

# 改进BP神经网络的光伏系统发电功率预测<sup>①</sup>

韩艳赞, 周 伟

(河南工业职业技术学院, 南阳 473000)

**摘要:** 为了提高光伏发电功率的预测精度, 提出一种改进BP神经网络的光伏发电功率预测模型. 首先采用包括室外温度、光照辐射量、风速等作为输入层节点, 交流发电功率作为输出节点, 引入RMSE作为衡量最优模型指标, 确定了隐含层节点数, 然后采用BP神经网络对其进行学习, 并采用布谷鸟搜索算法对BP神经网络进行优化, 最后采用仿真实验对其有效性进行测试. 结果表明, 改进神经网络提高了光伏发电功率预测精度, 具有一定的推广价值.

**关键词:** BP神经网络; 发电功率; 预测模型; 布谷鸟搜索算法

## Prediction of Capacity of Power Generation System Based on Improved BP Neural Network

HAN Yan-Zan, ZHOU Wei

(Henan Polytechnic Institute, Nanyang 473000, China)

**Abstract:** In order to improve the prediction accuracy of photovoltaic power generation, a prediction model of photovoltaic power generation based on improved BP neural network is proposed. First, such factors as outdoor temperature, light radiation, wind speed and other factors are taken as input layer nodes while AC power is taken as output nodes, RMSE is introduced as indicators to measure the optimal model to determine number of hidden layer nodes, and then BP neural network is used to learn which cuckoo search algorithm is used to optimize BP neural network. Finally, the simulation experiment is used to test its effectiveness. The results show that improved neural network can improve prediction accuracy of photovoltaic power generation, and it has a widespread value.

**Key words:** BP neural network; capacity of power generation; prediction model; cuckoo search algorithm

### 1 引言

研究光伏发电系统发电功率预测对实现太阳能并网利用, 降低电力系统的运行成本, 提高能源利用率, 推动光伏发电快速健康稳定发展具有重要意义<sup>[1-3]</sup>.

光伏发电系统的发电功率预测传统模型主要包括: 线性回归, 泊松过程, 时间序列等<sup>[4-6]</sup>, 它们可以对线性光伏发电系统发电功率数据进行预测, 但光伏发电系统发电功率受到室外温度、光照辐射量、风速等影响因素, 变化相当复杂, 具有非线性变化特点, 因此传统预测模型的精度有待进一步提高. 随着非线性理论发展, 出现了以BP神经网络(BP neural network, BPNN)为代表的光伏发电系统发电功率非线性预测模

型, 可对光伏发电系统的发电功率变化特点进行准确跟踪, 提高了光伏发电系统发电功率的预测精度<sup>[7]</sup>. BP神经网络的预测性能与参数密切相关<sup>[8,9]</sup>. 为此, 有学者提出采用遗传算法、粒子群算法等对BP神经网络参数进行优化, 一定程度较好解决BP神经网络参数优化的难题, 但这些算法有各身的局限性<sup>[10]</sup>. 布谷鸟搜索(cuckoo search, CS)算法是一种新型的群体智能算法, 具有简单、参数少、易于实现等特点, 在模式识别、组合优化等领域得到了广泛的应用<sup>[11]</sup>.

为了提高光伏发电系统发电功率预测精度, 针对BP神经网络参数优化的难题, 提出一种改进神经网络的光伏发电系统发电功率预测模型(CS-BPNN). 仿真

<sup>①</sup> 基金项目:河南省科技攻关项目(132102210208)

收稿时间:2015-12-04;收到修改稿时间:2016-06-20 [doi: 10.15888/j.cnki.csa.005582]

实验表明, CS-BPNN)获得理想的光伏发电系统发电功率预测结果.

## 2 BP神经网络和布谷鸟搜索算法

### 2.1 BP 神经网络

设一个系统输入为  $m$ 、隐层节点数是  $p$ 、输出个数是 1, 通过  $f:R^n \rightarrow R$  构建映射<sup>[13]</sup>, BP 神经网络的隐层节点输入为

$$S_j = \sum_{i=1}^n \omega_{ij} x(i) - \theta_j \quad (1)$$

其中,  $\omega_{ij}$  为从输入层到隐层的连接权值,  $\theta_j$  为隐层节点的阈值.

隐层节点的输出是

$$b_j = \frac{1}{1 + \exp(\sum_{i=1}^n \omega_{ij} x_i - \theta_j)} \quad (2)$$

输出层节点的输入是

$$L = \sum_{j=1}^p \omega_{jk} b_j - \theta_k \quad (3)$$

输出层节点的输出是

$$x_{i+1} = \frac{1}{1 + \exp(\sum_{j=1}^p v_j b_j - \gamma)} \quad (4)$$

式中,  $v_j$  表示从隐层到输出层的连接权值;  $\gamma$  表示输出层的阈值.

在 BP 神经网络的建模过程中, 连接权值和阈值等参数直接其预测性能, 因此本文选择布谷鸟搜索算法确定最优的参数值.

### 2.2 布谷鸟搜索算法

设  $x_i^{(k)}$  为第  $i$  个鸟巢在第  $k$  代的鸟巢位置,  $L(\lambda)$  为 Levy 随机搜寻路径, 则布谷鸟寻巢的路径和位置更新方式为:

$$x_i^{k+1} = x_i^k + \partial \oplus L(\lambda), i = 1, 2, \dots, n \quad (5)$$

其中,  $\partial$  为步长控制量,  $\oplus$  为点对点乘法.

更新鸟巢的位置后, 产生一个随机数  $r$ , 如果  $r > P_a$ , 那么随机改变  $x_i^{k+1}$ , 不然保持鸟巢的位置, 最后保留最优一组鸟巢位置  $y_i^{k+1}$ , 也将  $y_i^{k+1}$  记为  $x_i^{k+1}$ .

采用 3 个准测试函数对布谷鸟 CS 算法和粒子群算法 PSO(Particle Swarm Optimization)的性能进行对比测试, 各测试函数的数学表达式如表 1 所示. 两种算法的运行结果如图 1 所示. 对图 1 进行分析可以看出, CS 算法的性能均优于粒子群算法(PSO)算法, 对比结果表明, CS 算法加快算法收敛速度, 提高了算法的搜索能力, 获得了更优的结果.

表 1 测试函数的具体描述

函数名	函数形式	约束条件
$f_1$	$\max f(\vec{x}) = (\sqrt{n})^n \prod_{i=1}^n x_i$	$\begin{cases} n = 10, \\ 0 \leq x_i \leq 10 (i = 1, 2, \dots, n) \end{cases}$
$f_2$	$\min f(\vec{x}) = x_1^2 + (x_2 - 1)^2$	$h(\vec{x}) = x_2 - x_1^2 = 0$
$f_3$	$\min f(\vec{x}) = \frac{\sum_{i=1}^n \cos^4(x_i) - 2 \prod_{i=1}^n \cos^2(x_i)}{\sqrt{\sum_{i=1}^n i x_i^2}}$	$\begin{cases} g_1(\vec{x}) = 0.75 - \prod_{i=1}^n x_i \leq 0 \\ g_2(\vec{x}) = \sum_{i=1}^n x_i - 7.5n \leq 0 \\ n = 20, 0 \leq x_i \leq 10, i = 1, 2, \dots, 20 \end{cases}$

### 2.3 布谷鸟算法优化 BP 神经网络参数步骤

Step1: 初始化鸟巢数  $n$ 、 $P_a$  及最大迭代次数  $N_{max}$  等参数.

Step2: 随机产生  $n$  个鸟巢的初始位置:  $q_i^{(0)} = [x_1^{(0)}, x_2^{(0)}, \dots, x_n^{(0)}]^T$ , 它们与 BP 神经网络初始阈值和连接权值相对应, BP 神经网络根据参数值对训练集进行训练, 并计算预测结果.

Step3: 根据预测结果找出当代的最佳鸟巢的位置  $x_d^{(0)}$ , 并根据式(5)更新鸟巢位置, 得到新的鸟巢位置.


Step4: 计算新鸟巢位置, 并用好的鸟巢位置代替上一代较差的鸟巢位置, 得出较优的一组鸟巢位置  $e_k = [x_1^{(k)}, x_2^{(k)}, \dots, x_n^{(k)}]^T$ .

Step5: 将  $r$  与  $P_a$  进行比较, 保留  $e_k$  中较小  $P_a$  的鸟巢, 并更新较大  $P_a$  鸟巢位置, 得到一组新鸟巢位置, 并用好的替代  $e_k$  中较差的鸟巢位置, 得出新一组较佳鸟巢位置  $q_k = [x_1^{(k)}, x_2^{(k)}, \dots, x_n^{(k)}]^T$ .


Step6: 找出  $q_k$  中最佳的一个鸟巢位置  $x_d^{(k)}$ , 如果达到最大迭代次数, 若是, 则停止搜索, 并输出最佳位置  $x_d^{(k)}$ , 否则, 回到 Step3 继续优化.

Step7 根据最佳鸟巢位置  $x_d^{(k)}$  对应的参数作为 BP 神经网络初始阈值和权值, 对训练集进行训练, 建立光伏发电系统发电功率预测模型.


综合上述可知, 本文基于 CS-BPNN 的光伏发电系统发电功率预测模型的工作流程如图 2 所示.



(a) f1 适应度变化曲线



(b) f2 适应度变化曲线



(c) f3 适应度变化曲线

图 1 CS 算法与其它算法的性能对比

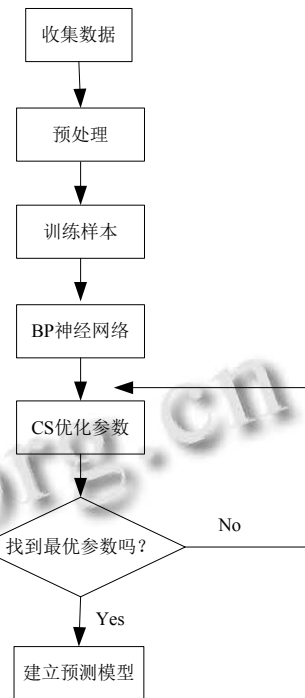


图 2 光伏发电系统发电功率的建模流程

### 3 CS-BPNN在光伏发电系统发电功率预测中的应用

#### 3.1 数据来源

采用一个光伏发电系统每小时数据作为测试对象, 选择 200 个数据作为训练集, 100 个作为预测集, CS 算法的参数设置为: 最大迭代次数为 600, 鸟巢数为 40, 外来蛋的发现概率  $P_a=0.25$ . 为了使 CS-BPNN 预测结果具有可比性, 选择 BPNN 进行对比实验, 采用均方根误差(root mean square error, RMSE)和平均相对百分比误差(mean percent absolute error, MPAE)进行衡量, 它们定义为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{x}(i) - x(i))^2} \quad (6)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{x}(i) - x(i)}{x(i)} \right| \times 100\% \quad (7)$$

式中,  $n$  表示样本数.

#### 3.2 数据预处理

采用小波分析中的信号奇异点检测法对历史数据中的不良数据进行剔除, 并采用神经网络的时间序列预测模型对剔除后的数据进行重构, 从而达到检测并消除不良数据的目的, 为发电功率预测提供能反应其变化规律的真实历史信息. 为了避免因输入输出数据

数量级差别较大而造成网络预测的误差较大和神经元出现饱和现象,对网络训练的输入、输出发电量数据进行归一化处理,使训练数据、测试数据都转化成为 [0,1]之间的数.采用归一化公式如下:

$$I^*(t) = \frac{l(t) - L_{\min}}{L_{\max} - L_{\min}} \quad (8)$$

式中,  $l(t)$ 为光伏系统发电量  $t$ 时刻原始数据,  $L_{\min}$ 为原始光伏发电量数据序列中的最小值,  $L_{\max}$ 为原始光伏发电量数据序列中的最大值,  $I^*(t)$ 为归一化后的发电量数据.

### 3.3 神经网络结构的确定

输入层节点个数对应于模型的输入量个数,本模型采用 8 个输入量,其中包括预测日某时刻的室外温度、光照辐射量、风速、风向、交流电流、交流电压、蓄电池温度、直流负荷电压等 8 个影响因素.模型输出的是预测日某时刻的发电量,即输出层 1 个节点.

隐含层节点数的选择对网络的学习训练都非常重要.如果隐含层的节点数过少,网络的学习能力和信息处理能力不能达到要求;如果隐含层节点数过多,不但会大大增加网络结构的复杂性,网络在学习过程中易陷入局部最优,还会使网络的学习训练速度变得很慢<sup>[4]</sup>.根据经验公式

$$N = \sqrt{n + m} + a \quad (9)$$

式中,  $N$ 为隐含层节点的个数,  $n$ 为输入层节点个数,  $m$ 为输出层节点个数,  $a$ 为 [0,10]的常数.

本文对不同隐含层节点个数进行多次实例仿真,将得到 RMSE 平均值作为一种确定最优模型的指标,结果表明当隐含层节点的个数  $N=9$ 时, RMSE 最小,对应的预测效果最好.

### 3.4 结果与分析

采用 CS 找到的 BPNN 最优参数,建立基于 CS-BPNN 的光伏发电功率预测模型,然后用测试集进行预测,其参数寻优曲线如图 3 所示,预测结果如图 4 所示.从图 4 可知,相对于 BPNN,CS-BPNN 提高了光伏发电功率的预测精度,预测偏差更小,对比结果表明,CS-BPNN 融合 CS 算法的全局搜索能力和 BPNN 的非线性预测,可以对光伏发电功率变化趋准确跟踪,预测结果更加稳定、可靠.

统计 BPNN、CS-BPNN 的光伏发电功率预测结果的 MAPE 和 RMSE 以及训练时间如见表 1.从表 1 可知,相对于 BPNN,CS-BPNN 预测误差更小,预测精度

更高,对比结果表明,CS-BPNN 建立了预测精度更高的光伏发电功率预测模型.相对于 BPNN,CS-BPNN 的训练时间有所增加,但是现在计算机性能不断提升,而且预测精度的提高相对于训练时间来说是值得,体现了 CS-BPNN 的优越性.




图 3 CS 的寻优曲线

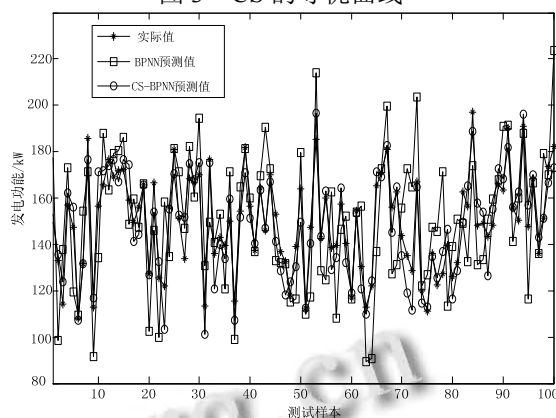


图 4 不同模型的预测性对比

表 2 不同模型的预测误差比较

模型	RMSE	MAPE	训练时间(s)
BPNN	24.73	8.56%	2.35
CS-BPNN	12.96	4.72%	3.68

## 4 结论

为了获得更加理想的光伏发电功率预测结果,建立了一种基于改进 BP 神经网络的光伏发电功率预测模型,该模型采用包括预测日某时刻的室外温度、光照辐射量、风速、风向、交流电流、交流电压、蓄电池温度、直流负荷电压等 8 个影响因素作为输入层节点,交流发电功率作为输出节点,引入 RMSE 作为衡量最优模型指标,确定了隐含层节点数为 9,然后采用布谷鸟搜索算法优化 BP 神经网络,最后通过实际仿

真验证了模型预测的精确性。

### 参考文献

- 1 赵争鸣,等.太阳能光伏发电及其应用.北京:科学出版社,2005.
- 2 张耀明.中国太阳能光伏发电产业的现状与前景.能源研究与利用,2007,1:1-6.
- 3 Ghoddami H, Yazdani A. A single-stage three-phase photovoltaic system with enhanced maximum power point tracking capability and increased power rating. IEEE Trans. on Power Delivery, 2011, 26(2): 1017-1029.
- 4 Yona A, Senjyc T, Funabashi T. Application of recurrent neural network to short-term ahead generating power forecasting for photovoltaic system. Power Engineering Society General Meeting, 2007: 1-7.
- 5 Rahman MH, Yamashiro S. Novel distributed power generating system of PV-ECaSS using solar energy estimation. IEEE Trans. on Energy Conversion, 2007, 22(2): 358-367.
- 6 代倩,段善旭,蔡涛,等.基于天气类型聚类识别的光伏系统短期无辐照度发电预测模型研究.中国电机工程学报, 2011,31(34):28-30.
- 7 丁明,工磊,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.电力系统保护与控制,2012,40(11): 94-99.
- 8 陈昌松,段善旭,蔡涛,等.基于模糊识别的光伏发电短期预测系统.电工技术学报,2011,26(7):83-88.
- 9 赵杰,张艳霞.基于 CAPSO-RNN 的光伏系统短期发电量预测.中国电力,2012,45(4):87-90.
- 10 张艳霞,赵杰.基于反馈型神经网络的光伏系统发电功率预测.电力系统保护与控制,2011,39(15):96-101.
- 11 Yang XS, Deb S. Engineering optimization by cuckoo search. International Journal of Mathematical Modeling and Numerical Optimization, 2010, 1(4): 330-343.