

基于自组织映射的改进 BP 神经网络 短期光伏出力预测研究

詹仲强¹, 余金², 郭志³, 王银涛⁴, 克帕依吐·吐尔逊¹

(1. 国网新疆电力有限公司电力科学研究院, 新疆 乌鲁木齐 830011;

2. 国网新疆电力有限公司经济技术研究院, 新疆 乌鲁木齐 830046;

3. 国网淮南供电公司, 安徽 淮南 232007; 4. 新奥泛能网络科技股份有限公司, 河北 廊坊 065600)

摘要: 针对光伏发电出力随机波动给电网调度造成困难这一问题, 提出了一种基于 SOM-PSO-BP 的模型对光伏有功功率进行短期预测, 用于提高电网对可再生能源的调度能力。首先采用自组织映射对原始数据组进行聚类降维; 接着使用粒子群算法对 BP 神经网络的权重和偏置矩阵进行寻优; 然后利用训练集构造 SOM-PSO-BP 预测模型; 最后在对比仿真中验证了所提方法的有效性。

关键词: 光伏发电; 出力预测; 自组织映射; BP 神经网络

中图分类号: TM615 文献标志码: A 文章编号: 1003-6954(2018)02-0024-05

DOI:10.16527/j.cnki.cn51-1315/tm.2018.02.006

Study on Prediction of Short-term Photovoltaic Output Power with Improved BP Neural Network Based on Self-organizing Mapping

Zhan Zhongqiang¹, Yu Jin², Guo Zhi³, Wang Yintao⁴, Kepaiyitulla · Tursun¹

(1. State Grid Xinjiang Electric Power Research Institute, Urumqi 830011, Xijiang, China;

2. State Grid Xinjiang Economic Research Institute, Urumqi 830046, Xijiang, China;

3. State Grid Huainan Power Supply Company, Huainan 232007, Anhui, China;

4. ENN Ubiquitous Energy Network Technology Corporation Limited, Langfang 065600, Hebei, China)

Abstract: The random fluctuation of photovoltaic power generation may cause difficulties for power grid dispatching, so a short-term prediction model based on SOM-PSO-BP is proposed, which will improve the dispatching ability of renewable energy by power grid. Firstly, the self-organizing mapping is used to reduce and cluster the dimension of the original data. Secondly, the weight and bias matrix of BP neural network are optimized by using particle swarm algorithm, and then the SOM-PSO-BP prediction model is constructed by using the training sets. Finally, the effectiveness of the proposed method is verified in the simulation.

Key words: photovoltaic generation; output power prediction; self-organizing mapping; BP neural network

0 引言

随着环境压力不断增加, 中国大力发展光伏发电这种可再生能源^[1-2]。虽然光伏发电具有无污染等优点, 但其出力因气候变化而随机波动给光伏电站并网带来巨大困扰, 让电力系统的稳定性受到影响^[3]。为了解决这一问题, 国内外学者提出对光伏出力进行预测, 让电力调度部门能够提前做出判断,

降低波动影响以提高稳定性。

目前主流的光伏预测模型有 3 种, 分别为人工智能模型^[4-6]、统计模型^[7-8]和混合模型^[9-10]。人工智能模型使用大数据处理中的神经网络和支持向量机等黑箱模型对光伏出力进行直接或间接预测。文献[4]使用光伏出力的信息熵作为特征, 采用极限学习机、广义回归神经网络、径向基神经网络分别建立预测对比, 得出极限学习机的预测效果最好。文献[5]首先对原始数据进行小波分解, 然后对每

层数据使用神经网络进行预测,最后对预测数据进行重构得到结果。文献[6]使用天气模式下的光伏波动作为特征,使用EMD对原始数据进行特征映射,使用IMF分量进行LSSVM预测,对预测结果进行等权值求和得到光伏出力预测。统计模型采用数理统计的方法,对光伏出力进行联合概率分布拟合,得到光伏出力的概率模型。文献[7]对不同天气下的光伏出力用K-means进行聚类,统计有功出力的实际边缘分布和预测边缘分布,以最优拟合作为目标对不同种类的Copula函数参数进行识别,得到先验条件下误差的条件概率分布,并对预测结果进行修正。文献[8]使用混沌理论建立光伏出力的向空间,建立其混沌预测模型得到良好的预测结果。混合模型是将人工智能模型与概率模型进行融合的预测模型。文献[9]对径向基神经网络的边界进行评估,以减少预测模型中累计误差,取得良好结果。文献[10]使用灰色模型建立统计后的相似日时刻出力,使用灰色模型回归结果和采样日的温度建立神经网络预测模型得到预测结果。

国内主流预测模型的采样间隔通常选择1h,但是采样间隔过大,这会平滑光伏出力的实际波动。在前人基础上,所提出的短期光伏预测方法其采样间隔为5min,详细显示了原始数据中的波动,提高了预测精度。采用SOM对光伏历史数据组进行聚类降维,采用PSO对BP神经网络进行优化,最后得到16h的光伏出力预测模型,通过仿真验证所提模型具有良好的预测效果。

1 原始数据的降维处理

1.1 原始数据说明

光伏发电主要受太阳辐射影响,而太阳辐射又与温度、湿度、风速等气候因素有关。在众多环境参数中如何选择与光伏出力最相关的环境变量,从而降低预测模型输入维数,减少模型训练时间是建立光伏预测模型首先需要考虑的问题。

选用澳大利亚的Yulara光伏电站数据,其额定功率为1058.4kW,地面固定式安装。数据中的环境变量有:光伏有功出力(active power, AP), kW;地面水平辐射(global horizontal radiation, GHR), W/m²;弥散性辐射(diffuse horizontal radiation, DHR), W/m²;环境温度(weather temperature,

WT), °C;环境相对湿度(weather relative humidity, WRH), %;风速(wind speed, WS), m/s;风向(wind direction, WD), °。选取2017年8月光伏电站数据组作为预测模型的训练数据和测试数据。

原始数据总共有8912×7个点,记录时间从8月1日至8月31日,采样间隔时间为5min。由于数据过多,故只将AP、GHR作为代表给出,见图1所示。

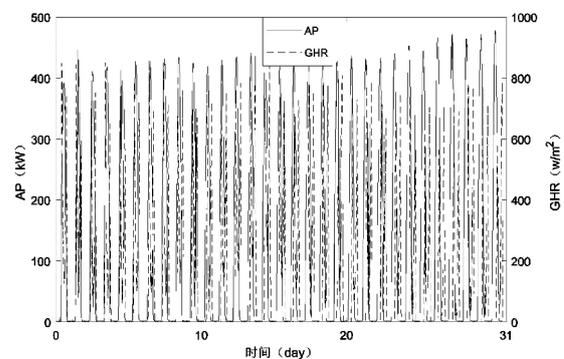


图1 8月的AP和GHR数据

从图1中可以得到AP最大值为439.5453kW,最小值为0;GHR最大值为955.1118W/m²,最小值为0。可以看出AP和GHR具有很强的趋势相关性,通过皮尔逊相关系数计算可得到AP和GHR的相关度为0.5032。为了提高预测精度,将7组环境变量进行归一化,见式(1)。考虑到夜间光伏电站无有功功率输出,故在原始数据中去除输出为0的部分,仅将每日有功输出部分进行连接,得到31日的光伏电站数据组见图2。

$$X_{\text{Nomarl}} = \frac{X_{\text{actual}} - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \quad (1)$$

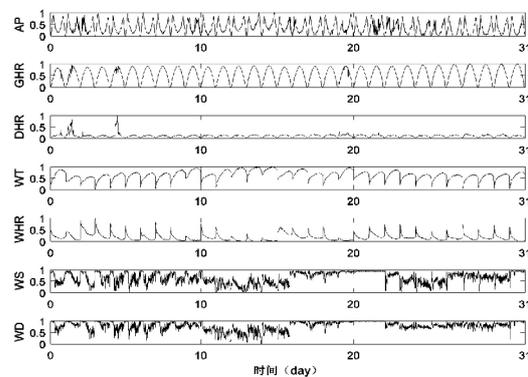


图2 Yulara光伏电站归一化后的数据组

从图2中可得,在8月数据中AP变化具有一定周期性,每日出力曲线整体呈现M型。在第2日AP剧烈波动的同时,GHR、DHR和WHR也出现大幅变化,而发生变化时间滞后于AP,尤其是WHR出现类似阶跃信号一般的陡增,暗示此日出现了突

然降雨影响了 AP 输出,WT、WS 和 WD 数据未能直观看出来与 AP 波动有何关系;第 10 日,当 AP 发生剧烈变化时,GHR、DHR 没有同步出现波动,但 WT 数据出现增长。从以上数据中可以得到光伏出力在环境没有出现大幅变化时,从每日尺度上看到光伏出力具有周期性,但具体到某 1 日中的某一时刻,其输出具有很强的随机波动。

1.2 自组织映射 SOM

自组织映射(self-organization mapping, SOM)于 1982 年由 Kohonen 提出,用于解决非线性空间内的分类问题。它能根据高维数据通过自我竞争学习得到其最大相关组,即最优分类。一个标准的 SOM 结构如图 3 所示。 x_1, x_2, \dots, x_m 为输入信号,经过输入层节点进入竞争层,竞争层由一个二维神经节点阵列组成,在节点权重信号更新过程中,竞争层中获胜的神经节点会自动将输入信号自动向其靠拢,最终得到输入信号的分类。

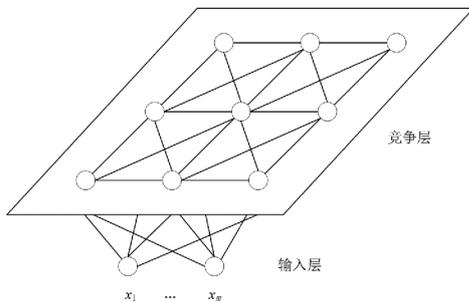


图 3 标准 SOM 结构

建立 SOM 分类模型,首先是根据输出信号种类确定竞争层节点数,并对节点进行随机权重赋值;接着计算节点权重向量与输出数据之间的距离,目前常用的向量距离计算公式见式(2)、式(3)和式(4);然后选择向量距离最小的节点为竞争层获胜节点;使用式(5)更新节点的权重,让获胜节点向最优分类靠近;通过自适应梯度下降法更新学习速率和领域大小,重新计算向量距离;最后经过不断迭代,得到最优分类模式。

Box 距离:

$$d = \max(|x_i - w_{11}|, |x_i - w_{12}|, \dots, |x_i - w_{ij}|) \quad (2)$$

欧式距离:

$$d = |X - W_j| = \sqrt{\sum_{i=1}^m (x_i - w_{ij})^2} \quad (3)$$

曼哈顿距离(出租车距离):

$$d = \sum_{i=1}^m |x_i - w_{ij}| \quad (4)$$

式(2)、式(3)和式(4)中: X 为输入层向量,即输入信号 x_1, x_2, \dots, x_m ; W 为竞争层神经节点权重向量。

更新权重计算公式:

$$W(n+1) = W(n) + \Theta(n) \alpha(n) [X(n) - W(n)] \quad (5)$$

式中: W 为权重向量; n 为迭代次数; Θ 为领域函数; α 为学习速率; X 为输入向量。

对图 2 中的数据进行划分,将第 1 日至第 29 日数据作为预测模型的训练数据,将第 30 日和第 31 日数据作为测试数据。使用所提出的 SOM 分类方法,网络结构为 2×2 ;向量距离选用欧式距离,分类结果见图 4。

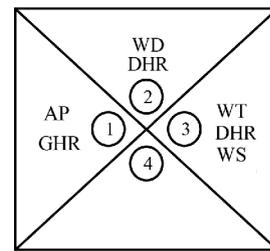


图 4 SOM 对 7 类数据的分类结果

从图 4 的分类结果来看,WT、DHR、WS 被划为 3 组,与之差异较大的 AP 和 GHR 划为 1 组,而 WD 和 DHR 虽与 1 组和 3 组都相似,但又不能单独划为其中一类,故在其后的 BP 神经网络训练模型中使用 AP、GHR、DHR 和 WD 作为输入向量。

2 基于 SOM - PSO - BP 的短期预测模型

2.1 BP 神经网络

BP 神经网络——反向传播神经网络(back-propagation neural networks)由 3 层节点组成:输入层、隐藏层和输出层,一个结构为 $3-4-2$,即 3 个输入节点、4 个隐藏节点、2 个输出节点的典型神经网络见图 5 所示。输入信号经过输入层向前传播,经过隐藏层和输出层作用得到输出信号。输出信号与实际测量信号之间的误差,又通过反向通道向后修正神经网络节点的权值来减少输出误差,使输出结果不断逼近真实信号,所以称作反向传播神经网络。

以图 5 所示的 BP 神经网络结构为例,输入 $X = [x_1, x_2, x_3]^T$,输出 $Y = [y_1, y_2]^T$, W 为神经节点权重

矩阵, 见式 (6) 所示, 从输入层到隐藏层的映射见式 (7) 其中 B 为偏执矩阵 $U = [U_{k1} \ U_{k2} \ U_{k3} \ U_{k4}]^T$ 为隐藏层的线性组合结果, 从隐藏层到输出层的映射见式 (8) 所示, 其中 f 为激活函数, 在神经网络中常用的有: sigmoid、tanh - sig 和高斯径向基。

$$W_k = \begin{bmatrix} \omega_{k11} & \omega_{k12} & \omega_{k13} \\ \omega_{k21} & \omega_{k22} & \omega_{k23} \\ \omega_{k31} & \omega_{k32} & \omega_{k33} \\ \omega_{k41} & \omega_{k42} & \omega_{k43} \end{bmatrix} \quad (6)$$

$$U = f(W_k \cdot X + B_k) \quad (7)$$

$$Y = f(W_j \cdot U + B_j) \quad (8)$$

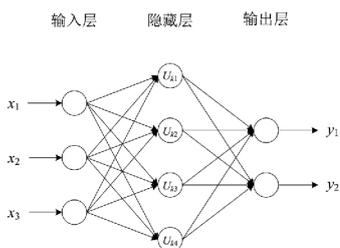


图 5 结构为 3-4-2 的典型神经网络

在 BP 神经网络计算过程中, 从输出向输入侧不断传递误差, 同时使用梯度下降法对隐藏层和输出层中的权值矩阵进行修改以降低误差, 最终将输出误差降低到给定值。

在 BP 算法中, 神经网络对初始神经节点权重矩阵 W 和偏执矩阵 B 会进行随机赋值, 这有可能让自适应梯度算法陷入局部最优解, 导致输出结果差异很大。为了解决这一问题, 采用粒子群算法 (particle swarm optimization, PSO) 对权重矩阵 W 和偏执矩阵 B 进行寻优, 加快 BP 网络收敛速度和精度。

2.2 使用 PSO 对 BP 神经网络参数寻优

根据 SOM 的分类结果, 选用 4-13-1 的网络结构, 即 4 个输入层节点、13 个隐藏层节点和 1 个输出层节点。粒子群算法优化流程见图 6, 以权重矩阵 W 和偏执矩阵 B 为优化目标, 以均方误差 MSE 为评价函数, 如式 (9) 所示, 使用 BP 神经网络进行迭代计算, 训练集使用前 29 日的测量数据用于建立 GA-BP 预测模型, 最终得到最优结果, 迭代结果见图 7。

$$MSE = \frac{1}{N} \sum_{i=1}^N (W_{forecasted} - W_{true})^2 \quad (9)$$

从图 7 可以看到, 所采用的粒子群算法在迭代 90 次之后就趋于稳定, 均方误差 MSE 为 7.2401×10^{-3} 。从迭代结果可以看出所提出的预测模型具有

很高的精度。

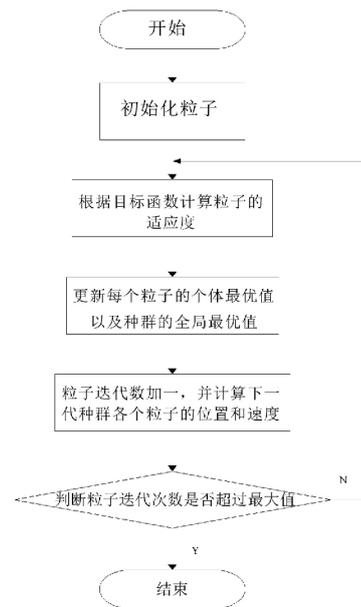


图 6 粒子群算法优化 BP 神经网络流程

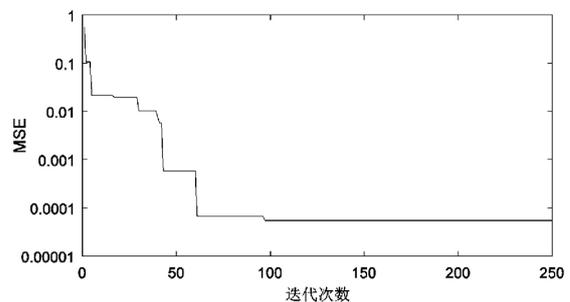


图 7 PSO-BP 的迭代结果

3 算例仿真

以 Matlab 作为仿真平台, 使用 SOM-PSO-BP 模型和 AMIRA 模型进行仿真对比, 以图 2 所示数据中的第 1 日至第 29 日作为训练数据, 用于建立两种预测模型, 以第 30 日和第 31 日数据对模型进行测试, 以均方误差 MSE 作为评价指标检验预测模型的精度。

3.1 ARIMA 预测模型及预测结果

累积式自回归滑动平均 (auto regressive integrated moving average, ARIMA) 模型被广泛应用于金融、电价预测^[11-12]等领域。预测模型通常将非平稳的历史数据进行有限次差分得到平稳时间序列数据, 然后采用贝叶斯法则对模型的 p 和 q 阶数进行寻优, 最后使用最大似然估计找到模型中的最优系数, 得到 ARIMA 预测模型。ARIMA 的数学模型见式 (10) 所示。

$$\Delta^d y_t = \theta_0 + \sum_{i=1}^p \Phi_i \Delta^d y_{t-i} + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j} \quad (10)$$

式中: $\Delta^d y_t$ 为被 d 次差分后的 y_t 序列; Φ_i 和 θ_j 为 ARIMA 模型的待评估系数; ε_t 为 t 时刻的 0 均值高斯分布误差。采用 ARIMA 对 1 日至 29 日的光伏有功出力进行建模,得到 30 日和 31 日的预测结果和预测误差如图 8 和图 9 所示。

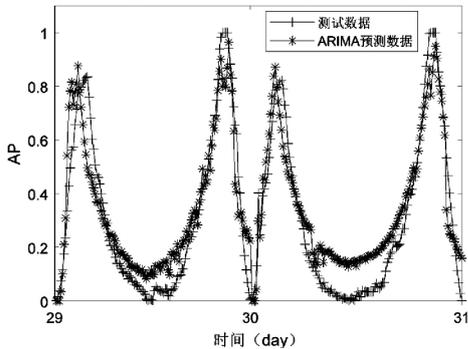


图8 ARIMA 模型的有功出力 AP 预测结果

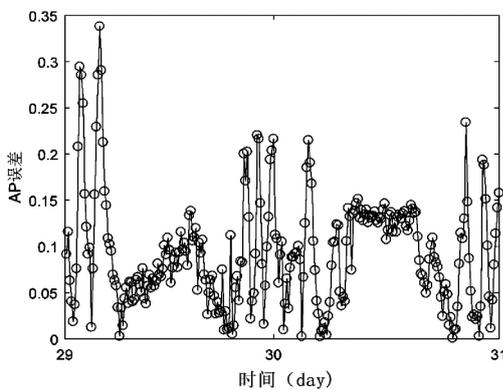


图9 ARIMA 模型的有功出力 AP 预测误差

从图 8 和图 9 可以得到,基于 ARIMA 的光伏预测模型 MSE 为 0.012 2,误差最大值为 0.338。从误差分布来看,主要集中在 0.15 以下,误差在全部预测期间的波动都剧烈,没有明显的分布特征,由此可以得出 ARIMA 模型具有有限的预测精度。

3.2 SOM - PSO - BP 预测结果

将 30 日、31 日的测试数据带入基于 SOM - PSO - BP 的光伏出力预测模型进行计算,得到预测结果和预测误差如图 10 所示。

从图 10 和图 11 中可以看到,所提出的基于 SOM - PSO - BP 预测模型的 MSE 误差为 $2.172\ 93 \times 10^{-3}$,误差最大值为 0.261 6。误差分布主要集中在 0.1 以下,在 AP 的上升段和下降段,预测数据和测试数据相差不大,预测误差主要集中在光伏出力的低谷时段,在这一时段,光伏出力波动变得剧烈,然而其波动幅值并不大,所以即便在图 7 中可以明

显看出预测误差偏离测试数据较大,但总体误差并未出现增加。对比图 8、图 9 和图 10、图 11,可以得出所提出的 SOM - PSO - BP 光伏预测模型在精度上领先 ARIMA 模型,在 MSE 指标上低一个数量级,在误差分布上更加稳定,且幅值低。

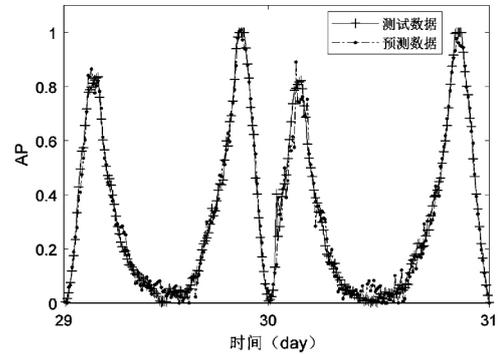


图10 SOM - PSO - BP 模型的有功出力 AP 预测结果

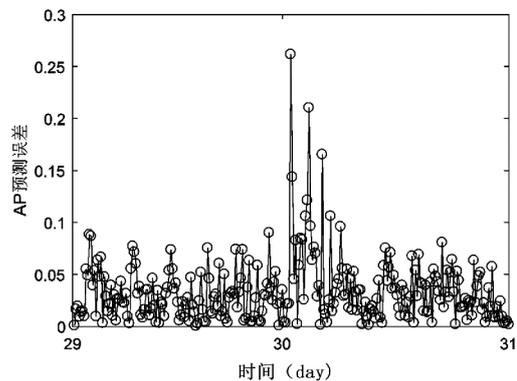


图11 SOM - PSO - BP 模型的有功出力 AP 预测误差

4 结 语

光伏出力预测对电网调度具有重要意义,通过预测数据能够及时调整调度计划,稳定电网电压、频率在正常范围内,提高电能质量,降低电网运行风险。所提出的基于 SOM 降维、PSO - BP 神经网络的光伏出力预测模型,通过光伏电站 1 个月的数据对预测模型进行训练,对比 ARIMA 预测模型得到了良好的预测效果,为解决光伏并网发电随机波动无法预测问题提供了一些建议。

参考文献

- [1] 赵争鸣,雷一,贺凡波,等. 大容量并网光伏电站技术综述[J]. 电力系统自动化,2011,35(12):101-107.
- [2] 龚莺飞,鲁宗相,乔颖,等. 光伏功率预测技术[J]. 电力系统自动化,2016,40(4):140-151.

(下转第 67 页)

于实现较为精确的纯手动控制。

5 国产主配压阀现状

目前中国在主配压阀选材、加工、热处理上面具有十分成熟的技术和丰富的应用经验,拥有一批较为成熟的产品,主配压阀通径系列涵盖了从 DN50 至 DN250 各种大小,压力等级适用于 2.5 ~ 6.3 MPa,能够满足各大、中、小型水轮发电机组的控制^[3]。

由于市场方面原因,国产主配压阀质量参差不齐,但从巨型水电机组上应用的产品来进行技术比较,国产主配压阀的活塞、衬套、引导阀等关键部件在选材、热处理、加工精度、使用寿命等方面与国外同类产品相当甚至更高,在壳体铸造工艺和流道设计上较进口产品还有一些差距,但对使用性能几乎没有影响。功能上国内主配压阀拥有集成的流量反馈装置可用于主配压阀掉电复中和手动控制,领先于国外产品;此外国产主配压阀具有齐全的功能附件,布置合理,便于操作。

应当注意,目前掉电复中型主配压阀应用越来越多,需要指出的是掉电复中必须结合电站的保护系统结构,保证极端故障失电时机组能够可靠停机。

6 结 语

通过对各种主配压阀结构和原理的了解,用户可以从安全性、控制性能、可靠性等方面结合电站自身情况进行分析,选择合适的主配压阀和控制逻辑,提高水轮机调节水平,保证水轮发电机组长期安全、可靠运行。

参考文献

- [1] 李壮云. 液压元件与系统(第二版) [M]. 北京: 机械工业出版社, 2005.
- [2] 魏守平. 现代水轮机调节技术 [M]. 武汉: 华中科技大学出版社, 2002.
- [3] 吴应文, 余志强, 王丽娟. 我国大型水轮机调速器主配压阀 [C]. 中国水电控制设备论文集, 2009: 222 - 231.

作者简介:

朱廷忠(1984), 工程师, 长期从事调速器液压控制系统设计和研究。

(收稿日期: 2017-09-15)

(上接第 28 页)

- [3] 丁明, 王伟胜, 王秀丽, 等. 大规模光伏发电对电力系统影响综述[J]. 中国电机工程学报, 2014, 34(1): 1 - 14.
- [4] Pingzhou Tang, Di Chen, Yushuo Hou. Entropy Method Combined with Extreme Learning Machine Method for the Short-term Photovoltaic Power Generation Forecasting [J]. Chaos, Solitons and Fractals, 2015(89): 243 - 248.
- [5] Honglu Zhu, Xu Li, Qiao Sun, et al. A Power Prediction Method for Photovoltaic Power Plant Based on Wavelet Decomposition and Artificial Neural Networks [J]. Energies, 2016, 9(1): 1 - 15.
- [6] 阳霜, 罗滇生, 何洪英, 等. 基于 EMD-LSSVM 的光伏发电系统功率预测方法研究 [J]. 太阳能学报, 2016, 37(6): 1387 - 1395.
- [7] 赵唯嘉, 张宁, 康重庆, 等. 光伏发电出力的条件预测误差概率分布估计方法 [J]. 电力系统自动化, 2015, 39(16): 8 - 15.
- [8] Wang Yufe, Sun Lu, Xue Hua. Photovoltaic Output Power Chaotic Characteristic and Trend Prediction Based on

the Actual Measurement Data [C]. Proceedings of the 2016 IEEE 11th Conference on Industrial Electronics and Applications, 2016, 1(1): 326 - 331.

- [9] Chen Jun - Ma, Wang Bing, Lu, Zhou - Xin, et al. Photovoltaic Power Generation Prediction Based on MEA - BP Neural Network [C]. 2017 32nd Youth Academic Annual Conference of Chinese Association of Automation, 2017, 1(1): 387 - 392.
- [10] 王守相, 张娜. 基于灰色神经网络组合模型的光伏短期出力预测 [J]. 电力系统自动化, 2012, 36(19): 37 - 41.
- [11] 熊志斌. ARIMA 融合神经网络的人民币汇率预测模型研究 [J]. 数量经济技术经济研究, 2011(6): 64 - 76.
- [12] 周明, 聂艳丽, 李庚银, 等. 基于小波分析的短期电价 ARIMA 预测方法 [J]. 电网技术, 2005, 29(9): 50 - 55.

作者简介:

詹仲强(1987), 硕士研究生, 主要从事新能源并网技术研究。

(收稿日期: 2017-12-10)