_{X,Y}(x,y)}{F_X(x_j)F_Y(y_j)} \right). \tag{2}$$

式(2)中:  $N$  为变量  $X$  的观测样本数;  $j$  为观测样本的编号;  $F_{X,Y}(x,y)$  为  $X, Y$  的联合概率密度函数,  $F_{X,Y}(x,y) = F_X(x)F_Y(y)$ ,  $F_X(x), F_Y(y)$  分别为  $X, Y$  的边缘概率密度函数,  $x$  为样本中任一影响因素序列,  $y$  为输出功率序列; 当  $X$  与  $Y$  互不相关时, MI 值将趋近于 0, 当  $X$  与  $Y$  的相关程度越大时, MI 值将趋近于 1<sup>[12-13]</sup>.

计算各影响因素与输出功率间的 MI 值. 首先, 求出联合概率密度函数和边缘概率密度函数. 由于影响输出功率的因素都是离散性变量, 故需要对变量进行离散化处理. 将风速、风向正弦值、风向余弦值、桨距角等因素序列从小到大进行排列, 把各因素等分为  $[x_{\min}, x_{\max}]$  这样的区间, 在选取的影响因素样本数据中, 统计出落入各区间的概率, 即为边缘概率密度. 同理, 将输出功率序列等分为区间  $[y_{\min}, y_{\max}]$ , 统计同时落入区间  $[x_{\min}, x_{\max}]$  和  $[y_{\min}, y_{\max}]$  的概率, 即为联合概率密度.

通过式(2)计算出影响因素与输出功率之间的 MI 值, 筛选出与输出功率相关度较大的 8 种影响因素, 即风速、风向正弦值、风向余弦值、桨距角、相对湿度、温度、海拔高度、空气密度, 其相应的 MI 值分

别为 0.964 5,0.854 3,0.826 8,0.802 3,0.432 6,0.571 5,0.671 9,0.483 6.

2 自适应变异粒子群优化 BP 的风电功率预测

2.1 BP 神经网络

BP 神经网络是一种多层前馈网络模型,是人工神经网络的算法之一<sup>[14-15]</sup>.BP 神经网络首先将输入量由各层之间的连接关系传递到隐含层,再传递到输出层,得到输出层输出;然后,将输出层输出与期望输出进行比较,得出误差;最后,通过误差的反向传播,对各层之间的权重和阈值进行反复修正,以完成学习的过程.

2.2 粒子群优化算法

粒子群优化(PSO)算法是一种模仿鸟类运动规律的优化算法.在优化过程中,粒子在空间中不断更新位置和速度,搜索最优位置,然后,与其他粒子搜索的最优位置进行比较,找到全局最优位置<sup>[16]</sup>.梯度下降法是求解无约束优化问题的迭代算法,其利用负梯度方向决定每次迭代的新的搜索方向,使每次迭代都能朝着函数最小的方向前进.在解决实际问题时,如果函数不是凸函数,则很可能陷入局部极值.粒子群优化算法可用于解决大量非线性、不可微和多峰值的复杂函数优化问题,可以有效地克服传统优化算法收敛速度慢、易陷入局部极值等缺点.由于智能优化算法的迅猛发展,且其优越性已在其他应用中得到验证,故不采用梯度下降算法,而采用粒子群优化算法.

设种群规模为  $m$  的粒子群,在  $d$  维搜索空间中,粒子  $i$  在  $M$  次迭代的位置和速度分别表示为  $x_i^M = (x_{i,1}^M, x_{i,2}^M, \cdots, x_{i,m}^M), v_i^M = (v_{i,1}^M, v_{i,2}^M, \cdots, v_{i,m}^M), i = 1, 2, \cdots, m$ .标准 PSO 的速度和位置的更新公式<sup>[17]</sup>为

$$v_{i,d}^{M+1} = \omega v_{i,d}^M + c_1 r_1 (p_{i,d}^M - x_{i,d}^M) + c_2 r_2 (p_{gd}^M - x_{i,d}^M), \tag{3}$$

$$x_{i,d}^{M+1} = x_{i,d}^M + v_{i,d}^{M+1}. \tag{4}$$

式(3),(4)中: $\omega$  为自适应惯性权重系数; $c_1, c_2$  均为学习因子,一般  $c_1 = c_2 = 2$ ;  $r_1, r_2$  均为分布于  $[0, 1]$  的随机数;  $x_{i,d}^M, v_{i,d}^M$  分别表示在第  $M$  次迭代中第  $i$  个粒子在第  $d$  维的位置和速度;  $p_{i,d}^M$  为当前粒子的历史最优位置;  $p_{gd}^M$  为全局粒子的历史最优位置.

粒子不断更新位置和速度,直到粒子在搜索空间中找到全局最优位置,或者算法达到最大迭代次数时,算法才结束搜索.

2.3 粒子群算法的改进

在风电输出功率预测问题中,粒子群优化算法结构简单、易于实现,但在优化过程中,一旦粒子找到 1 个最优位置,其他粒子则会趋于该最优位置,很难跳出该局部极值.针对这些问题,通过自适应惯性权重系数和变异扰动的方法对传统粒子群进行改进,提高粒子的全局搜索能力.

实际问题大多数是复杂、非线性的,选择合适的惯性权重系数可以均衡粒子的全局搜索和局部搜索能力,使粒子摆脱早熟.传统的惯性权重系数对非线性问题的处理能力有限,故引入自适应惯性权重系数  $\omega$ ,以避免粒子陷入局部最优,即

$$\omega = (\omega_{\max} - \omega_{\min}) \exp\left(-\alpha \left(\frac{M}{M_{\max}}\right)^2\right). \tag{5}$$

式(5)中: $\alpha$  分布于  $[15, 30]$ ;  $\omega_{\max}, \omega_{\min}$  分别为自适应惯性权重系数值的上、下限;  $M_{\max}$  为最大迭代次数.

为避免粒子早熟收敛,并提高种群的多样性,引入变异思想对粒子进行扰动.当粒子一直陷入局部最优,停止向新的方向搜索时,引入变异扰动,迫使粒子进入其他区域继续搜索.假设 1 个变异概率为  $q_0$ ,若  $r < q_0, r$  为  $[0, 1]$  的随机数,则对粒子进行变异操作,有

$$p_{gd}^{M+1} = p_{gd}^M (1 + 0.3\delta). \tag{6}$$

式(6)中: $p_{gd}^{M+1}$  为全局粒子第  $M+1$  次迭代后的历史最优位置;  $\delta$  为服从 Gauss(0, 1) 分布的随机变量.

2.4 粒子群算法的实现步骤

- 粒子群算法的实现有以下 5 个步骤.
- 步骤 1 随机初始化粒子的位置和速度.
  - 步骤 2 将均方误差函数作为其适应度函数,计算出各粒子的适应度值  $f_i$ .
  - 步骤 3 将各粒子的适应度值  $f_i$  与该粒子目前搜索到最优位置时的适应度值  $f(p_{best})$  进行比较,若

$f_i > f(p_{\text{best}})$ , 则更新  $p_{\text{best}}$ ; 否则, 保持不变. 将  $f_i$  与全部粒子搜索到最优位置时的适应度值  $f(g_{\text{best}})$  进行比较, 若  $f_i > f(g_{\text{best}})$ , 则更新  $g_{\text{best}}$ ; 否则, 保持不变.

**步骤 4** 对粒子的自适应惯性权重系数、位置和速度进行更新, 若  $r < q_0$ , 则进行变异操作.

**步骤 5** 判断是否已满足约束条件, 若满足, 则算法结束, 输出最优解; 否则, 返回步骤 2, 继续迭代.

## 2.5 MI-IPSO-BP 预测模型的建立

MI-IPSO-BP 预测模型的建立有以下 8 个步骤.

**步骤 1** 数据的预处理. 对选取的样本数据进行补全和修正, 对样本数据进行归一化处理.

**步骤 2** 模型参数的设置. 对粒子群优化算法中的参数进行设置, 并初始化粒子的位置和速度, 确定粒子各维度上的数值与神经网络中输入层、隐含层、输出层之间的权重相对应.

**步骤 3** 建立 BP 神经网络, 采用单隐层结构, 输入层神经元 8 个, 输出层神经元 1 个, 隐含层神经元的个数  $h$  可通过试凑法或经验公式确定, 即

$$h = \sqrt{a+b} + c, \quad h = 2a + 1. \quad (7)$$

式(7)中:  $a, b$  分别为输入层、输出层的个数;  $c$  为常数, 分布于  $[1, 10]$ .

**步骤 4** 采用均方误差函数, 计算出各粒子的适应度值  $f_i$ .

**步骤 5** 将粒子的适应度值  $f_i$  与该粒子目前搜索到最优位置时的适应度值  $f(p_{\text{best}})$  进行比较, 若  $f_i > f(p_{\text{best}})$ , 则更新  $p_{\text{best}}$ ; 否则, 保持不变. 同时, 将各粒子的适应度值  $f_i$  与全部粒子搜索到最优位置时的适应度值  $f(g_{\text{best}})$  进行比较, 若  $f_i > f(g_{\text{best}})$ , 则更新  $g_{\text{best}}$ ; 否则, 保持不变.

**步骤 6** 对粒子的位置、速度和惯性权重系数进行更新, 并假设变异概率  $q_0 = 0.95$ , 若  $r < q_0$ , 则对粒子进行变异操作.

**步骤 7** 判断误差是否达到误差标准, 以及迭代次数是否达到最大, 若达到最大, 则停止迭代, 得出最优解; 否则, 返回步骤 4, 继续迭代.

**步骤 8** 将粒子群优化算法得到的最优参数设置为 BP 神经网络的权值和阈值, 并对预测模型进行训练. 根据实际输出功率和预测输出功率, 不断调整权值和阈值, 直到满足结束条件, 算法结束.

## 3 算例与分析

### 3.1 数据预处理

在选取的样本数据中, 由于监控系统出错或人为原因, 往往存在明显的错误数据或数据缺失等问题, 如果未能很好地处理这些问题, 预测结果会有更大的误差. 通常选取该缺失数据或错误数据的前一个和后一个数据的平均值作为替代数据.

此外, 在这些数据中, 有些影响因素的数据不在同一个量级上, 需要对数据进行归一化处理, 即

$$\bar{z} = \frac{z - z_{\min}}{z_{\max} - z_{\min}}. \quad (8)$$

式(8)中:  $z, \bar{z}$  分别为归一化前、后的数据;  $z_{\max}, z_{\min}$  分别为影响因素中的最大数据和最小数据.

### 3.2 预测模型的评价指标

由于风电输出功率受风速、风向、温度等随机性天气因素的影响较大, 因此, 为了验证文中模型的预测性能, 选取平均绝对误差 ( $E_{\text{MA}}$ )、均方根误差 ( $E_{\text{RMS}}$ ) 和平均绝对百分比误差 ( $E_{\text{MAP}}$ ) 作为评价指标<sup>[18]</sup>, 其计算式分别为

$$E_{\text{MA}} = \frac{1}{n} \sum_{j=1}^n |P_c - P_r|, \quad (9)$$

$$E_{\text{RMS}} = \sqrt{\frac{1}{n} \sum_{j=1}^n (P_c - P_r)^2}, \quad (10)$$

$$E_{\text{MAP}} = \frac{1}{n} \sum_{j=1}^n \left| \frac{P_c - P_r}{P_r} \right| \times 100\%. \quad (11)$$

式(9)~(11)中:  $n$  为预测样本数;  $P_c$  为预测输出功率;  $P_r$  为实际输出功率;  $j$  为预测输出功率的个数.

3.3 预测结果及分析

选取该风电场 2014 年 4 月 1 日—30 日的气象数据和历史输出功率数据(4 320 个)作为预测模型的输入样本数据,其中,前 3 800 个数据作为训练样本,其余数据作为测试样本. 将风速、风向正弦值、风向余弦值、桨距角、相对湿度、温度、海拔高度、空气密度这 8 种影响因素作为预测模型的输入. 根据经验公式,将隐含层神经元数设置为输入层神经元数的 2 倍加 1;最大迭代次数设置为 100;种群规模为 25; $\omega_{\max}$ ,  $\omega_{\min}$  分别为 0.9,0.2; $c_1$ ,  $c_2$  均为 2.

通过 MATLAB 软件对 MI-IPSO-BP 预测模型进行仿真,为了对比研究,同时采用遗传算法-反向传播(GA-BP)预测模型和粒子群优化算法-反向传播(PSO-BP)预测模型对输出功率进行预测. GA-BP 预测模型采用遗传算法对个体进行筛选,寻找最优个体作为 BP 神经网络的初始权值,对短期输出功率进行预测. PSO-BP 预测模型采用传统的粒子群优化算法对 BP 神经网络进行优化.

预测模型输出功率的对比,如图 3 所示. 预测模型平均绝对误差的对比,如图 4 所示.

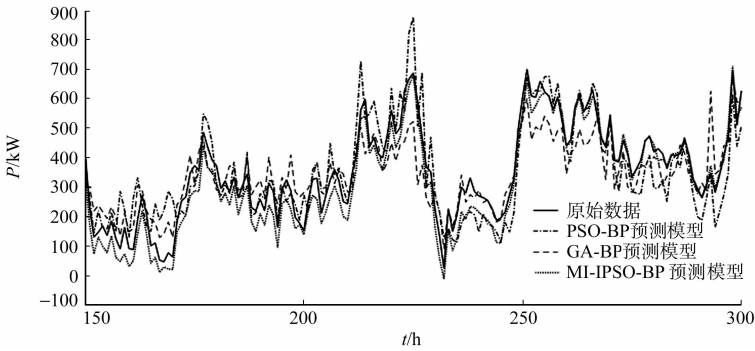


图 3 预测模型输出功率的对比

Fig. 3 Comparison of output power of prediction models

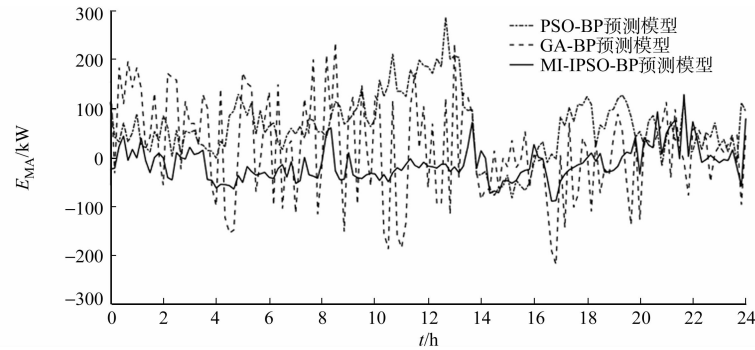


图 4 预测模型平均绝对误差的对比

Fig. 4 Comparison of mean absolute error of prediction models

由式(9)~(11)及图 3,4 可以得到以下 2 个结论.

1) 3 种预测模型都可以对风电短期输出功率进行有效的预测,但 MI-IPSO-BP 预测模型的预测曲线能够更好地逼近实际的输出功率. 与 PSO-BP 预测模型相比,MI-IPSO-BP 预测模型具有更高的预测精度,说明改进后的粒子群优化 BP 神经网络具有更好的预测能力;与 GA-BP 预测模型相比,MI-IPSO-BP 预测模型的优化效果更好.

2) MI-IPSO-BP 预测模型的  $E_{MA}$ ,  $E_{RMS}$  分别为 20.869 4,35.622 4 kW,  $E_{MAP}$  为 8.96%. 相较于 GA-BP 预测模型,MI-IPSO-BP 预测模型的  $E_{MA}$ ,  $E_{RMS}$  分别减少了 27.651 9,24.703 7 kW,而  $E_{MAP}$  减少了 6.78%;相较于 PSO-BP 预测模型,MI-IPSO-BP 预测模型的  $E_{MA}$ ,  $E_{RMS}$  分别减少了 84.853 7,103.323 9 kW,而  $E_{MAP}$  减少了 18.50%. 由此可知,MI-IPSO-BP 预测模型的预测精度最高,效果最佳.

4 结束语

采用互信息对原始数据进行降维,可以保留有用的特征信息,舍弃冗余的特征信息,降低算法的复

杂性. 加入自适应惯性权重系数和变异因子改进粒子群算法, 不仅优化BP神经网络, 解决传统粒子群算法存在的问题, 还可以提高粒子的全局搜索能力. 结果表明, MI-IPSO-BP预测模型比GA-BP预测模型、PSO-BP预测模型具有更高的预测精度, 预测结果更接近实际值.

## 参考文献:

- [1] SAROHA S, AGGARWAL S K. Wind power forecasting using wavelet transforms and neural networks with tapped delay[J]. CSEE Journal of Power and Energy Systems, 2018, 4(2): 197-209. DOI: 10.17775/CSEEJPES. 2016. 00970.
- [2] 杨茂, 周宜. 计及风电场状态的风电功率超短期预测[J]. 中国电机工程学报, 2019, 39(5): 1259-1268. DOI: 10.13334/j.0258-8013.pcsee.180873.
- [3] WU Yuankang, SU Po'en, WU Tingyi, *et al.* Probabilistic wind power forecasting using weather ensemble models [J]. IEEE Transactions on Industry Applications, 2018, 54(6): 5609-5620. DOI: 10.1109/TIA.2018.2858183.
- [4] 薛禹胜, 郁琛, 赵俊华, 等. 关于短期及超短期风电功率预测的评述[J]. 电力系统自动化, 2015, 39(6): 141-150. DOI: 10.7500/AEPS20141218003.
- [5] 马聪. 基于BP神经网络优化的风电场短期功率预测研究[D]. 昆明: 昆明理工大学, 2017.
- [6] WANG Zheng, WANG Bo, LIU Chun, *et al.* Improved BP neural network algorithm to wind power forecast[J]. The Journal of Engineering, 2017, 2017(13): 940-943. DOI: 10.1049/joe.2017.0469.
- [7] 徐龙博, 王伟, 张滔, 等. 基于神经网络平均影响值的超短期风电功率预测[J]. 电力系统自动化, 2017, 41(21): 40-45. DOI: 10.7500/AEPS20170321005.
- [8] 张颖超, 王雅晨, 邓华, 等. 基于IAFSA-BPNN的短期风电功率预测[J]. 电力系统保护与控制, 2017, 45(7): 58-63. DOI: 10.7667/PSPC16048.
- [9] WANG Yun, HU Qinghua, SRINIVASAN D, *et al.* Wind power curve modeling and wind power forecasting with inconsistent data[J]. IEEE Transactions on Sustainable Energy, 2018, 1(1): 16-25. DOI: 10.1109/TSSTE.2018.2820198.
- [10] 刘红柳, 杨茂, 于宁, 等. 风向空间分散性及其对全场风电功率预测误差的影响[J]. 电测与仪表, 2017, 54(12): 54-59. DOI: 10.3969/j.issn.1001-1390.2017.12.009.
- [11] 李长松, 刘凯, 肖先勇, 等. 基于条件互信息特征选择法和Adaboost算法的电能质量复合扰动分类[J]. 高电压技术, 2019, 45(2): 579-585. DOI: 10.13336/j.1003-6520.hve.20190130031.
- [12] 史坤鹏, 乔颖, 赵伟, 等. 计及历史数据熵关联信息挖掘的短期风电功率预测[J]. 电力系统自动化, 2017, 41(3): 13-18. DOI: 10.7500/AEPS20160504020.
- [13] MARINONI A, GAMBA P. Unsupervised data driven feature extraction by means of mutual information maximization[J]. IEEE Transactions on Computational Imaging, 2017, 3(2): 243-253. DOI: 10.1109/TCI.2017.2669731.
- [14] 李丹, 任洲洋, 颜伟, 等. 基于因子分析和神经网络分位数回归的月度风电功率曲线概率预测[J]. 中国电机工程学报, 2017, 37(18): 34-43. DOI: 10.13334/j.0258-8013.pcsee.161368.
- [15] WANG Shuangxin, LI Meng, ZHAO Long, *et al.* Short-term wind power prediction based on improved small-world neural network[J]. Neural Computing and Applications, 2019, 31(7): 3173-3185. DOI: 10.1007/s00521-017-3262-7.
- [16] 王功臣, 邓长虹, 夏沛, 等. 考虑机组优化选取的含风电电网滚动优化调度方法[J]. 电力系统自动化, 2017, 41(11): 55-60. DOI: 10.7500/AEPS20160922005.
- [17] ROCHA H R O, SILVESTRE L J, CELESTE W C, *et al.* Forecast of distributed electrical generation system capacity based on seasonal micro generators using ELM and PSO[J]. IEEE Latin America Transactions, 2018, 16(4): 1136-1141. DOI: 10.1109/TLA.2018.8362148.
- [18] 丁明, 张超, 王勃, 等. 基于功率波动过程的风电功率短期预测及误差修正[J]. 电力系统自动化, 2019, 43(3): 8-18. DOI: 10.7500/AEPS20180322011.

(责任编辑: 钱筠 英文审校: 吴逢铁)