

# 基于改进萤火虫算法的5G基站光伏功率预测

陈婷婷<sup>1</sup>, 闫明<sup>2,3</sup>, 胡永乐<sup>4</sup>, 覃团发<sup>1,3\*</sup>

<sup>1</sup>广西大学计算机与电子信息学院, 广西 南宁

<sup>2</sup>广西大学电气工程学院, 广西 南宁

<sup>3</sup>广西大学多媒体通信与网络技术重点实验室, 广西 南宁

<sup>4</sup>润建股份有限公司, 广西 南宁

收稿日期: 2022年3月28日; 录用日期: 2022年4月19日; 发布日期: 2022年4月28日

## 摘要

为保证5G基站光伏供电系统的稳定性, 需要精确地预测光伏发电输出功率, 因此, 本文提出了一种基于改进萤火虫算法(Firefly Algorithm, FA)来优化反向传播(Back Propagation, BP)神经网络的光伏功率预测模型(IFA-BP), 首先采用灰色关联分析法分析多种气象因素对光伏功率预测的影响程度, 然后利用Circle混沌映射使萤火虫种群分布更加均匀, 并对寻得的萤火虫最优解加入非线性突变扰动来避免陷入局部最优解, 最后建立IFA-BP光伏功率预测模型。通过MATLAB进行仿真, 将本文提出的IFA-BP预测模型与FA-BP预测模型、BP预测模型的光伏功率预测结果对比分析, 结果表明, 提出的IFA-BP预测模型在不同天气下均具有最佳的预测精度。

## 关键词

萤火虫算法, BP神经网络, 5G基站, 光伏功率预测

# Photovoltaic Power Prediction of 5G Base Station Based on Improved Firefly Algorithm

Tingting Chen<sup>1</sup>, Ming Yan<sup>2,3</sup>, Yongle Hu<sup>4</sup>, Tuanfa Qin<sup>1,3\*</sup>

<sup>1</sup>School of Computer and Electronic Information, Guangxi University, Nanning Guangxi

<sup>2</sup>School of Electrical Engineering, Guangxi University, Nanning Guangxi

<sup>3</sup>Guangxi Key Laboratory of Multimedia Communications and Network Technology, Guangxi University, Nanning Guangxi

<sup>4</sup>Runjian Co., Ltd., Nanning Guangxi

\*通讯作者。

文章引用: 陈婷婷, 闫明, 胡永乐, 覃团发. 基于改进萤火虫算法的5G基站光伏功率预测[J]. 智能电网, 2022, 12(2): 43-55. DOI: 10.12677/sg.2022.122006

## Abstract

In order to ensure the stability of 5G base station photovoltaic power generation system, it is necessary to accurately predict the photovoltaic power generation output. Therefore, this paper puts forward an algorithm based on improved firefly to optimize the photovoltaic power of the back propagation neural network prediction model (IFA-BP), first using the method of grey correlation analysis of many kinds of meteorological factors to predict the impact of photovoltaic power. Then, Circle chaos mapping was used to make the firefly population distribution more uniform, and nonlinear mutation disturbance was added to the optimal firefly solution to avoid falling into the local optimal solution. Finally, the IFA-BP photovoltaic power prediction model was established. Simulation experiments were carried out by MATLAB, and the results of photovoltaic power prediction were compared with those of FA-BP prediction model and BP prediction model. The results show that the proposed FA-BP prediction model has the best prediction accuracy under different weather conditions.

## Keywords

Firefly Algorithm, BP Neural Network, 5G Base Station, Photovoltaic Power Prediction

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

5G 通信给人们的生活带来了极大的便利,其采用大规模天线阵列技术使传输速率大幅提升,但海量通信数据的传输所需的电能也大大的增加[1]。与 4G 网络相比,5G 对基站的数量和密度有更高的要求,其能耗水平提高了近 9 倍,从而带来了不可忽视的能耗挑战。面对当今地球生态环境的恶化和传统能源不断枯竭,为节约能源、确保可持续发展,引入光伏发电有望解决 5G 基站能耗大的问题[2]。然而由于受到季节、昼夜、地理位置和天气状况等不确定性因素的影响,以及太阳能资源本身具有的波动性、间歇性等特点,使得光伏发电系统的输出功率变化过程具有不稳定性[3]。为了减轻光伏发电系统对基站供电系统的安全性、稳定性所造成的影响,对其输出功率进行更精准地预测成为一项必要工作。

光伏功率预测研究可大致分为直接预测和间接预测。直接预测是指根据历史数据直接预测光伏发电功率;间接预测是指先对地表辐照强度、光伏板温度等进行预测,再将预测结果输入建立的光伏发电的物理模型,间接预测过程复杂且预测精度较低[4],其中本文使用的是直接预测的方式。目前国内外学者针对光伏功率预测取得了一定的成果,文献[5]建立了基于径向基神经网络的光伏预测模型,使得光伏功率预测更加方便且预测精度更高;文献[6]结合光伏发电系统的特性,提出并联灰色关联小二乘支持向量机预测方法和串联灰色关联小二乘支持向量机预测方法;文献[7]提出一种基于粒子群算法和神经网络算法的组合预测方法对光伏发电功率进行短期预测,仿真结果表明预测模型在晴朗天气时的预测结果较好。但是现有研究较少涉及 5G 基站供电系统中的光伏功率预测,且在群优化算法的应用中存在容易陷入局部最优从而使光伏功率预测精度降低的缺点。

本文建立了基于改进萤火虫算法优化 BP (Back Propagation)神经网络的 5G 基站光伏功率预测模型, 首先通过灰色关联分析法来确定对光伏功率预测相关性更强的输入变量类型, 此外提出了基于 Circle 混沌映射和非线性突变扰动等方式来避免萤火虫算法陷入局部最优, 用改进的萤火虫算法寻找神经网络中随机参数的最优解从而实现光伏功率预测精度的提高。最后采用该预测模型进行仿真, 验证了本文所提方法的有效性并提高了 5G 基站供电系统的稳定性。

## 2. 光伏功率预测模型

### 2.1. BP 神经网络

BP 神经网络是一种按照误差逆向传播算法训练的多层前馈神经网络, 一般由输入层、隐含层以及输出层构成, 层与层之间通过神经元连接, 同一层的神经元互不连接[8]。本文采用含有一个隐含层的三层 BP 神经网络搭建模型, 模型输入数据为光伏发电功率影响因素的值, 模型训练输出数据为光伏发电功率。其结构如图 1 所示。图中  $V_{ij}$  表示输入层第  $i$  个节点到隐含层第  $j$  个节点的连接权值,  $W_{jk}$  表示隐含层第  $j$  个节点到输出层第  $k$  个节点的连接权值,  $b_r$  表示隐含层第  $r$  个节点的阈值,  $h_k$  表示输出层第  $k$  个节点的阈值。

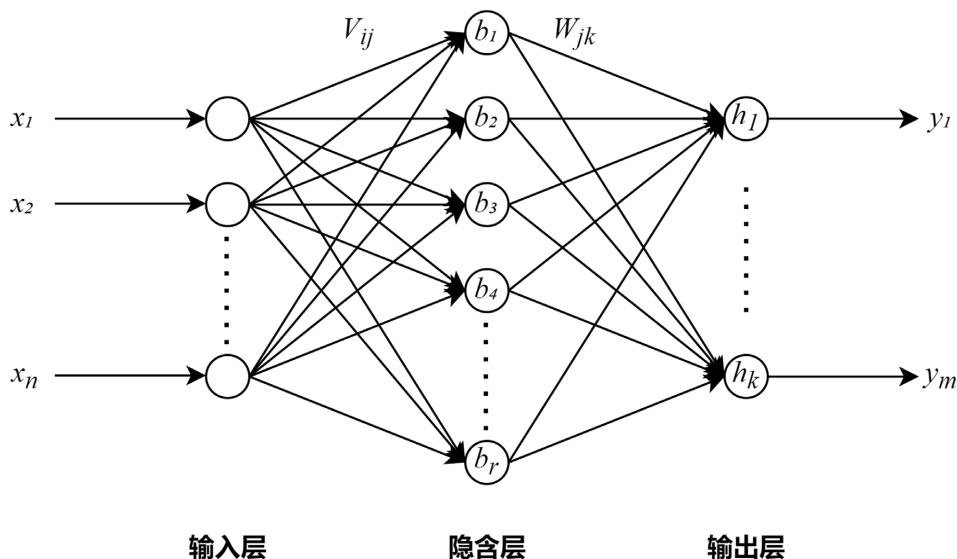


Figure 1. Structure of BP neural networks  
图 1. BP 神经网络结构

BP 神经网络的训练过程分为数据正向传播和误差值反向传播两个步骤。输入信号通过输入层输入模型, 输入层将数据传递给隐含层, 然后经过隐含层传向输出层, 这便实现了正向传播。当输出功率和实际功率值的差值不满足目标误差时, 就进入反向传播阶段, 将误差值通过输出层反向传播, 通过梯度下降法修正每个节点的权值和阈值。以上过程不断循环, 直到误差值满足目标误差范围或达到最大迭代次数便停止。

通过分析可知 BP 神经网络具有自学习、自适应能力, 只需使用历史数据进行训练, 便可达到良好的预测效果[9]。但其误差函数通常会有多个极值点, 并且其初始参数的选择具有随机性, 所以 BP 网络经常容易陷入局部最小, 不容易获得全局最优解。因此本文考虑在构建 BP 神经网络之前先用改进的萤火虫算法去搜寻神经网络中各个节点的连接权值和阈值的最优解, 再将求得的最优解赋值给神经网络, 以此弥补 BP 神经网络的缺点, 从而提高模型的预测精度。

## 2.2. 改进萤火虫算法

### 2.2.1. 萤火虫算法

萤火虫算法(Firefly Algorithm)是一种模仿萤火虫之间信息交流及其吸引聚集行为的群优化算法。萤火虫算法的原理简单,且提出时间不长,国内外相应的应用研究已经有了一定的成果。根据先前文献中与其他群智能优化算法进行的分析与对比,能够得出萤火虫算法在局部搜索方面有较高的性能,并在精度和寻优速度上表现优秀[10] [11]。

为简单起见,可将算法规则理想化为以下三点:

- 1) 对所有萤火虫的性别不做区分。每只萤火虫都可以被其他任意一只萤火虫所吸引;
- 2) 萤火虫的亮度只与目标函数有关。为了求解亮度最优化问题,将亮度与目标函数的值成正比。在一些优化技术中,可以采用类似于适应度函数的方法来建立可选的亮度形式;
- 3) 萤火虫的吸引力只与萤火虫的亮度有关。较暗的萤火虫将会向较亮的萤火虫移动。另外相对亮度会随着萤火虫之间距离的增加而减弱。如果出现无法找到更亮萤火虫的情况,萤火虫就会在搜索空间内随机移动。

从数学角度来看,亮度  $I$  和吸引力  $\beta$  是两个极其重要的参数,两者都随距离  $r$  而变化。具体可由公式(1)和(2)给出:

$$I_r = I_0 \cdot e^{-\theta r^2} \quad (1)$$

$$\beta_r = \beta_0 \cdot e^{-\theta r^2} \quad (2)$$

$I_0$  和  $\beta_0$  分别为初始的亮度和距离为 0 时的吸引力,  $\theta$  为光的吸收系数,  $r$  为萤火虫之间的距离。

公式(1)和(2)上的距离  $r$  由(3)中表示的方程给出,表示两个萤火虫  $i$  和  $j$  之间的距离,即两点之间的空间距离。

$$r_{i,j} = \|x_i - x_j\| = \sqrt{\sum_{k=1}^d (x_{i,k} - x_{j,k})^2} \quad (3)$$

萤火虫在后面每个时刻的位置更新公式由下式(4)给出:

$$x_i^{t+1} = x_i^t + \beta_0 \cdot e^{-\theta r_{ij}^2} \cdot (x_j^t - x_i^t) + \alpha G_i \quad (4)$$

公式(4)中第一项表示萤火虫在迭代到  $t$  时的位置,第二项表示两个萤火虫之间由于其吸引力而产生的距离,最后一项表示萤火虫的随机扰动,有利于加大搜索区域,避免算法过早停滞。其中  $\alpha$  是扰动的步长因子且为 0 和 1 之间的常数,  $G_i$  为服从高斯分布的变化量。如果萤火虫的亮度一样,则萤火虫各自随机移动,通过萤火虫位置的不断更新,群体最终会聚集在亮度最高的萤火虫位置,实现目标寻优。但有时萤火虫会陷入局部最优,因此在全局搜索中表现不佳。此外,萤火虫算法的搜索完全依赖于随机运动,因此不能保证收敛性。

### 2.2.2. 基于 Circle 混沌映射的萤火虫种群初始化

种群初始化决定了初始种群的位置分布和适应度。在原有萤火虫算法中,由于没有任何先验条件可以使用,因此都是采用随机分布来进行种群初始化,这就有可能出现萤火虫个体分布不均匀的情况并最终导致陷入局部最优。混沌是由非线性系统发展而来,其通过确定性方程得到具有随机性的运动状态。具有遍历性、非周期性和对初始值的敏感性等特点,是目前一种有效的优化工具。在优化方面,混沌映射可以用于替代伪随机数生成器。因此针对上述问题本文采用 Circle 混沌映射来生成初始萤火虫群体,

Circle 映射的定义如下式所示:

$$x_{i+1} = \text{mod} \left( x_i + 0.2 - \frac{0.5}{2\pi} \cdot \sin(2\pi x_i), 1 \right) \quad (5)$$

在可行域中生成 Circle 混沌映射序列的流程如下:

- 1) 随机产生初值  $x_0$  并作为标记组,  $z_1 = x_0$ 。
- 2) 按式(5)迭代, 最终产生一个混沌序列。
- 3) 若达到最大迭代次数, 则转至步骤 5, 若跳出混沌周期则转至步骤 2。
- 4) 按式  $x_i = z_j + \eta$  重新生成迭代初值,  $i = j = 1$ ,  $\eta$  为服从正态分布的一个 0 到 1 范围内的常数,  $j = j + 1$ , 转至步骤 2。
- 5) 运行结束, 将最终的序列作为萤火虫的初始种群。

利用 Circle 映射产生初始种群, 相比于随机分布的萤火虫种群, 改进后的种群可以使初始位置的分布更加均匀, 扩大了萤火虫的搜索多样性, 提高了全局搜索能力, 避免早熟收敛, 有助于求取全局最优解, 并进一步提高了算法的寻优效率。

### 2.2.3. 非线性突变扰动

最优萤火虫个体的位置不断影响种群中其他个体的分布, 这种机制有助于 FA 最优解的求取。但当迭代次数较小时, 这种机制会导致 FA 快速进入局部搜索阶段, 无法找到最优解, 使算法陷入局部最优。因此, 本文对最优萤火虫个体加入非线性突变扰动, 使最优个体以一定的概率变化, 从而 FA 避免陷入局部最优。扰动因子  $N$  的表达式如式(6)所示。

$$N = (1 - t/t_{\max}) \tan \left[ (0.5 - \text{rand}(1)) \pi \right] \quad (6)$$

当前迭代次数和最大迭代次数分别用  $t$  和  $t_{\max}$  表示。 $\text{rand}(1)$  是取值范围为[0,1]的随机数。随机扰动的变化范围逐渐减小, 保证了 IFA 的局部搜索精度不受影响。改进后的 FA 基本算法流程如图 2 所示。

## 2.3. 参数的选择

对于统计预测方法来说, 准确且详细的历史发电量数据是保证光伏输出功率预测精度的必要条件。但是, 5G 光伏发电站的发电功率受组件自身特性、电池板安装角度、海拔以及天气的影响较大, 具有随机性和间断性等特点。过多的输入数据不仅会增加预测模型的训练时间, 而且随着数据的增加, 可能会导致预测精度下降, 因此很难在实际工程的应用中充分考虑所有的性能参数。本文采用灰色关联分析法分析气象因素对光伏功率预测影响程度, 其计算过程如下:

式(7)定义比较序列和参考序列之间的差值关联矩阵:

$$\Delta_i(k) = |s_j(k) - s_i(k)| \quad (i = 1, 2, \dots, m; k = 1, 2, \dots, n) \quad (7)$$

在表达式中:  $s_i(k)$  为第  $i$  个比较序列的第  $k$  个特征值,  $s_j(k)$  表示第  $j$  个参考序列的第  $k$  个特征值 ( $k = 1, 2, \dots, m$ )。  $m$  为特征向量的维数,  $n$  为样本个数

第  $i$  个参考序列与比较序列的相关系数  $\gamma_{ij}(k)$  如下式(8)所示:

$$\gamma_{ij}(k) = \frac{\min \Delta_i(k) + \delta \max \Delta_i(k)}{\Delta_i(k) + \delta \max \Delta_i(k)} \quad (8)$$

其中  $\min \Delta_i(k)$  和  $\max \Delta_i(k)$  是两个序列之差的最小值和最大值,  $\delta$  为分辨系数(在本文中  $\delta = 0.5$ )。

最后第  $i$  个比较序列与参考序列的灰色关联度  $r_i$  如式(9)所示

$$r_i = \frac{1}{n} \sum_{k=1}^n \gamma_{ij}(k) \quad (9)$$

选取广西大学 5G 光伏基站的两组分别为晴天和多云天气的历史发电数据。比较序列为辐射强度、风速、大气温度和相对湿度四种数据类型，参考序列是实际光伏输出功率。结果如表 1 所示。

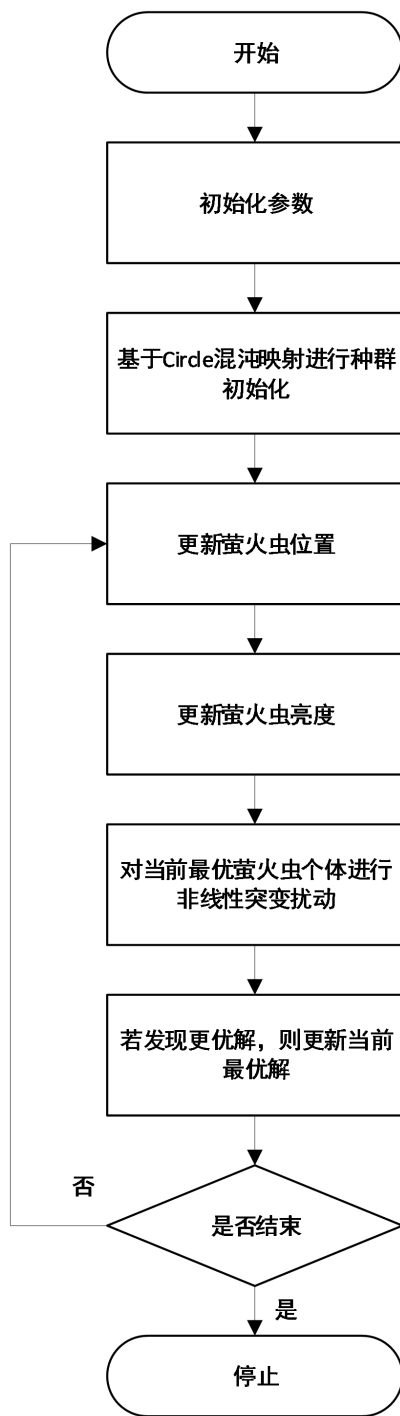


Figure 2. Improve firefly algorithm flow  
图 2. 改进萤火虫算法流程



**Table 1.** The degree of grey correlation of individual factors**表 1.** 各个因素的灰色关联度

历史发电数据	数据类型	灰色关联度
晴天	辐照强度	0.9275
	温度	0.5675
	相对湿度	0.3527
	风速	0.5874
多云	辐照强度	0.9524
	温度	0.5852
	相对湿度	0.3668
	风速	0.635

由表 1 可知, 两组辐照强度的灰色关联度均在 0.9 以上, 说明辐照强度与光伏输出功率相关性最强。两组数据中相对湿度的灰色关联度都在 0.35 左右, 说明相对湿度与光伏输出功率的关联度最低。温度与风速的灰色关联度相对较低, 但也达到了一定的相关性。因此, 预测模型的输入变量确定为辐照强度、风速和大气温度。

#### 2.4. IFA-BP 光伏功率预测模型

改进的萤火虫算法以其独特的优点, 可通过萤火虫的亮度和吸引力来更新位置并一步一步地向全局最优值移动, 并在最优值附近快速收敛。在该模型中, IFA 主要优化 BP 神经网络中的连接权值和阈值, 并在得到参数最优值的条件下赋值给 BP 神经网络, 对光伏功率进行短期预测。在训练前, 导入光伏功率预测的训练集和测试集样本, 选择 sigmoid 函数作为激活函数。训练后, 将测试集的实际数据与预测的光伏功率数据进行比较。利用 IFA-BP 模型预测光伏输出功率的具体流程图如图 3 所示。

### 3. 仿真与结果分析

#### 3.1. FA 与 IFA 性能对比

为了将提出的 IFA 算法与基本 FA 算法的性能进行比较, 本文选择了 4 个标准测试函数进行仿真实验。标准测试函数具体如表 2 所示。

算法设置参数情况如下:  $d = 8$ , 萤火虫个数  $n = 20$ , 最大迭代数  $M = 10,000$ , 步长  $\alpha = 0.2$ , 最大吸引度  $\beta_0 = 1$ , 光吸收强度  $\gamma = 1$ 。为了避免偶然性带来的误差, 保证实验结果的可信度, 每一个算法将为每个测试函数独立运行 50 次, 对获得的平均最优值和寻优成功率进行比较, 具体结果如表 3 所示。

由表 3 结果显示, 对于测试函数  $f_1 \sim f_4$ , IFA 算法均能找到最优解, 并且成功率均高于 FA, 尤其表现在  $f_2$  和  $f_3$  上较为明显。这说明改进方法可以快速收敛且能有效提高 FA 逃离局部最优解的性能。在相同条件下, IFA 的优化精度和稳定性都是最好的且本文所采取的改进措施是合理有效的。

#### 3.2. IFA-BP 模型仿真结果

本文基于 2021 年广西大学西校园的基站运行数据, 在 Matlab 软件中验证了 IFA-BP 模型的预测性能。数据选取的是天气条件复杂的 10 月和 12 月, 10 月 15 日是晴天, 12 月 17 日是雨天。训练数据从预测日期前一周的历史数据中选取, 分别为 10 月 8~14 日和 12 月 10~16 日。研究时间为每天 8:00~17:00, 间隔为 1 小时。改进萤火虫算法的最大迭代次数为 200 次, 其他参数都采用默认值。预测模型的输入为辐照强度、风速和大气温度, 预测模型的输出为光伏输出功率。以平均百分比误差(MAPE)和决定系数( $R^2$ )为评价指标, 其中  $X_r$  为实际值,  $X_p$  为预测值,  $s$  为光伏发电采样点数。

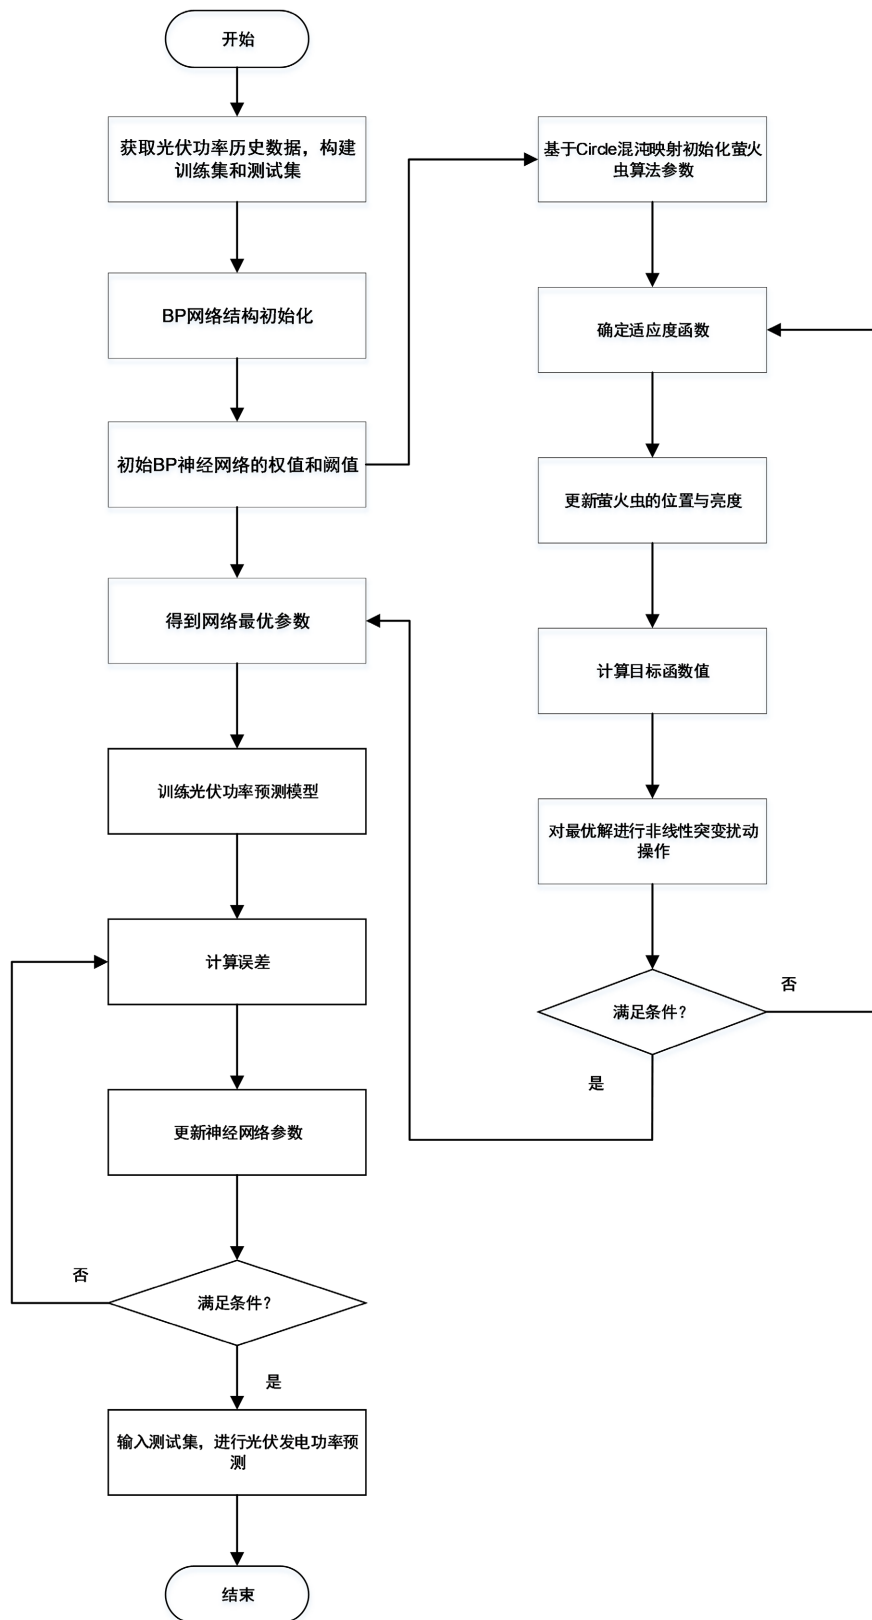


Figure 3. The forecasting process of the IFA-BP model  
图 3. IFA-BP 模型的预测流程



**Table 2.** Four Benchmark functions  
**表 2.** 4 个标准测试函数

函数名	表达式	搜索范围	最优值
Sphere	$f_1(x) = \sum_{i=1}^d x_i^2$	[-100, 100]	0
Rosenbrock	$f_2(x) = \sum_{i=1}^{d-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	[-30, 30]	0
Rastrigin	$f_3(x) = \sum_{i=1}^d [x_i^2 - 10 \cos(2\pi x_i) + 10]$	[-5.12, 5.12]	0
Griedwank	$f_4(x) = \frac{1}{4000} \sum_{i=1}^d x_i^2 - \prod_{i=1}^d \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	[-100, 100]	0

**Table 3.** Simulation result of the four Benchmark functions  
**表 3.** 4 个标准测试函数的仿真结果

函数名	算法	最差值	最优值	平均值	成功率
F1: Sphere	FA	5.6242e-10	0	8.2836e-11	60%
	IFA	0	0	0	100%
F2: Rosenbrock	FA	6.2348	3.5562e-04	1.7290	0%
	IFA	0	0.0027	1.7525e-04	60%
F3: Rastrigin	FA	20.8941	3.9798	10.1287	0%
	IFA	0	0	0	100%
F4: Griedwank	FA	0.0017	0	1.2347e-04	26%
	IFA	0	0	0	100%

$$R^2 = 1 - \frac{\sum_{i=1}^s [X_p(i) - X_r(i)]^2}{\sum_{i=1}^s [X_p(i) - \overline{X_p(i)}]^2} \quad (10)$$

$$MAPE = \sum_{i=1}^s \left| \frac{X_r(i) - X_p(i)}{X_r(i)} \right| \times \frac{100}{s} \quad (11)$$

本文使用了 3 个模型来评估光伏输出功率预测的有效性, 分别是 BP 模型、FA-BP 模型和 IFA-BP 模型。

图 4 显示了各模型晴天的预测结果与实际值的对比, 而图 5 为 3 种预测模型之间绝对误差的对比。其中绝对误差(AE)定义为

$$\Delta X = X_r - X_p \quad (12)$$

可以发现, 在晴天的光伏输出功率在 12~14 时左右达到峰值, 曲线总体趋势稳定, 规律性强。这是由于在晴天条件下, 各种气象因素变化平稳, 光伏输出功率随着光强和大气温度的变化缓慢。在初始预测阶段(8:00~11:00), FA-BP 模型的预测曲线拟合效果较差。在中期(12:00~14:00), BP 模型与实际输出功率曲线相比误差最大。在预测后期(15:00~17:00), BP 模型和 FA-BP 模型的预测效果均比较差。另一方面, IFA-BP 模型在整个预测期间都表现出良好的拟合效果, 而且绝对误差值也最低, 在[-0.5, 0.4]之间, 尤其在中期预测较为准确。




Figure 4. Prediction results on sunny days  
图 4. 晴天预测结果

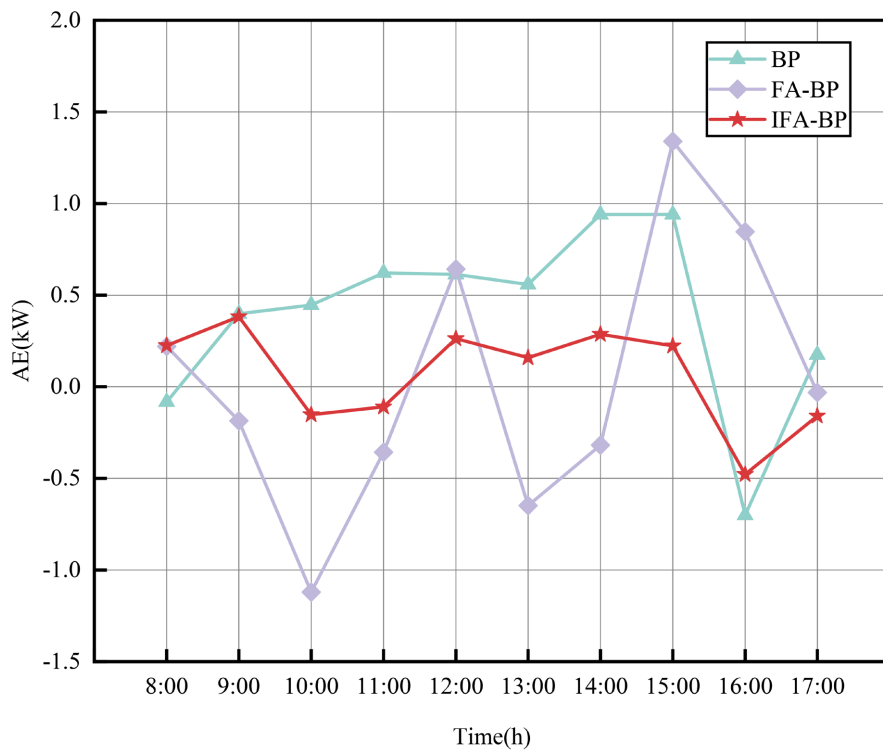


Figure 5. Absolute error on sunny days  
图 5. 晴天绝对误差

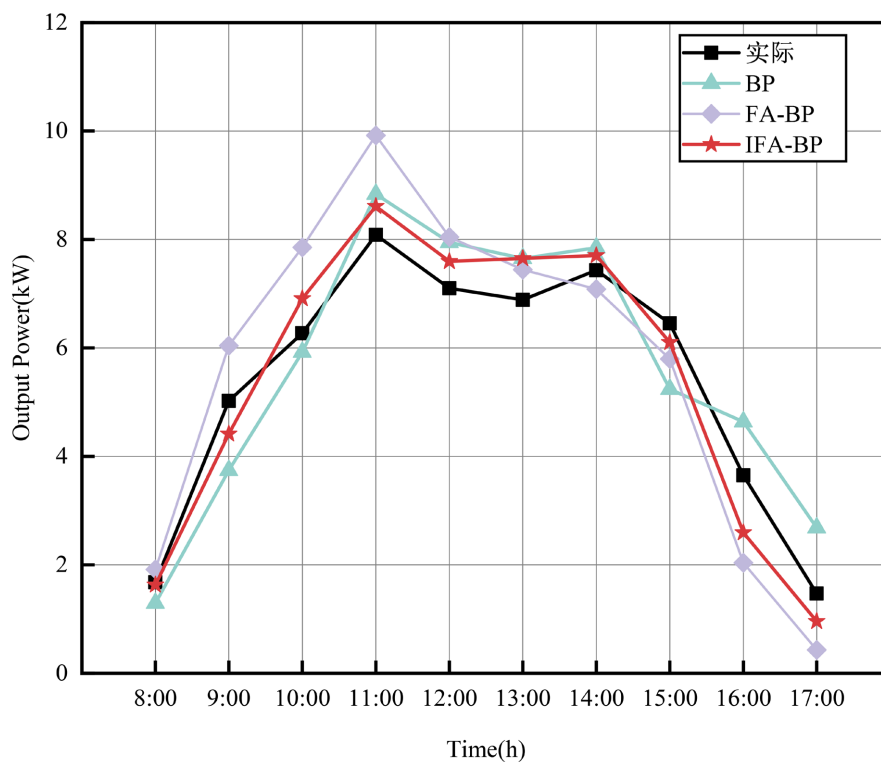


Figure 6. Prediction results for cloudy days

图 6. 多云预测结果




Figure 7. Absolute error on cloudy days

图 7. 多云天气绝对误差

图 6 和图 7 为采用 3 种预测模型进行多云条件下光伏输出功率预测的仿真结果。从图 6 可以看出，多云时光伏输出功率曲线波动较大，规律性较弱。而且，输出功率与时间之间没有明显的线性关系。这是由于多云条件下各种外部因素的剧烈变化使得光强、风速和大气温度在短时间内变化明显，从而导致基站光伏发电系统不够稳定。多云天气的 AE 如图 7 所示。在预测初始阶段，FA-BP 模型的误差较大。在预测中期和后期 BP 模型的波动较大，最大误差也已经将要达到 1.8 kW。但是 IFA-BP 的误差在[-1, 0.75] 之间，是三种预测模型中误差最小的。

最终结果表明，多云天气的预报误差相对于晴天的预报误差较大。与其他三种模型相比，IFA-BP 模型的预测误差最小，并证明了在不同天气条件下都可以显示出较为理想的预测效果。表 4 为本文仿真使用 MAPE 和  $R^2$  的评价结果。

**Table 4.** Evaluation of three predictive models

**表 4.** 三种预测模型评估

天气	预测模型	MAPE	$R^2$
晴天	BP	7.8073	0.9655
	FA-BP	7.9432	0.9797
	IFA-BP	4.8230	0.9945
多云	BP	22.0366	0.9313
	FA-BP	23.3664	0.9510
	IFA-BP	12.2488	0.9853

如表 4 所示，每个模型晴天时的预测结果都明显优于阴天时的预测结果。例如，IFA-BP 的 MAPE 值在晴天为 4.8230，在阴天为 12.2488。此外，无论是在晴天还是多云天气，IFA-BP 模型的 MAPE 值都是最低的。晴天各模型的  $R^2$  均达到 95% 以上；然而，在多云天气下，各模型的  $R^2$  相对于晴天较低。在所有模型中，只有 IFA-BP 模型在晴天和阴天都达到了 98% 以上。综上所述，本文提出的 IFA-BP 光伏功率预测模型无论在晴天还是多云天气都能达到理想的预测性能，也能达到较好的预测精度。仿真结果表明，IFA-BP 模型具有较好的预测精度和抗干扰能力，同时也证明了本文提出的预测模型是有效的。

## 4. 结论

本文提出一种基于改进萤火虫算法优化 BP 神经网络的 5G 基站光伏功率预测方法，此方法利用改进萤火虫算法来优化 BP 神经网络的参数，可改善 BP 神经网络易陷入局部最优和收敛速度慢等问题，有效提高了 5G 基站光伏发电系统的预测精度。通过 MATLAB 仿真分析可知，IFA-BP 预测模型在晴天和多云天气条件下的 MAPE 均低于其他两种预测模型， $R^2$  均高于其他两种预测模型且达到 98% 以上，这说明该预测模型在一定程度上提高了预测精度，使得 5G 基站光伏供电系统运行更加可靠，并为调度人员的决策提供了参考。另外此预测方法在多云时预测精度有所下降，因此后续研究应考虑云层对光伏功率影响的情况，提高对不同天气条件的敏感度，以进一步提高模型光伏功率预测精度。

## 基金项目

资助项目：2020 年度南宁市创新创业领军人才(团队)“邕江计划”项目(编号：2020006)。

## 参考文献

- [1] 陈文伟, 朱玉坤, 张宁池, 王艳茹. 面向能源互联网的 5G 关键技术及应用场景研究[J]. 电力信息与通信技术, 2021(8): 83-90.

- 
- [2] 闫明, 郭文豪, 胡永乐, 覃团发. 基于 5G 的配电网智能故障诊断方法[J/OL]. 电测与仪表, 2021. <http://kns.cnki.net/kcms/detail/23.1202.TH.20210319.1036.006.html>, 2022-03-25.
- [3] 郭虎, 刘文颖, 张鹏, 陈钊. 基于 MEA-小波 Elman 神经网络的光伏超短期预测方法[J]. 智能电网, 2017, 7(4): 260-267. <https://doi.org/10.12677/SG.2017.74029>
- [4] 龚莺飞, 鲁宗相, 乔颖, 王强. 光伏功率预测技术[J]. 电力系统自动化, 2016, 40(4): 140-151.
- [5] 文明, 李刚强, 江辉, 彭建春. 光伏电站输出功率的主因隐藏型 RBFNN 预测方法[J]. 智能电网, 2016, 6(4): 212-220. <http://dx.doi.org/10.12677/SG.2016.64024>
- [6] 韩丽洁. 基于灰色关联分析和最小二乘支持向量机的光伏功率预测算法的研究[D]: [硕士学位论文]. 天津: 天津大学, 2014.
- [7] 高正. 基于改进神经网络的光伏发电功率短期预测研究[D]: [硕士学位论文]. 长春: 长春工业大学, 2019.
- [8] 马海志. BP 神经网络的改进研究及应用[D]: [硕士学位论文]. 哈尔滨: 东北农业大学, 2015.
- [9] 张洁, 郝倩男. 基于烟花算法优化 BP 神经网络的光伏功率预测[J]. 计算机技术与发展, 2021(10): 146-153.
- [10] 张大力, 夏红伟, 张朝兴, 马广程, 王常虹. 改进萤火虫算法及其收敛性分析[J]. 系统工程与电子技术, 2022, 44(4): 1291-1300.
- [11] 孙爱晶, 郑世鹏. 基于混沌优化萤火虫算法的 WSN 分簇算法[J]. 传感技术学报, 2021(9): 1224-1230.