

doi:10.3969/j.issn.1673-9833.2019.05.004

基于 DBN-Kalman-EC 算法的 短期风电功率组合预测

曹庆兰, 匡洪海, 王建辉, 荣浩博

(湖南工业大学 电气与信息工程学院, 湖南 株洲 412007)

摘要: 提出一种基于深度置信网络 (DBN) 和卡尔曼算法 (Kalman), 结合误差修正算法 (EC) 的短期风电功率组合预测模型。运用经验模态算法 (EMD) 将原始风速序列分解, 提取其主要特征, 降低风速序列突变性; 然后利用 DBN 法, 通过构造两种不同的输入输出矩阵, 得到 pro_1 和 pro_2 两种预测功率、 $bias_1$ 和 $bias_2$ 两种预测误差; 接着将 pro_1 作为测量值、 $bias_1$ 作为测量误差, 将 pro_2 作为观测值、 $bias_2$ 作为过程误差引入 Kalman 模型, 得到预测结果 pro 和预测误差 $bias$; 最后利用 EC 算法对 pro 和 $bias$ 进行修正。仿真结果表明, DBN-Kalman-EC 模型能有效中和 $bias_1$ 和 $bias_2$ 两种误差, 降低了预测误差, 修正预测值, 有效地提高了短期风电功率预测的精度。

关键词: 短期风电功率预测; 卡尔曼算法; 深度置信网络; 误差修正算法

中图分类号: TM614

文献标志码: A

文章编号: 1673-9833(2019)05-0019-06

引文格式: 曹庆兰, 匡洪海, 王建辉, 等. 基于 DBN-Kalman-EC 算法的短期风电功率组合预测 [J]. 湖南工业大学学报, 2019, 33(5): 19-24.

Short-Term Wind Power Combination Forecasting Based on DBN-Kalman-EC Algorithm

CAO Qinglan, KUANG Honghai, WANG Jianhui, RONG Haobo

(College of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou Hunan 412007, China)

Abstract: A short-term wind power combination forecasting model has been proposed based on deep belief network (DBN) and Kalman algorithm combined with the error correction algorithm (EC). Firstly, the empirical modal algorithm (EMD) is to be used to decompose the original wind speed sequence, thus extracting its main features and reducing the mutation of the wind speed sequence. Then, by adopting DBN method, two kinds of input and output matrices can be constructed so as to obtain the predicted powers of pro_1 and pro_2 , thus obtaining the two kinds of prediction errors. Next, with pro_1 as the measurement value, and $bias_1$ as the measurement error, the introduction into Kalman model of pro_2 as the observation value and $bias_2$ as the process error helps to obtain the prediction result pro and prediction error $bias$, followed by a modification of pro and $bias$ based on EC algorithm. The simulation results show that DBN-kalman-EC combined prediction model can effectively neutralize $bias_1$ and $bias_2$ errors, reduce prediction errors, correct predicted values, and effectively improve the accuracy of the short-term wind power prediction.

收稿日期: 2018-10-26

作者简介: 曹庆兰 (1993-), 女, 湖北黄石人, 湖南工业大学硕士生, 主要研究方向为新能源功率预测及并网技术, E-mail: 1753546318@qq.com

通信作者: 匡洪海 (1972-), 女, 湖南双峰人, 湖南工业大学教授, 博士, 硕士生导师, 主要从事分布式发电技术和配电网停电技术方面的教学与研究, E-mail: 2451884132@qq.com

Keywords: short-term wind power prediction; Kalman algorithm; deep belief network; error correction algorithm

1 研究背景

随着风电的大规模并网，将会给电网的平稳安全运行带来较大的影响，因此有必要对风电功率进行预测^[1-3]。短期风电功率预测可以给电网调度和控制提供依据，有效减小风功率对电网的影响，增加电网的安全性、稳定性和可靠性^[4]，所以对风电短期功率预测的研究是必要的。文献[5]采用一种时间序列方法，通过多次迭代计算不同点施加不同的权重，有效地减少了异常点对预测结果的影响，但预测方法仅将时间序列单一因数作为参考；文献[6]提出一种基于主成分分析与人工神经网络的风电功率预测方法，先对影响风电输出功率的多个变量进行分析，提取其特征向量，同时消除了各变量间的相关性，再通过前馈BP神经网络进行学习，该方法有效提高了功率预测精度，但具有泛化性；文献[7-8]通过对神经网络的改进方法进行功率预测，具有很好的学习能力，但容易陷入局部极值，且与样本的选择密切相关；文献[9-16]基于支持向量机的方法与优化算法结合，在相对较少的数据训练时，也可以得到相对较好的预测精度，但需要解决多分类以及二次规划的问题，大规模数据训练比较难实现；文献[17]针对风力发电时间序列具有混沌属性和单步预测出现的滞后现象，通过小波变换将功率时间序列分解成多层频域不同的子序列，再将其通过BP神经网络进行功率预测后将结果叠加在一起；文献[18]针对数据量的不断增长问题，提出一种改进的灰色预测法，删除与现阶段不符合的数据，不断更新数据库，计算方便且不需考虑分布规律，但没有考虑多个因素之间的联系和影响。

以上方法都有各自的特点，但在应用时存在不足且采用单一方法对风电功率进行预测的误差相对较大，一般为25%~40%^[19-20]，已经无法满足预测精度的要求。且随着数据量的指数式增长，传统的模型也不能满足海量数据的运行，海量数据与深度网络结合模型成为智能时代的标志。为此，本文提出一种基于深度置信网络（deep belief network, DBN）和卡尔曼算法（Kalman）的组合预测算法（基本流程见图1），并利用误差修正算法对预测值进行修正，在Matlab 2015平台上进行建模分析，以期提高短期风电功率预测水平，为风力发电规划提供参考依据。

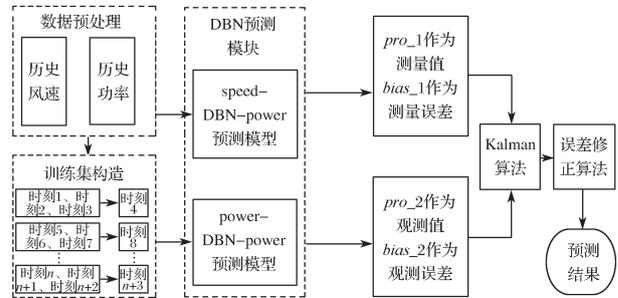


图1 整体思路的基本框图

Fig. 1 Basic overall block diagram

2 深度置信网络

深度置信网络，是一种由多组受限玻尔兹曼机（restricted boltzmann machine, RBM）网络堆栈而成，具有高效的深度学习神经网络模型，在多维、大规模数据处理问题上应用广泛。利用DBN进行功率预测时，首先应对网络进行训练，包括RBM训练过程，并根据预测结果进行反向调整。利用无监督学习方式逐层对RBM进行训练，能够保证得出的特征向量具有一定的代表性。DBN网络通过该训练过程，得到良好的权重初值基础，再通过预测值与实际值比较得到误差，返回网络后对参数进行微调处理。

基于DBN方法的短期风电功率预测网络结构模型如图2所示。

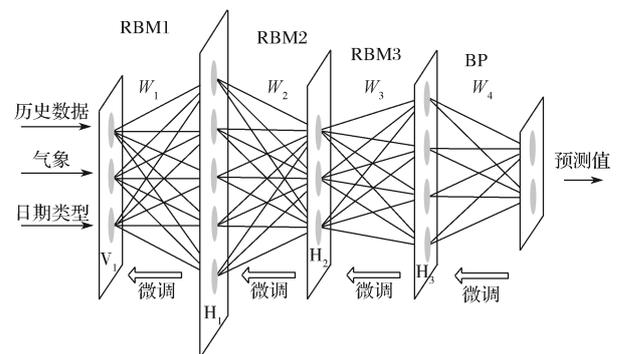


图2 DBN 短期风电功率预测网络结构模型

Fig. 2 DBN short-term wind power prediction network structure model

短期风电功率预测网络结构的数学模型如下：

神经元的激活和未激活两种状态，分别用二进制的0和1表示。状态(v, h)确定的RBM系统所具有的能量可表示为

$$E(v, h|\theta) = -\sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i w_{ij} h_j. \quad (1)$$

式(1)中: v 、 h 分别为可见层和隐含层; w 为可见层与隐含层之间的连接权重; n 、 m 分别为可见层与隐含层的神经元数量; i 、 j 为序号。

由能量函数, 得到 (v, h) 的联合概率分布为

$$p(v, h|\theta) = \frac{1}{Z(\theta)} \exp(-E(v, h|\theta)). \quad (2)$$

式中, $Z(\theta)$ 为归一化因子, 且

$$Z(\theta) = \sum_v \sum_h \exp(-E(v, h|\theta)).$$

利用最大对数似然函数计算参数 θ , 即

$$\theta^* = \arg \max_{\theta} L(\theta) = \arg \max_{\theta} \sum_{n=1}^N \ln(p(v^n|\theta)),$$

其中, $p(v|\theta)$ 为观测数据的似然函数, 且

$$p(v|\theta) = \frac{1}{Z(\theta)} \sum_h \exp(-E(v, h|\theta)). \quad (3)$$

RBM 层内各神经元状态之间是不相关的, 由可见层神经元状态计算隐含层神经元的激活概率为

$$p(h_j = 1|v, \theta) = \left[1 + \exp\left(-b_j - \sum_i v_i w_{ij}\right) \right]^{-1}; \quad (4)$$

由隐含层重建可见层神经元的激活概率为

$$p(v_j = 1|h, \theta) = \left[1 + \exp\left(-a_j - \sum_j w_{ij} h_j\right) \right]^{-1}; \quad (5)$$

各参数变化量计算准则为

$$\begin{cases} \Delta w_{ij} = \langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}}, \\ \Delta a_i = \langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}}, \\ \Delta b_j = \langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}}. \end{cases} \quad (6)$$

式(6)中: $\langle \cdot \rangle_{\text{data}}$ 为原始观测数据模型定义分布; $\langle \cdot \rangle_{\text{recon}}$ 为重构后模型定义分布。

考虑学习率的参数更新准则如下:

$$\begin{cases} w_{ij}^{k+1} = w_{ij}^k + \varepsilon \Delta w_{ij}, \\ a_i^{k+1} = a_i^k + \varepsilon \Delta a_i, \\ b_j^{k+1} = b_j^k + \varepsilon \Delta b_j. \end{cases} \quad (7)$$

3 误差修正算法

风电功率一次预测存在较大误差, 可通过寻找原始数据及气象数据的相似性寻找偏差项和修正因子, 再将得到的一次功率预测结果偏差序列通过误差修正算法修正, 得到最终的预测结果。该算法可避免文献 [18-19] 中需选择误差模型的问题, 通过历史相似日对预测结果精准修正, 修正算法流程见图 3。

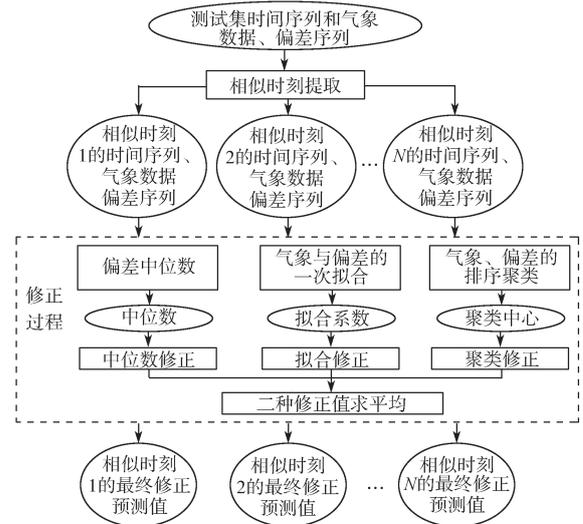


图3 修正算法流程图

Fig. 3 Modified algorithm flow chart

首先, 将一次预测得到的偏差、时间以及气象数据, 通过模型分析找到相似时刻。然后, 通过误差修正算法进行修正。

修正算法的步骤如下: 第一步, 将一次预测的偏差序列的中位数作为修正偏差①; 第二步, 采用多项式拟合, 根据相似时刻的一次偏差和风速构造一次拟合方程, 然后将数据代入拟合方程, 得到修正偏差②; 第三步, 通过对偏差序列和气象数据采用聚类分析, 得到修正偏差③; 第四步, 对三种修正方法的修正偏差通过加权平均计算, 得到最终的修正参数, 相关系数的计算公式如下:

$$r(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}[X] * \text{Var}[Y]}}, \quad (8)$$

$$\text{Cov}(X, Y) = E[XY] - E[X] * E[Y], \quad (9)$$

$$\text{Var}(X) = \frac{\sum (X - X_{\text{平均}})^2}{N}, \quad (10)$$

$$\text{Var}(Y) = \frac{\sum (Y - Y_{\text{平均}})^2}{N}. \quad (11)$$

式(8)~(11)中: r 为相关系数; Cov 为协方差; Var 为方差; E 为数学期望。

4 基于 DBN-Kalman-EC 组合预测的建模与实现

本文提出一种基于 DBN-Kalman-EC 的组合预测模型。首先利用经验模态分解 (empirical mode decomposition, EMD) 将原始风速序列分解, 提取其主要特征, 降低风速序列突变性。然后基于 DBN 预测模型, 构建不同的输入矩阵。本研究构建了两种功率预测方式: 以风速作为输入量的 speed-DBN-power 方式和以功率作为输入量的 power-DBN-

power 方式。通过对比这两种不同的预测方式得出: speed-DBN-power 预测方式的误差主要来源于气象误差, 而 power-DBN-power 预测方式的误差主要来源于模型误差。为了能够有效地中和两种误差, 本文引入卡尔曼滤波模型, 将气象误差和模型误差分别作为测量值和观测值输入 Kalman 模型, 以中和两种误差。仿真结果表明, 该组合模型可以有效地中和两种误差, 减小预测过程中的误差迭代, 有效提高预测精度。具体实施步骤如下:

Step 1 实际功率、风速前期数据质量控制处理, 包括对缺值进行插值, 对死数、错数进行删除。

Step 2 采用 EMD 算法将风速分解, 有效地降低风速突变性。

Step 3 利用 DBN 算法, 以 speed-DBN-power 方式进行功率预测, 得到 pro_1 预测功率和 $bias_1$ 预测误差。

Step 4 利用 DBN 算法, 以 power-DBN-power 方式进行功率预测, 得到 pro_2 预测功率和 $bias_2$ 预测误差。

Step 5 将上述两种预测进行组合, 再利用 Kalman 算法, 得到预测结果 pro 和预测误差 $bias$ 。

Step 6 调用误差修正算法。

Step 7 输出实际功率值, 修正预测功率, 计算误差指标并对比分析。

5 实例分析

5.1 研究对象与参数

原始数据来源于甘肃地区某风电场 2016 年 10 月 1 日—2017 年 12 月 31 日的历史数据, 每隔 15 min 对风电场的功率、风速、风向、气压、温度等进行采样, 并将其中的异常数据删除, 图 4 为清洗后的实际功率输出曲线。从图 4 所示输出值变化情况看, 它们遍及了风电功率的各种状态, 能很好地反映风电场的实际运行情况, 是一组较理想的仿真数据。

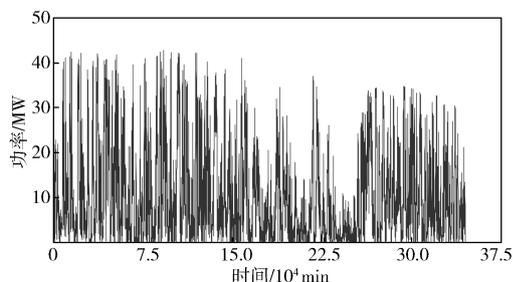


图 4 风电场实际功率输出曲线

Fig. 4 Actual power curves of the wind farm

5.2 DBN 仿真

首先利用 DBN 算法进行 speed-DBN-power 方式预测, 输入量为清洗后的风速数据, 输出量为清洗

后的实际功率数据。训练阶段: 提取前 2/3 的 20 000 条清洗后的数据作为训练数据。测试阶段: 取后 300 条清洗后的风速与功率数据作为测试数据, 得到预测功率 pro_1 和 $bias_1$ 预测误差。如图 5 为 speed-DBN-power 预测方式下的预测功率 pro_1 与实际功率对比图。

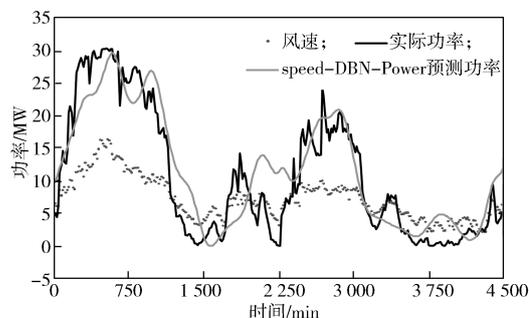


图 5 Speed-DBN-power 预测功率与实际功率对比图

Fig. 5 Speed-DBN-power prediction power and actual power contrast chart

从图 5 可以看出, speed-DBN-power 的预测效果能大致反应实际功率的走向, 但对实际功率的爬坡现象预测不理想, 功率峰值处误差较大。 $bias_1$ 误差的主要来源如下: 1) 风速预报误差。由于风速预报不准确, 预报风速低于实际风速, 导致预测值低于实际值。2) 模型预测误差。由于历史功率在高风速段下普遍低于正常值, 导致基于历史数据训练的 DBN 模型出现预测误差。

5.3 DBN-Kalman 仿真

基于上述仿真, 为降低预测误差, 接下来利用 DBN 算法进行 power-DBN-power 方式预测, 通过前三时刻功率预测下一时刻功率, 得到预测功率 pro_2 和预测误差 $bias_2$, 再将得到的两组预测功率和预测误差输入卡尔曼滤波算法, 得到最终预测结果 pro 和预测误差 $bias$ 。图 6 为 DBN-Kalman 预测功率、speed-DBN-power 预测功率和实际功率对比图。

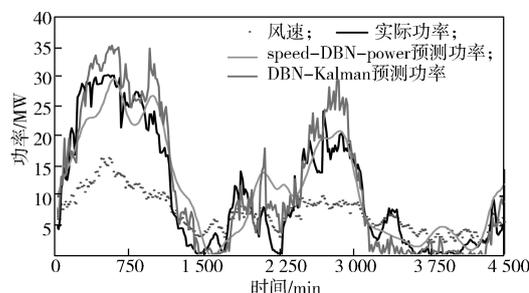


图 6 speed-DBN-power 预测功率、DBN-Kalman 预测功率、实际功率对比图

Fig. 6 Speed-DBN-power prediction power, DBN-Kalman prediction power, actual power contrast chart

从图 6 可以看出, DBN-Kalman 的预测功率 pro 更接近实际功率, 说明当加入 pro_2 和 $bias_2$,

并利用 Kalman 算法修正, 能较好地修正 pro_1 和 $bias_1$, 从而验证了 DBN-Kalman 模型的有效性。

5.4 DBN-Kalman-EC 仿真

DBN-Kalman 模型虽然在一定程度上提升了模型的预测精度, 但在功率峰值处的误差较大, 且不能很好地拟合实际功率曲线。为此, 在 DBN-Kalman 模型的基础上, 利用预测误差 $bias$ 来修正预测功率 pro 。如图 7 为误差修正后的预测功率曲线与各个预测功率曲线对比图。

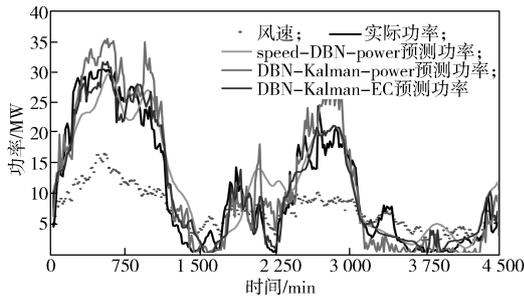


图 7 3 种模型的预测功率及实际功率对比图

Fig. 7 Predictive power and actual power contrast diagrams of three models

图 7 表明, 经过误差修正算法修正后, DBN-Kalman-EC 模型的预测功率曲线能更好地与实际功率拟合, 在细节预测方面, DBN-Kalman-EC 模型的表现更加优良。上述 3 种模型的预测误差对比结果见表 1。

表 1 3 种不同组合算法的风电功率预测误差对比

Table 1 Comparison of the errors of wind power prediction based on three different combination algorithms

算法	均方误差	平均绝对误差
speed-DBN-power	19.397 9	4.304 8
DBN-Kalman	16.004 9	3.808 1
DBN-Kalman-EC	6.926 1	2.614 7

根据仿真得到的数据可以看出, 3 种风电功率预测方法中, speed-DBN-power 单一方法的预测结果比较差, DBN-Kalman-EC 模型预测曲线拟合效果最好, 而且该方法有效地控制了两种误差。但是在高风速段时仍然出现预测值明显低于实际值的情况, 产生较大误差, 其主要原因为风速的爬坡现象和历史数据的局限性。

6 结论

本文是基于深度置信网络、卡尔曼算法和误差修正算法的风电短期功率预测, 针对风速带来的预测误差, 采用 Kalman 算法进行修正; 针对模型带来的误差项, 采用 EC 算法进行修正。经过仿真对比, 可得出以下结论:

1) DBN 模型利用特征提取技术, 可以较好地训练出风速与功率的内在映射, 以预测风电功率短期趋势, 其预测精度取决于历史数据的质量。

2) 引入 power-DBN-power 的预测功率作为 DBN-Kalman 模型的测量值, 可以较好地修正由风速引起的误差。

3) 与传统的单一预测模型相比, DBN-Kalman-EC 模型的预测精度有所提高, 两种误差都有所下降。

本文的模型建立不是很严密, 只把风速和功率作为输入量, 并未考虑气压、温度和地理等影响因素; 对风速爬坡现象的分析与预测, 修正爬坡期的预测误差, 进一步提高预测精度, 是未来的研究方向之一。

参考文献:

- [1] 黎静华, 桑川川, 甘一夫, 等. 风电功率预测技术研究综述 [J]. 现代电力, 2017, 34(3): 1-11.
LI Jinghua, SANG Chuanchuan, GAN Yifu, et al. A Review of Researches on Wind Power Forecasting Technology[J]. Modern Electric Power, 2017, 34(3): 1-11.
- [2] 何亚. 风电场超短期功率组合预测方法研究 [D]. 成都: 电子科技大学, 2017.
HE Ya. Research on the Combination Method of Forecasting the Ultra-Short-Term Power of Wind Farm[D]. Chengdu: University of Electric Science and Technology of China, 2017.
- [3] 齐霞, 安磊, 张妍, 等. 风电机组功率曲线建模方法对比研究 [J]. 可再生能源, 2018, 36(4): 580-585.
QI Xia, AN Lei, ZHANG Yan, et al. A Comparative Study of Multiple Power Curve Modelling Methods[J]. Renewable Energy Resources, 2018, 36(4): 580-585.
- [4] 钱政, 裴岩, 曹利霄, 等. 风电功率预测方法综述 [J]. 高电压技术, 2016, 42(4): 1047-1060.
QIAN Zheng, PEI Yan, CAO Lixiao, et al. Review of Wind Power Forecasting Method[J]. High Voltage Engineering, 2016, 42(4): 1047-1060.
- [5] 朱晓荣, 刘艳萍. 基于稳健估计时间序列法的风功率预测 [J]. 电力系统及其自动化学报, 2012, 24(3): 107-110, 126.
ZHU Xiaorong, LIU Yanping. Wind Power Forecasting Using Time Series Model Based on Robust Estimation[J]. Proceedings of the Chinese Society of Universities, 2012, 24(3): 107-110, 126.
- [6] 李刚, 吴潮, 赵建平. 基于改进果蝇神经网络的短期风电功率预测 [J]. 测控技术, 2018, 37(7): 23-26, 31.
LI Gang, WU Chao, ZHAO Jianping. Short Term Wind Power Prediction Based on Improved Fruit Fly-Neural

- Network[J]. Measurement & Control Technology, 2018, 37(7): 23–26, 31.
- [7] 李 操. 基于 IPSO-BP 神经网络模型的风电功率预测研究[D]. 武汉: 武汉科技大学, 2016.
LI Cao. The Research on Wind Power Prediction Based on the IPSO-BP Neural Network Model[D]. Wuhan: Wuhan University of Science and Technology, 2016.
- [8] 张立影, 孟令甲, 王泽忠, 等. 基于双层 BP 神经网络的光伏电站输出功率预测[J]. 电测与仪表, 2015, 52(11): 31–35.
ZHANG Liying, MENG Lingjia, WANG Zezhong, et al. Photovoltaic Power Station Output Power Prediction Based on the Double BP Neural Network[J]. Electrical Measurement & Instrumentation, 2015, 52(11): 31–35.
- [9] 粟 然, 柯拥勤, 张孝乾, 等. 基于时序-支持向量机的风电场发电功率预测[J]. 中国电力, 2012, 45(1): 64–68.
SU Ran, KE Yongqin, ZHANG Xiaoqian, et al. Wind Power Forecasting Based on Time Series and SVM[J]. Electric Power, 2012, 45(1): 64–68.
- [10] 丁志勇, 杨 苹, 杨 曦, 等. 基于连续时间段聚类的支持向量机风电功率预测方法[J]. 电力系统自动化, 2012, 36(14): 131–135, 149.
DING Zhiyong, YANG Ping, YANG Xi, et al. Wind Power Prediction Method Based on Sequential Time Clustering Support Vector Machine[J]. Automation of Electric Power Systems, 2012, 36(14): 131–135, 149.
- [11] 王 恺, 关少卿, 汪令祥, 等. 基于模糊信息粒化和最小二乘支持向量机的风电功率联合预测建模[J]. 电力系统保护与控制, 2015, 43(2): 26–32.
WANG Kai, GUAN Shaoqing, WANG Lingxiang, et al. A Combined Forecasting Model for Wind Power Prediction Based on Fuzzy Information Granulation and Least Squares Support Vector Machine[J]. Power System Protection and Control, 2015, 43(2): 26–32.
- [12] 李 霄, 王 昕, 郑益慧, 等. 基于改进最小二乘支持向量机和预测误差校正的短期风电负荷预测[J]. 电力系统保护与控制, 2015, 43(11): 63–69.
LI Xiao, WANG Xin, ZHENG Yihui, et al. Short-Term Wind Load Forecasting Based on Improved LSSVM and Error Forecasting Correction[J]. Power System Protection and Control, 2015, 43(11): 63–69.
- [13] 陈道君, 龚庆武, 金朝意, 等. 基于自适应扰动量子粒子群算法参数优化的支持向量回归机短期风电功率预测[J]. 电网技术, 2013, 37(4): 974–980.
CHEN Daojun, GONG Qingwu, JIN Zhaoyi, et al. Short-Term Wind Power Prediction Based on Support Vector Regression Machine Optimized by Adaptive Disturbance Quantum-Behaved Particle Swarm Optimization[J]. Fudan International Studies Review, 2013, 37(4): 974–980.
- [14] 杨 茂, 翟冠强. 基于决策树理论的风电功率实时预测方法[J]. 电测与仪表, 2018, 55(11): 120–124.
YANG Mao, ZHAI Guanqiang. Real-Time Wind Power Forecasting Method Based on Decision Tree Theory[J]. Electrical Measurement & Instrumentation, 2018, 55(11): 120–124.
- [15] 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 & Instrumentation, 2016, 53(3): 80–84.
- [16] 田淑慧, 于惠钧, 赵巧红, 等. 基于经验模态分解的 PSO-SVM 风电功率短期预测[J]. 湖南工业大学学报, 2018, 32(3): 59–64.
TIAN Shuhui, YU Huijun, ZHAO Qiaohong, et al. Short-Term Prediction of PSO-SVM Wind Power Based on Empirical Mode Decomposition[J]. Journal of Hunan University of Technology, 2018, 32(3): 59–64.
- [17] 王丽婕, 冬 雷, 廖晓钟, 等. 基于小波分析的风电场短期发电功率预测[J]. 中国电机工程学报, 2009, 29(28): 30–33.
WANG Lijie, DONG Lei, LIAO Xiaozhong, et al. Short-Term Power Prediction of a Wind Farm Based on Wavelet Analysis[J]. Proceedings of the CSEE, 2009, 29(28): 30–33.
- [18] 孟祥星, 田成微, 冬 雷, 等. 灰色理论用于风力发电容量中长期预测的研究[J]. 电力系统保护与控制, 2011, 39(21): 81–85.
MENG Xiangxing, TIAN Chengwei, DONG Lei, et al. A Study on Grey Theory Used in Prediction of Medium and Long-Term Wind Power Generation[J]. Power System Protection and Control, 2011, 39(21): 81–85.
- [19] 孟岩峰, 胡书举, 邓 雅, 等. 风电功率预测误差分析及预测误差评价方法[J]. 电力建设, 2013, 34(7): 6–9.
MENG Yanfeng, HU Shuju, DENG Ya, et al. Analysis and Evaluation Method of Wind Power Predicted-Errors[J]. Electric Power Construction, 2013, 34(7): 6–9.
- [20] LI K P, GAO Y J. A Combination Method for Wind Power Prediction Based on Cooperative Game Theory[J]. Electricity, 2014(2/3): 36–40.

(责任编辑: 姜利民)