

基于 GA-BP 和 POS-BP 神经网络的光伏电站出力短期预测

姚仲敏¹, 潘飞¹, 沈玉会¹, 吴金秋¹, 于晓红²

(1. 齐齐哈尔大学通信与电子工程学院, 黑龙江 齐齐哈尔 161006;
2. 哈尔滨师范大学计算机与信息工程学院, 黑龙江 哈尔滨 150080)

摘要:当前在光伏电站出力短期预测方面较多的采用 BP 或者优化的 BP 神经网络算法, 存在采用的优化算法单一、缺乏多种优化算法比较选优、预测误差大的问题。基于本地 5 kW 小型分布式光伏电站, 综合考虑影响光伏出力的太阳光辐射强度、环境温度、风速气象相关因素和光伏电站历史发电数据, 分别采用 BP 以及遗传算法和粒子群算法优化的 BP 神经网络算法—GA-BP 和 POS-BP 构建了晴天、多云、阴雨三种天气条件下光伏出力短期预测模型。实测结果表明, 三种神经网络算法预测模型在三种不同天气条件下均达到了一定的预测精度。其中 GA-BP、POS-BP 相比传统的 BP 预测模型降低了预测误差, 且 POS 算法相比 GA 算法对于 BP 神经网络预测模型的优化效果更好, 进一步降低了预测误差, 适用性更强。

关键词: BP 神经网络算法; GA-BP 算法; POS-BP 算法; 光伏发电短期预测

Short-term prediction of photovoltaic power generation output based on GA-BP and POS-BP neural network

YAO Zhongmin¹, PAN Fei¹, SHEN Yuhui¹, WU Jinqiu¹, YU Xiaohong²

(1. College of Communications and Electronics Engineering, Qiqihar University, Qiqihar 161006, China;
2. College of Computer and Information Engineering, Harbin Normal University, Harbin 150080, China)

Abstract: In the current PV output short-term forecast, BP or optimization BP neural network algorithm is used commonly, which has problems of single optimization algorithm, the lack of a variety of optimization algorithms for comparison and selection, and big forecast error. Therefore, based on local 5 kW small-scale distributed PV power station, considering the related factors that influence PV output such as solar radiation intensity, environmental temperature, wind speed and historical generation data of photovoltaic power station, this paper uses BP, GA-BP and POS-BP neural network algorithm respectively to construct short-term prediction model of PV output in sunny, cloudy and rainy weather conditions. Test results show that three kinds of neural network prediction models all reach certain prediction accuracy under three different weather conditions, among which GA-BP and POS-BP prediction models reduce the prediction errors compared to the traditional BP model, and POS algorithm has a better optimization effect on BP neural network prediction model and a stronger applicability compared to GA algorithm, and further reduces the prediction errors.

Key words: BP neural network algorithm; GA-BP algorithm; POS-BP algorithm; photovoltaic power short-term prediction

中图分类号: TM715

文章编号: 1674-3415(2015)20-0083-07

0 引言

太阳能光伏发电系统输出受天文、地理、气象环境等多种因素的影响, 系统输出是个非平稳的随

机过程, 具有波动性、间歇性、周期性的特点, 是一个不可控源, 大规模分布式光伏电源接入大电网时, 如果光伏电站装机容量占电力总装机容量的比例失调会对大电网造成冲击, 影响大电网运行的安全性和稳定性^[1]。研究表明, 当光伏穿透功率超过总功率的 10% 时, 会显著拉大电网最大峰谷差率, 对电力调峰造成困难, 影响电能质量和电网正常、稳定的运行^[2]。因此, 结合天气信息预测未来 12 h

基金项目: 智能教育与信息工程黑龙江省高校重点实验室开放课题 (SEIE2014-05); 齐齐哈尔市科技局工业攻关项目 (GYGG-201106)

内不同时间点的光伏系统的实时输出功率，及时制定合理的电站调度、管理方案，适时调节光伏并网比例，可以有效降低光伏并网时比例失调对大电网的冲击，进而实现安全并网，平稳运行和经济调度，获得更大的经济效益和社会效益。

目前，国内多采用 BP 神经网络算法或结合数值优化算法进行光伏发电出力短期预测，并取得了一定的研究成果，但是较多的采用单一遗传算法(GA)或粒子群算法(POS)来优化 BP 预测模型，缺乏使用这两种算法对 BP 预测模型的优化效果对比研究、预测误差相对较大^[3-7]。

针对以上问题，本文综合考虑太阳辐照强度、环境温度、风速等气象因素和光伏电站历史发电数据，在晴天、多云、阴雨三种不同天气条件下分别采用 BP, GA-BP, POS-BP 三种神经网络算法构建光伏发电短期预测模型，根据未来短期内的天气信息预测工作时间内(7:00~18:00)每隔 30 min 的光伏系统输出功率。实验结果表明，本文改进的 GA-BP 和 POS-BP 预测模型相比传统 BP 预测模型预测误差有明显改善，并且粒子群算法在优化 BP 神经网络算法上比遗传算法有更好的适应性。

1 BP 神经网络

BP(Back Propagation)网络是一种误差反向传播训练的多层前馈神经网络，具有良好的自组织学习能力，它可以实现从输入到输出的任意非线性映射。其网络预测模型主要是通过输入信号正向传播和误差信号反向传播来实现训练过程的，能够对大规模数据进行并行处理，具有一定的鲁棒性和容错性^[8]，典型的三层 BP 神经网络基本结构如图 1 所示。

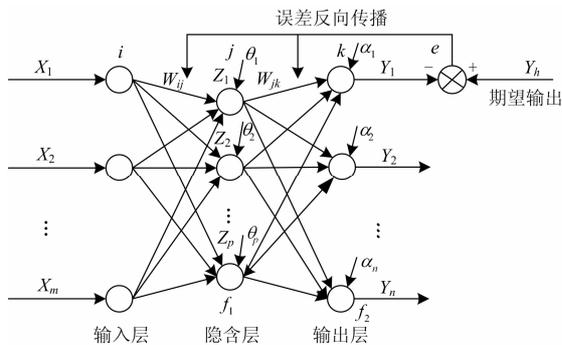


图 1 BP 神经网络基本结构

Fig. 1 Basic structure of BP neural network

如图 1 所示，输入层有 m 个神经元节点，隐含层有 p 个神经元节点，输出层有 n 个神经元节点， W_{ij} ($i=1,2,\dots,m; j=1,2,\dots,p$) 为输入层到隐含层的权值， W_{jk} ($j=1,2,\dots,p; k=1,2,\dots,n$) 为隐含层到输

出层的权值， θ_j ($j=1,2,\dots,p$) 为隐含层的阈值， α_k ($k=1,2,\dots,n$) 为输出层阈值， (X_1, X_2, \dots, X_m) 为神经网络输入向量， (Y_1, Y_2, \dots, Y_n) 为神经网络输出向量， Y_h 为期望输出， e 为神经网络期望输出与实际输出的误差。

输入向量从输入层、隐含层、输出层逐层传播，用各层连接权值和阈值和激励函数来计算，得到输出层的输出向量；BP 神经网络的输出值与期望值之间的误差自输出层、隐含层、输入层逐层反向传播，沿着误差减小的方向修正各层连接的权值、阈值，反复修改权值、阈值直至算法收敛，得到满意的误差精度。

BP 神经网络算法用于本地 5 kW 小型分布式光伏电站出力短期预测，采用三层结构，输入层是气象环境参量，共 25 个神经元节点，为每日光伏电站工作时段内(7:00~18:00)每隔 30 min 共 23 个时间点的环境温度 T_1, T_2, \dots, T_{23} 、日平均太阳辐射强度 \bar{S} 、日平均风速 \bar{V} ；隐含层神经元节点数目根据经验公式(1)确定初始节点数，然后采用“试凑法”逐步增大和减小隐含层节点数目使得神经网络的误差最小，最终隐含层节点数确定为 16；输出层是 23 个时间点光伏系统实时输出功率 P_1, P_2, \dots, P_{23} ，共 23 个神经元节点。因此，用于本地光伏电站短期功率预测的三层神经网络结构为 25—16—23。

$$p = \sqrt{m+n+a} \quad (1)$$

式中， a 的取值范围为 1~10。

虽然 BP 神经网络算法可以通过不断地训练学习拟合任何输入、输出之间的各种复杂的非线性关系，具有一定的鲁棒性和泛化能力，但是 BP 神经网络算法存在自身的“缺陷”，由于 BP 神经网络算法采用标准梯度下降算法，在数据训练时很容易陷入局部极值，导致数据训练失败；同时 BP 神经网络算法存在数据“过拟合”现象，通常神经网络的预测能力与样本训练能力成正比，但是实际上随着样本训练能力提高，BP 神经网络预测能力会达到一个极限值，之后预测能力会有所下降，即所谓“过拟合”现象。因此为了改善 BP 神经网络算法容易陷入局部极值和数据过拟合的缺陷，采用遗传算法(GA)、粒子群算法(POS)等数值优化算法来优化 BP 神经网络。

2 GA-BP 神经网络

遗传算法(Genetic Algorithm, GA)是基于生物进化原理的一种多点搜索全局性优化算法，因此可以避免局部最优。GA 采用启发性原理，按照一定

的适用度函数处理种群中的个体, 保留适应度高的个体进行遗传操作(选择、交叉、变异), 模拟自然进化过程—“优胜劣汰”, 搜索最优解^[9]。

传统的 BP 神经网络算法预测模型容易陷入局部最优、收敛速度较慢, 同时也容易出现数据“过拟合”。而遗传算法有很强的宏观搜索能力, 良好的全局优化性能, 用来优化 BP 神经网络模型各层之间的连接权值和阈值, 能够很好地弥补 BP 神经网络算法的缺陷, 提高 BP 神经网络模型预测逼近能力。遗传算法优化 BP 神经网络过程主要包括种群初始化、适应度函数、选择、交叉和变异操作。

2.1 种群初始化

常见的 GA 染色体编码方式有二进制编码, 实数编码, 字符编码, 字符串编码^[10]。本地 5 kW 分布式光伏电站出力短期预测模型有 25 个环境输入量(23 个时间点环境温度 T_1, T_2, \dots, T_{23} 、日平均太阳辐照强度 \bar{S} 、日平均风速 \bar{V}), 23 个光伏出力(23 个时间点光伏系统实时输出功率 P_1, P_2, \dots, P_{23}), 其中隐含层有个 17 个神经元节点, 则有 25×17 个权值 W_{ij} , 17×23 个权值 W_{jk} , 隐含层 17 个阈值, 输出层 23 个阈值。种群个体编码方式采用实数编码, 种群中个体包括输入层与隐含层连接权值、隐含层阈值、隐含层与输出层连接权值和输出层阈值, 则个体编码长度为 $25 \times 17 + 17 \times 23 + 17 + 23 = 856$ 。

2.2 适应度函数

根据个体编码值得到 BP 神经网络的各层之间连接权值和阈值, 采用训练数据预测误差绝对值和 E 作为个体适应度值 F , 计算公式为

$$F = k \left(\sum_{i=1}^n \text{abs}(y_i - z_i) \right) \quad (2)$$

式中: n 为输出节点数; y_i 为 BP 神经网络第 i 个节点的期望输出; z_i 为 BP 神经网络第 i 个节点的预测输出; k 为系数。

2.3 选择交叉和变异操作

采用轮盘赌法进行遗传算法选择操作, 即基于适应度比例的选择策略, 每个个体 x 选择概率 p_x 为

$$p_x = \frac{f_x}{\sum_{j=1}^N f_j} \quad (3)$$

$$f_x = k / F_x \quad (4)$$

式中: F_x 为个体 x 的适应度值; N 为个体种群数; k 为系数。

为保证遗传算法种群的多样性和收敛性, 采用自适应交叉变异算子。在个体适应度小于平均适应度时, 使用较大的交叉、变异概率, 以加快个体更

新, 增加种群多样性; 反之, 采用较小的交叉、变异概率, 来保障适应度高的个体在群体中的比例, 提高算法的收敛速度^[11]。

自适应交叉概率 P_c 的计算公式为

$$P_c = \begin{cases} K_1 \frac{(F_{\max} - F_{\text{avg}})}{F_{\max} - F_a} & F_a \leq F_{\text{avg}} \\ K_2 & F_a > F_{\text{avg}} \end{cases} \quad (5)$$

自适应变异概率 P_m 的计算公式为

$$P_m = \begin{cases} K_3 \frac{(F_{\max} - F_b)}{F_{\max} - F_{\text{avg}}} & F_b \leq F_{\text{avg}} \\ K_4 & F_b > F_{\text{avg}} \end{cases} \quad (6)$$

式中: F_a 为待交叉个体的适应度值; F_b 为待变异个体的适应度值; F_{\max} 为当前种群中的最大适应度值; F_{avg} 为当前种群中的平均适应度值; K_1, K_2, K_3, K_4 为 0~1 之间的随机数, 一般取 $K_1 \cdot K_2 = 1, K_3 \cdot K_4 = 0.5$ 。

2.4 GA-BP 算法流程

GA-BP 算法的流程图如图 2 所示, 根据 BP 神经网络的结构确定各层之间连接权值和各层的阈值总数, 进而对种群中个体进行编码, 采用神经网络训练误差和作为适应度函数, 通过选择、自适应交叉和变异得到种群最佳适应度个体, 作为神经网络最佳初始权值、阈值, 进行 BP 神经网络训练、预测仿真, 直到满足预测误差要求或者达到最大迭代次数结束。

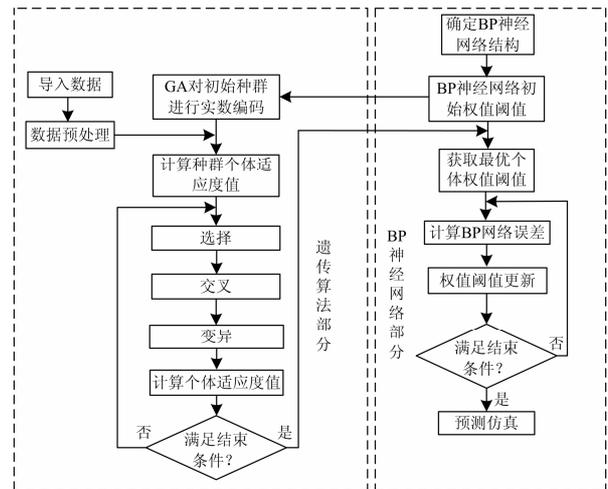


图 2 GA-BP 算法流程图

Fig. 2 GA-BP algorithm flowchart

3 POS-BP 算法

粒子群(Particle Swarm Optimization)算法简称 POS, 是一种群体智能优化算法, 源于生物界中鸟

类的捕食行为, 鸟类捕食时, 每只鸟找到食物最简单有效的方法就是搜寻当前距离食物最近的鸟的周围区域^[12]。与遗传算法类似, 粒子群算法也是采用种群中个体的适应度进行评估个体优劣, 但没有遗传操作的交叉和变异操作, 在 BP 神经网络权值、阈值可解空间中初始化一群粒子, 每个粒子都包含 BP 神经网络所有权值和阈值信息, 用种群中粒子的位置、速度和适应度值三项指标表征粒子特征, 通过跟踪个体最佳位置 $gbest$ 和群体最佳位置 $zbest$ 来获得最佳 BP 神经网络初始化权值和阈值, 可以加快 BP 神经网络收敛速度进而提高 BP 神经网络预测性能^[13]。

3.1 POS 种群初始化

根据 BP 神经网络的结构, POS 算法初始化种群粒子为 856 维行向量, 即包含 BP 神经网络所有权值和阈值, 适应度函数仍然采用 GA-BP 中的神经网络训练误差和, 然后通过迭代寻找种群最优粒子, 即神经网络最优初始化权值、阈值, 然后进行 BP 神经网络训练、预测。

3.2 POS 种群粒子更新

粒子群算法中粒子每一次迭代, 通过个体极值和全局极值进行自身速度和位置更新, 更新公式为如下。

速度更新公式为

$$V_i^{k+1} = w \cdot V_i^k + c_1 \cdot r_1 \cdot (P_g^k - X_i^k) + c_2 \cdot r_2 \cdot (P_z^k - X_i^k) \quad (7)$$

位置更新为

$$X_i^{k+1} = X_i^k + V_i^{k+1} \quad (8)$$

式中: k 为当前迭代次数; V_i^{k+1} 指种群中第 i 个粒子第 $k+1$ 代移动速度; V_i^k 指第 i 个粒子第 k 代移动速度; w 为惯性权重; r_1 和 r_2 为 0~1 之间的随机数; c_1 和 c_2 是粒子的加速度因子, 取非负常数。

选用可变惯性权重, 参考公式为

$$w = w_{\max} - \frac{w_{\max} - w_{\min}}{i_{\max}} \cdot i_i \quad (9)$$

式中: i_{\max} 指粒子群最大迭代次数; i_i 指粒子当前迭代次数; w_{\max} 为最大惯性权重, 典型取值为 0.9; w_{\min} 为最小惯性权重, 典型取值为 0.4。当粒子最大速度很小时, 一般使 w 接近于 1, 反之, 常取 $w=0.8$ 。 w 很小时有利于发挥 POS 算法的局部搜索能力, 比较大时侧重于发挥其全局搜索能力。

3.3 POS-BP 算法流程

POS-BP 算法流程图如图 3 所示, 相比于 GA 算法粒子群初始化没有采用编码方式, 而是根据 BP

神经网络各层之间连接权值和各层阈值总数, 随机初始化一定范围内的粒子位置和速度, 适应度函数同样利用 GA-BP 中适应度函数, 通过不断迭代寻找个体极值和种群极值, 把种群极值(包含 BP 神经网络所有权值、阈值)作为 BP 神经网络训练预测的初始权值和阈值, 改善 BP 神经网络预测效果。

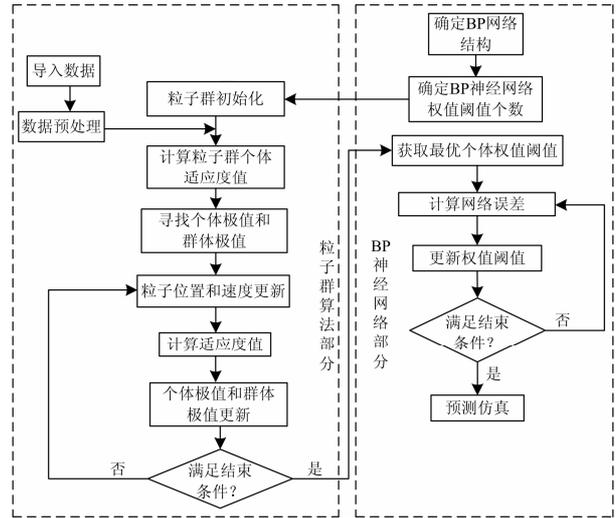


图 3 POS-BP 算法流程图

Fig. 3 POS-BP algorithm flowchart

4 实验测试

4.1 预测误差指标

选用平均绝对百分比误差(MAPE)和均方根误差(RMSE)作为本地光伏电站出力预测误差指标, 具体参考公式^[14]为

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{P_{pi} - P_{mi}}{P_{mi}} \right| \times 100\% \quad (10)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (P_{pi} - P_{mi})^2}{N}} \quad (11)$$

式中: N 为预测光伏系统输出功率的总个数; P_{pi} 为第 i 个时间点的光伏预测输出功率; P_{mi} 为第 i 个时间点实测光伏输出功率。

4.2 预测仿真测试

从本地 5 kW 分布式光伏电站历史数据库中提取 2014 年 3~5 月春季气象环境数据和历史发电数据, 对数据进行筛选整理, 取其中 50 组有效数据, 按天气条件(晴天、多云、阴雨)进行分类整理, 其中晴天数据 15 组, 多云天数据 20 组, 阴雨天数据 15 组, 每组输入数据包含 25 个输入环境参量(每日光伏逆变器工作时段内 7:00~18:00 每隔 30 min

共 23 个时间点的环境温度 T_1, T_2, \dots, T_{23} 、日平均太阳辐照强度 \bar{S} 、日平均风速 \bar{V}) 和 23 个光伏系统输出量(每日光伏电站工作时段内 7:00~18:00 每隔 30 min 的 23 个时间点光伏输出功率 $P_1, P_2, \dots,$

P_{23})。对春季晴天、多云、阴雨天分别采用 BP、GA-BP、POS-BP 神经网络算法进行训练、预测, 预测结果和实测结果进行对比分析。经多次反复仿真试验, 确定各算法训练参数如表 1 所示。

表 1 各神经网络算法参数设置

Table 1 Each neural network algorithm parameter settings

神经网络算法	天气条件	数据量	种群规模	进化代数	BP 训练迭代次数	学习率	训练目标误差
BP	晴天	15	-	-	2 000	0.1	0.000 04
	多云	20	-	-	2 000	0.1	0.000 04
	阴雨	15	-	-	2 000	0.1	0.000 04
GA-BP	晴天	15	10	10	2 000	0.1	0.000 04
	多云	20	10	10	2 000	0.1	0.000 04
	阴雨	15	15	15	2 000	0.1	0.000 04
POS-BP	晴天	15	10	10	2 000	0.1	0.000 04
	多云	20	10	10	2 000	0.1	0.000 04
	阴雨	15	15	15	2 000	0.1	0.000 04

BP 神经网络采用 3 层结构, 输入层 25 个节点, 隐含层 16 个神经元节点, 输出层 23 个神经元节点。三种天气条件下三种神经网络算法预测与实测对比曲线分别如图 4~图 6 所示, 对应的预测误差数据表如表 2 所示。

4.3 分析比较

由以上三组不同天气条件下采用 BP、GA-BP、POS-BP 三种不同神经网络算法的光伏电站输出功率短期预测与实测对比曲线和预测误差数据表, 可得春季晴天光伏输出功率曲线相对比较平缓, 多云天和阴雨天波动相对较大, 这是由于多云天和阴雨天太阳光辐射强度波动较大; 三种不同神经网络算法在三种不同天气条件下均能实现本地光伏电站输

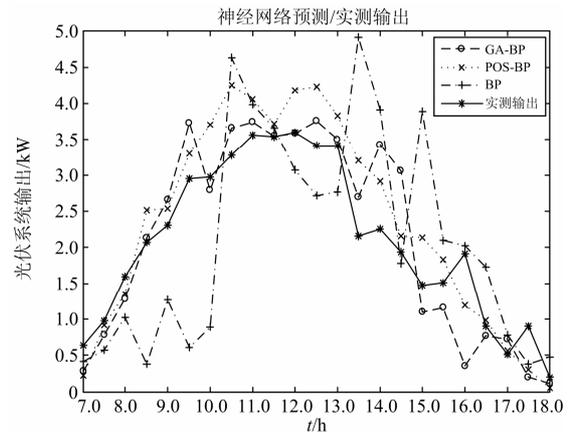


图 5 春季多云天三种神经网络预测与实测对比曲线

Fig. 5 Three kinds of neural networks predicted and measured contrast curves in cloudy days of spring

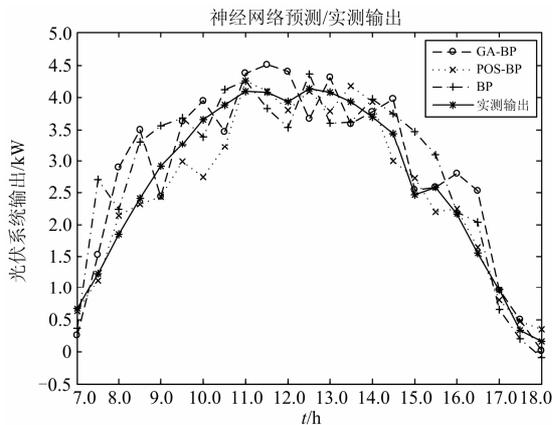


图 4 春季晴天三种神经网络预测与实测对比曲线

Fig. 4 Three kinds of neural networks predicted and measured contrast curves in sunny days of spring

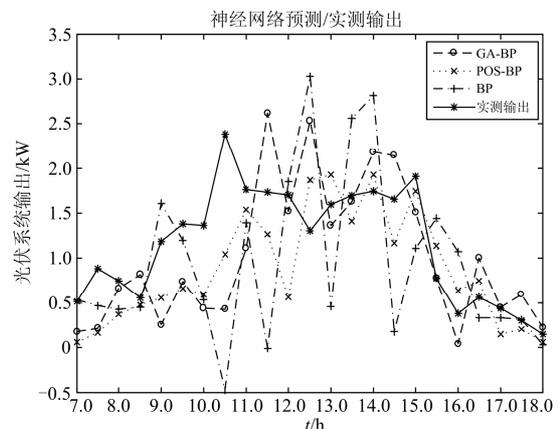


图 6 春季阴雨天三种神经网络预测与实测对比曲线

Fig. 6 Three kinds of neural networks predicted and measured contrast curves in rainy days of spring

表 2 三种不同天气条件下预测误差数据表
Table 2 Prediction error data table at three different weather conditions

神经网络 算法	天气 条件	平均绝对百分比误差 MAPE/%	均方根误差 RMSE/kW
BP	晴天	28.40	0.528 5
	多云	54.26	1.233 2
	阴雨	58.21	0.991 5
GA-BP	晴天	23.46	0.498 2
	多云	26.64	0.570 4
	阴雨	46.80	0.672 8
POS-BP	晴天	15.27	0.325 0
	多云	26.20	0.534 0
	阴雨	43.05	0.546 8

出功率短期预测,晴天三种神经网络算法预测效果要明显优于多云天和阴雨天;遗传算法和粒子群算法在三种不同天气条件下均能实现对 BP 预测模型的优化,有效降低 BP 预测模型的预测误差,并且粒子群算法优化效果相对遗传算法更好,更具有适用性。

5 结论

本文针对现有传统 BP 预测模型缺乏多类数值优化算法比较研究、输入气象因素和天气条件考虑不全面以及预测误差较大,采用遗传算法、粒子群算法分别优化 BP 神经网络光伏发电短期预测模型。分别采用改进的 GA 算法和 POS 算法对 BP 神经网络的权值和阈值进行优化,并在晴天、多云、阴雨三种不同天气条件下分别构建了 BP、GA-BP、POS-BP 三种光伏出力短期预测模型,并进行了预测与实测曲线对比和误差分析。测试仿真结果表明,三种天气条件下,GA 算法和 POS 算法都能有效提高 BP 预测模型预测精度,优化预测效果;且遗传算法相比粒子群算法优化效果更好,更具有适用性,POS-BP 预测模型相比 GA-BP 预测模型预测效果更好,可以作为本地小型分布式光伏电站出力短期预测的有效模型,对电力管理部门及时制定合理的能量管理、调度方案来保障光伏并网后大电网稳定、安全的运行具有一定的实际意义。

参考文献

[1] 罗建春, 晁勤, 罗洪, 等. 基于 LVQ-GA-BP 神经网络光伏电站出力短期预测[J]. 电力系统保护与控制, 2014, 42(13): 89-94.
LUO Jianchun, CHAO Qin, LUO Hong, et al. PV

short-term output forecasting based on LVQ-GA-BP neural network[J]. Power System Protection and Control, 2014, 42(13): 89-94.

[2] 卢静, 翟海青, 刘纯. 光伏发电功率预测统计方法研究[J]. 华东电力, 2010, 38(4): 563-567.
LU Jing, ZHAI Haiqing, LIU Chun. Study on statistical method for predicting photovoltaic generation power[J]. East China Electric Power, 2010, 38(4): 563-567.

[3] 袁晓玲, 施俊华, 徐杰彦. 基于 BP 神经网络的光伏发电短期出力预测[J]. 可再生能源, 2013, 31(7): 11-16.
YUAN Xiaoling, SHI Junhua, XU Jiayan. Short-term power forecast for photovoltaic generation based on BP neural network[J]. Renewable Energy Resources, 2013, 31(7): 11-16.

[4] 康洪波, 刘瑞梅, 侯秀梅. 基于神经网络光伏发电预测模型的研究[J]. 电源技术, 2013, 37(3): 447-449.
KANG Hongbo, LIU Ruimei, HOU Xiumei. Research of power forecasting model of photovoltaic power system based on neural network[J]. Chinese Journal of Power Sources, 2013, 37(3): 447-449.

[5] 丁明, 王磊, 毕锐. 基于改进 BP 神经网络的光伏发电系统输出功率短期预测模型[J]. 电力系统保护与控制, 2012, 40(11): 93-99.
DING Ming, WANG Lei, BI Rui. A short-term prediction model to forecast output power of photovoltaic system based on improved BP neural network[J]. Power System Protection and Control, 2012, 40(11): 93-99.

[6] 陈年, 王宏华, 韩伟. 基于 GA-BP 神经网络的光伏阵列 MPPT 研究[J]. 电测与仪表, 2014, 51(2): 40-44.
CHEN Nian, WANG Honghua, HAN Wei. Research on GA-BP based MPPT algorithm for photovoltaic array[J]. Electrical Measurement & Instrumentation, 2014, 51(2): 40-44.

[7] 张佳伟, 张自佳. 基于 POS-BP 神经网络的短期光伏系统发电预测[J]. 可再生能源, 2012, 30(8): 28-32.
ZHANG Jiawei, ZHANG Zijia. Short-term photovoltaic system power forecasting based on POS-BP neural network[J]. Renewable Energy Resources, 2012, 30(8): 28-32.

[8] 陈昌松, 段善旭, 殷进军. 基于神经网络的光伏阵列发电预测模型的设计[J]. 电工技术学报, 2009, 24(9): 153-158.

- CHEN Changsong, DUAN Shanxu, YIN Jinjun. Design of photovoltaic array power forecasting model based on neural network[J]. Transactions of China Electrotechnical Society, 2009, 24(9): 153-158.
- [9] 黄建国, 罗航, 王厚军, 等. 运用 GA-BP 神经网络研究时间序列的预测[J]. 电子科技大学学报, 2009, 38(5): 688-692.
- HUANG Jianguo, LUO Hang, WANG Houjun, et al. Prediction of time sequence based on GA-BP neural net[J]. Journal of University of Electronic Science and Technology of China, 2009, 38(5): 688-692.
- [10] 冯超, 周步祥, 林楠, 等. 电动汽车充电站规划的多种群混合遗传算法[J]. 电力系统及其自动化学报, 2013, 25(6): 124-129.
- FENG Chao, ZHOU Buxiang, LIN Nan, et al. Electric vehicle charging station planning based on multiple-population hybrid genetic algorithm[J]. Proceedings of the CSU-EPSCA, 2013, 25(6): 124-129.
- [11] 罗毅, 刘峰. 基于遗传神经网络的风电场输出功率短期预测[J]. 华东电力, 2012, 40(7): 1206-1208.
- LUO Yi, LIU Feng. Short-term forecast of wind farm output power based on genetic algorithm neural network[J]. East China Electric Power, 2012, 40(7): 1206-1208.
- [12] 林方, 袁越, 王敏, 等. 电动汽车接入微网研究[J]. 电网与清洁能源, 2013, 29(10): 81-85.
- LIN Fang, YUAN Yue, WANG Min, et al. Study of microgrid with electric vehicles[J]. Power System and Clean Energy, 2013, 29(10): 81-85.
- [13] 田金波, 赵智忠, 毕海岩. 基于 DSP 的 BP 神经网络真空度数据采集系统[J]. 高压电器, 2014, 50(12): 47-54.
- TIAN Jinbo, ZHAO Zhizhong, BI Haiyan. Vacuum level acquisition system of BP neural network based on DSP[J]. High Voltage Apparatus, 2014, 50(12):47-54.
- [14] 师彪, 李郁侠, 于新花, 等. 改进粒子群-BP 神经网络模型的短期电力负荷预测[J]. 计算机应用, 2009, 29(4): 1037-1039.
- SHI Biao, LI Yuxia, YU Xinhua, et al. Short-term load forecast based on modified particle swarm optimizer and back propagation neural network model[J]. Journal of Computer Applications, 2009, 29(4): 1037-1039.

收稿日期: 2015-01-14; 修回日期: 2015-04-10

作者简介:

姚仲敏(1959-), 女, 教授, 硕士生导师, 研究方向为基于物联网的光伏电站实验系统研究;

潘飞(1989-), 男, 硕士研究生, 研究方向为基于物联网的太阳能光伏电站预报模型研究; E-mail: 1032308804@qq.com

沈玉会(1987-), 女, 硕士研究生, 研究方向为基于物联网的车辆定位技术。

(编辑 周金梅)