



(12) 发明专利申请

(10) 申请公布号 CN 112149883 A

(43) 申请公布日 2020.12.29

(21) 申请号 202010927605.0

(22) 申请日 2020.09.07

(71) 申请人 南京邮电大学

地址 210023 江苏省南京市栖霞区仙林街
道文苑路9号

(72) 发明人 张洁 郝倩男

(74) 专利代理机构 南京苏科专利代理有限责任
公司 32102

代理人 姚姣阳

(51) Int. Cl.

G06Q 10/04 (2012.01)

G06N 3/04 (2006.01)

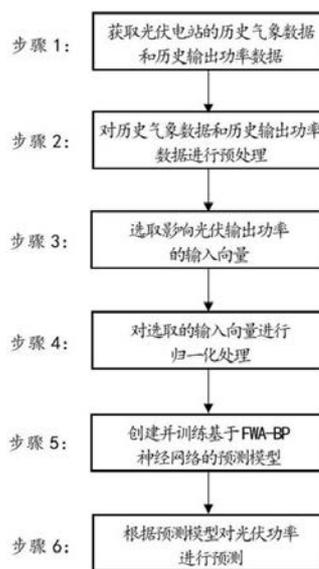
权利要求书2页 说明书7页 附图4页

(54) 发明名称

基于FWA-BP神经网络的光伏功率预测方法

(57) 摘要

本发明公开了一种基于FWA-BP神经网络的光伏功率预测方法,属于光伏发电技术领域。光伏发电功率的随机性和间接性会对大规模光伏并网造成一定的影响,因此本发明提出了一种基于FWA-BP神经网络的光伏功率预测方法,利用烟花算法(FWA)优化BP神经网络的权值和阈值,避免BP神经网络陷入局部最优,加快BP神经网络的收敛速度,同时通过数据预处理提高模型预测精度,能够实现对光伏功率高精度的预测。



1. 一种基于FWA-BP神经网络的光伏功率预测方法,其特征在于,包括以下步骤:

步骤1、获取光伏电站的历史气象数据和历史输出功率数据;

步骤2、对所述历史气象数据和所述历史输出功率数据进行预处理;

步骤3、从所述历史气象数据中选取影响光伏功率短期预测的数据作为输入向量;

步骤4、对所述输入向量进行归一化处理;

步骤5、运用烟花算法(FWA)优化后的BP神经网络进行离线训练,创建基于FWA-BP神经网络的预测模型;

步骤6、根据所述预测模型对光伏发电功率进行预测。

2. 根据权利要求1所述的基于FWA-BP神经网络的光伏功率预测方法,其特征在于:步骤1具体为获取对光伏输出功率有影响的历史气象数据和历史输出功率数据并形成数据集,所述历史气象数据包括辐照度、温度、湿度及风速。

3. 根据权利要求1所述的基于FWA-BP神经网络的光伏功率预测方法,其特征在于:步骤2中的预处理包括对异常数据的检测和对异常值的填补,所述异常数据的检测采用 3σ 原则,所述异常值的填补采用K近邻法,所述K近邻法的计算公式为:

$$X_i = \frac{x_{i-k} + \dots + x_{i-1} + x_{i+1} + \dots + x_{i+k}}{2k}$$

其中, x_{i-k} 是异常值前面的第k个数据, x_{i+k} 是异常值后面的第k个数据。

4. 根据权利要求1所述的基于FWA-BP神经网络的光伏功率预测方法,其特征在于:步骤3中采用Pearson相似度分析法,计算得出所述历史气象数据和所述历史输出功率数据的相关系数,选取相关系数最高的两个值作为输入向量,所述Pearson相似度分析法的计算公式为:

$$r = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^N (Y_i - \bar{Y})^2}}$$

其中, X 、 Y 分别为所述历史气象数据和所述历史输出功率。

5. 根据权利要求1所述的基于FWA-BP神经网络的光伏功率预测方法,其特征在于:步骤4中的归一化处理将所述输入向量归一至 $[0,1]$ 区间内,所述归一化处理计算公式为:

$$x^* = \frac{x - \min}{\max - \min}$$

其中, \max 为所述输入向量中数据的最大值, \min 为所述输入向量中数据的最小值, x 为当前点的数值, x^* 为归一化转换计算后的数值。

6. 根据权利要求2所述的基于FWA-BP神经网络的光伏功率预测方法,其特征在于:步骤5具体是将所述训练集中的辐照度、温度及历史发电功率作为输入量,发电功率作为输出量,利用烟花算法对BP神经网络模型的权值和阈值进行寻优,更新BP神经网络的权值和阈值,得到基于FWA-BP神经网络的预测模型。

7. 根据权利要求6所述的基于FWA-BP神经网络的光伏功率预测方法,其特征在于,基于BP神经网络的权值和阈值的寻优步骤具体为:

a、初始化种群位置,设置烟花爆炸火花个数上限及下限;

b、计算每一个烟花个体的适应度值,并根据公式

$$S_i = M_\varepsilon \times \frac{y_{\max} - f(x_i) + \varepsilon}{\sum_{i=1}^N (y_{\max} - f(x_i) + \varepsilon)} \quad \text{和} \quad A_i = \hat{A} \times \frac{f(x_i) - y_{\min} + \varepsilon}{\sum_{i=1}^N f(x_i) - y_{\min} + \varepsilon}$$

计算每个烟花爆炸产生的烟花个数和爆炸半径;

其中, y_{\max} 和 y_{\min} 分别为当前种群中适应度最大、最小值, \hat{A} 是用来调整爆炸半径大小的常数, M_ε 是用来调整爆炸产生的烟花数量的常数, ε 是一个机器最小量, 用来避免除零操作;

c、进行爆炸差异操作, 根据公式 $e_{x_{ik}} = x_{ik} + h$ 和 $m_{x_{ik}} = x_{ik} \times e$ 生成烟花个体的火花及经过高斯变异后的高斯变异火花, 位置偏移量由公式 $h = A_i \times \text{rand}(1, -1)$ 计算得到, 其中, h 为位置偏移量, x_{ik} 为种群中第 i 个烟花个体的第 k 维, $e_{x_{ik}}$ 为第 i 个烟花个体爆炸后的火花, $m_{x_{ik}}$ 为 x_{ik} 经过高斯变异后的高斯变异火花, e 为服从均值为 1、方差为 1 的高斯分布的随机数;

d、从烟花、爆炸火花及高斯变异火花种群中选择 N 个烟花个体形成候选种群;

e、判断是否满足终止条件, 若是, 则执行下一步, 否则跳转至 b;

f、输出全局最优个体和适应值, 算法结束;

g、将得到的最优权值和阈值带入 BP 神经网络中进行训练, 得到最优预测模型。

8. 根据权利要求 7 所述的基于 FWA-BP 神经网络的光伏功率预测方法, 其特征在于, 步骤 d 中候选种群的选择方法为: 选择适应度值最小的 $\min(f(x_i))$ 个体 x_k 直接为下一代烟花种群个体, 其余的 $N-1$ 个烟花个体采取轮盘赌方式。

9. 根据权利要求 6 所述的基于 FWA-BP 神经网络的光伏功率预测方法, 其特征在于: BP 神经网络权值和阈值的更新公式为:

$$\omega_{ij} = \omega_{ij} + \eta H_j (1 - H_j) x_i \sum_{k=1}^m \omega_{jk} e_k, \quad i = 1, 2, \dots, n; \quad j = 1, 2, \dots, l$$

$$\omega_{jk} = \omega_{jk} + \eta H_j e_k, \quad j = 1, 2, \dots, l; \quad k = 1, 2, \dots, m$$

$$a_j = a_j + \eta H_j (1 - H_j) x_i \sum_{k=1}^m \omega_{jk} e_k, \quad j = 1, 2, \dots, l$$

$$b_k = b_k + \eta e_k, \quad k = 1, 2, \dots, m$$

其中, ω_{ij} 、 a 为输入层和隐含层间的连接权值和隐含层阈值, ω_{jk} 、 b 为隐含层和输出层之间的连接权值和阈值, H_j 为隐含层输出, η 为学习率。

10. 根据权利要求 2 所述的基于 FWA-BP 神经网络的光伏功率预测方法, 其特征在于, 所述步骤 6 具体为: 在步骤 5 中训练结束后, 保存模型文件, 对所述测试集中的数据进行测试, 并通过公式 $e_k = Y_k - O_k$, $k = 1, 2, \dots, m$ 进行误差检查, 对模型进行反复验证和优化。

基于FWA-BP神经网络的光伏功率预测方法

技术领域

[0001] 本发明涉及一种基于FWA-BP神经网络的光伏功率预测方法,属于功率预测领域。

背景技术

[0002] 随着传统能源消耗的快速增长和气候环境的不断恶化,近年来光伏发电技术得到了迅速发展。然而受气象条件的影响,光伏发电功率的随机性和间接性会对大规模光伏并网造成一定地影响。为了保证光伏电站地稳定运行和电网地安全调度,准确及时地进行光伏功率预测具有非常重要地意义。

[0003] 现有光伏功率预测方法主要包括物理法和统计法。物理法需要气象数据、光伏电站所处地理信息以及光伏组件地参数,根据输出特性曲线计算得到光伏发电量,其预测准确性取决于待测对象的结构和选用参数的精度,但该方法涉及环节多,过程较为复杂;统计法则是通过对历史数据进行统计分析,发现其内在规律。

[0004] BP神经网络是一种基于误差反向传播的多层前馈神经网络,具有较强地鲁棒性,能对非线性进行无限地逼近且学习能力强,在光伏发电功率预测领域有着广泛应用。然而BP神经网络也有着易陷入局部极小值、收敛速度慢、存在过拟合的现象,同时BP神经网络模型误差较大,预测精度不高,该领域技术人员多次对其进行优化,仍难以达到理想的预测状态。

[0005] 传统BP神经网络在模型训练的过程中,容易使神经网络中的网络参数陷入局部最优,当陷入局部最优后,网络参数就会停止变化,即使继续对神经网络进行训练,训练集上的误差也不再减小。

[0006] 有鉴于此,需要对现有的BP神经网络进行改进,以解决上述问题。

发明内容

[0007] 本发明的目的在于提供一种基于FWA-BP神经网络的光伏功率预测方法,该方法可提高对光伏发电功率预测的精度。

[0008] 为实现上述目的,本发明提供如下技术方案:

[0009] 基于FWA-BP神经网络的光伏功率预测方法,主要包括以下步骤:

[0010] S1:获取光伏电站的历史气象数据和历史输出功率数据;

[0011] S2:对历史气象数据和历史输出功率数据进行预处理;

[0012] S3:从历史气象数据中选取影响光伏功率短期预测的数据作为输入向量;

[0013] S4:对输入向量进行归一化处理;

[0014] S5:运用烟花算法(FWA)优化后的BP神经网络进行离线训练,创建基于FWA-BP神经网络的预测模型;

[0015] S6:根据预测模型对光伏发电功率进行预测。

[0016] 作为本发明的进一步改进,步骤S1具体为获取对光伏输出功率有影响的历史气象数据和历史输出功率数据并形成数据集,历史气象数据包括辐照度、温度、湿度及风速,数

据集中选取80%的数据作为训练集,选取20%的数据作为测试集。

[0017] 作为本发明的进一步改进,步骤S2具体为对异常数据的检测和对异常值的填补,异常数据的检测采用 3σ 原则,异常值的填补采用K近邻法,K值近邻法算法公式为:

$$[0018] \quad X_i = \frac{x_{i-k} + \dots + x_{i-1} + x_{i+1} + \dots + x_{i+k}}{2k}$$

[0019] 式中, X_{i-k} 是异常值前面的第k个数据, X_{i+k} 是异常值后面的第k个数据。

[0020] 作为本发明的进一步改进,步骤S3具体为采用Pearson相似度分析法计算得出历史气象数据和历史输出功率的相关系数,选取相关系数最高的两个值作为输入向量,Pearson相似度分析法的计算公式为:

$$[0021] \quad r = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^N (Y_i - \bar{Y})^2}}$$

[0022] 其中,X、Y分别为历史气象数据和历史输出功率。

[0023] 作为本发明的进一步改进,步骤S4具体为归一化处理将输入向量归一至[0,1]区间内,计算公式为:

$$[0024] \quad x^* = \frac{x - \min}{\max - \min}$$

[0025] 其中,max为所述输入向量中数据的最大值,min为所输入向量中数据的最小值,x为当前点的数值,x*为归一化转换计算后的数值。

[0026] 作为本发明的进一步改进,步骤S5具体是将训练集中的辐照度、温度、历史发电功率(包括但不限于辐照度、温度两个影响因子)作为输入量,发电功率(包括但不限于发电功率)作为输出量,利用烟花算法对BP神经网络模型的权值和阈值进行寻优,更新BP神经网络的权值和阈值,得到基于FWA-BP神经网络的预测模型。

[0027] 作为本发明的进一步改进,所述基于FWA-BP神经网络的权值和阈值的寻优步骤具体为:

[0028] a、初始化种群位置,设置烟花爆炸火花个数上限及下限;

[0029] b、计算每一个烟花个体的适应度值,并根据公式:

$$[0030] \quad S_i = M_e \times \frac{y_{\max} - f(x_i) + \varepsilon}{\sum_{i=1}^N (y_{\max} - f(x_i) + \varepsilon)} \quad \text{和} \quad A_i = \hat{A} \times \frac{f(x_i) - y_{\min} + \varepsilon}{\sum_{i=1}^N f(x_i) - y_{\min} + \varepsilon}$$

[0031] 计算每个烟花爆炸产生的烟花个数和爆炸半径;

[0032] 其中, y_{\max} 和 y_{\min} 分别为当前种群中适应度最大、最小值, \hat{A} 是用来调整爆炸半径大小的常数, M_e 也是一个常数,用来调整爆炸产生的烟花数量, ε 是一个机器最小量,用来避免除零操作。

[0033] c、进行爆炸差异操作,根据公式 $e_{X_{ik}} = x_{ik} + h$ 和 $m_{X_{ik}} = x_{ik} \times e$ 生成烟花个体的火花及经过高斯变异后的高斯变异火花,位置偏移量由公式 $h = A_i \times \text{rand}(1, -1)$ 计算得到;其中,h为位置偏移量, x_{ik} 为种群中的第i个烟花个体的第k维, $e_{X_{ik}}$ 为第i个烟花个体爆炸后的火

花, $m_{x_{ik}}$ 为 x_{ik} 经过高斯变异后的高斯变异火花, e 为服从均值为1、方差为1的高斯分布的随机数;

[0034] d、从烟花、爆炸火花及高斯变异火花种群中选择N个烟花个体形成候选种群;

[0035] e、判断是否满足终止条件,若是,则执行下一步,否则跳转至b;

[0036] f、输出全局最优个体和适应值,算法结束;

[0037] g、将得到的最优权值和阈值带入BP神经网络中进行训练,得到最优预测模型。

[0038] 作为本发明的进一步改进,所述步骤d中候选种群的选择方法为:选择适应度值最小的 $\min(f(x_i))$ 个体 x_k 直接为下一代烟花种群个体,其余的N-1个烟花个体采取轮盘赌方式。

[0039] 作为本发明的进一步改进,步骤S5中BP神经网络权值和阈值的更新公式具体为:

$$[0040] \quad \omega_{ij} = \omega_{ij} + \eta H_j (1 - H_j) x_i \sum_{k=1}^m \omega_{jk} e_k, i = 1, 2, \dots, n; j = 1, 2, \dots, l$$

$$[0041] \quad \omega_{jk} = \omega_{jk} + \eta H_j e_k, j = 1, 2, \dots, l; k = 1, 2, \dots, m$$

$$[0042] \quad a_j = a_j + \eta H_j (1 - H_j) x_i \sum_{k=1}^m \omega_{jk} e_k, j = 1, 2, \dots, l$$

$$[0043] \quad b_k = b_k + \eta e_k, k = 1, 2, \dots, m$$

[0044] 其中, ω_{ij} 、 a 为输入层和隐含层间的连接权值和隐含层阈值, ω_{jk} 、 b 为隐含层和输出层之间的连接权值和阈值, H_j 为隐含层输出, η 为学习率。

[0045] 作为本发明的进一步改进,步骤S6具体为训练结束后,保存模型文件,对所述测试集中的数据进行测试,并通过公式 $e_k = Y_k - O_k, k = 1, 2, \dots, m$ 进行误差检查,对模型进行反复验证和优化。

[0046] 本发明的有益效果是:本发明在对各种影响因素与光伏发电功率的相关系数进行比较后,选取合适的模型输入,并对样本数据进行预处理,采用FWA-BP神经网络建立预测模型,从而实现光伏电站的短期功率预测,解决了传统BP神经网络易陷入局部最优和收敛速度慢的问题,能够实现高精度的预测。

附图说明

[0047] 图1是本发明的整体流程图;

[0048] 图2是步骤5的预测流程图;

[0049] 图3是BP神经网络拓扑结构图;

[0050] 图4是不同算法功率预测结果对比图。

具体实施方式

[0051] 为了使本发明的目的、技术方案和优点更加清楚,下面结合附图和具体实施例对本发明进行详细描述。

[0052] 本发明提供了一种基于FWA-BP神经网络的光伏功率预测方法,通过与BP神经网络模型、GA-BP神经网络模型对比,本发明的预测方法较现有技术具有精度高、收敛速度快、不易陷入局部最小值的优点。如图1所示,该FWA-BP神经网络的光伏功率预测方法具体包括:

[0053] 步骤1:获取光伏电站的历史气象数据和历史输出功率数据;

[0054] 截取2018年全年的数据,采集一天中8:00—17:00每15min的辐照度、温度、湿度、风速以及所对应的光伏电站每15min的历史发电功率作为数据集。选取数据集中前80%的数据作为训练集,用来对预测模型进行训练,选取数据集中后20%的数据作为测试集,用来对模型进行测试和验证。

[0055] 步骤2:对历史气象数据和历史输出功率数据进行预处理;

[0056] 预处理包括对异常数据的检测和对异常值的填补,异常数据的检测采用 3σ 原则,异常值的填补采用K近邻法,K近邻法的计算公式为:

$$[0057] \quad X_i = \frac{x_{i-k} + \dots + x_{i-1} + x_{i+1} + \dots + x_{i+k}}{2k}$$

[0058] 式中, X_{i-k} 是异常值前面的第k个数据, X_{i+k} 是异常值后面的第k个数据。

[0059] 步骤3:从历史气象数据中选取影响光伏功率短期预测的数据作为输入向量;

[0060] 使用Pearson相似度分析法可计算得出历史气象数据和历史输出功率数据的相关系数,选取相关系数最高的两个值作为输入向量,所述Pearson相似度分析法的计算公式为:

$$[0061] \quad r = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^N (Y_i - \bar{Y})^2}}$$

[0062] 其中,X、Y分别为所述历史气象数据的一项和所述历史输出功率,r为相关系数。

[0063] 步骤4:对输入向量进行归一化处理;

[0064] 归一化处理将输入向量归一至[0,1]区间内,计算公式为:

$$[0065] \quad x^* = \frac{x - \min}{\max - \min}$$

[0066] 其中,max为所述输入向量中数据的最大值,min为所输入向量中数据的最小值,x为当前点的数值,x*为归一化转换计算后的数值。

[0067] 步骤5:运用烟花算法(FWA)优化后的BP神经网络进行离线训练,创建基于FWA-BP神经网络的预测模型;

[0068] 如图2所示,该步骤5具体包括以下步骤:

[0069] 1、确定BP网络的拓扑结构;预测模型的输入量包括预测日前两天的辐照度、温度、历史光伏功率和预测日当天的辐照度、温度;预测日光伏功率作为输出量,所以BP神经网络模型的输入层节点数为8、输出层节点数为1,隐含层节点数由公式 $s = \sqrt{m + n} + a$ (m和n分别代表神经网络的输入层节点数和输出层节点数,a为0-10之间的常数)确定范围,经反复测试,将隐含节点数设为4个。BP神经网络模型的拓扑结构为8-4-1,如图3所示。

[0070] 2、设置所述神经网络模型的激活函数;在神经网络的预测模型中,输入层、输出层的激活函数都采用sigmoid函数,神经网络的训练主要采用梯度下降法。

[0071] 3、烟花算法优化BP神经网络的初始权值和阈值,具体步骤如下:

[0072] a、初始化种群位置,设置烟花爆炸火花个数上限及下限。种群大小决定了火花的多样性,种群越大,火花种类越多,但运行时间也会越长,种群大小一般选5。火花上下限用于限制火花数量,使每一个火花都能爆炸出新的火花数,其取值与火花调节常数有关。

[0073] b、计算每一个烟花个体的适应度值,并根据公式:

$$[0074] \quad S_i = M_\varepsilon \times \frac{y_{\max} - f(x_i) + \varepsilon}{\sum_{i=1}^N (y_{\max} - f(x_i) + \varepsilon)} \quad \text{和} \quad A_i = \hat{A} \times \frac{f(x_i) - y_{\min} + \varepsilon}{\sum_{i=1}^N f(x_i) - y_{\min} + \varepsilon}$$

[0075] 计算每个烟花爆炸产生的烟花个数和爆炸半径。 \hat{A} 是用来调整爆炸半径大小的常数,半径调节参数决定了火花爆炸的范围和震动幅度,半径调节常数越大则全局探索能力越强,但局部搜索能力会减弱,一般取20。 M_ε 用来调整爆炸产生的烟花数量,火花数决定了爆炸新生的火花个数,个数越多,找到最优解可能性越大,但需要的时间也越长,为了减少运行时间,所以火花数取值较小。

[0076] c、进行爆炸差异操作,根据公式 $e_{x_{ik}} = x_{ik} + h$ 和 $m_{x_{ik}} = x_{ik} \times e$ 生成烟花个体的火花及经过高斯变异后的高斯变异火花,位置偏移量计算公式为 $h = A_i \times \text{rand}(1, -1)$;

[0077] 其中, h 为位置偏移量, x_{ik} 为种群中的第*i*个烟花个体的第*k*维, $e_{x_{ik}}$ 为第*i*个烟花个体爆炸后的火花, $m_{x_{ik}}$ 为 x_{ik} 经过高斯变异后的高斯变异火花,其中 e 为服从均值为1、方差为1的高斯分布的随机数,则有 $e \sim N(1, 1)$ 。找到 $e_{x_{ik}}$ 和 $m_{x_{ik}}$ 的最优位置即为神经网络权值的最优参数。变异火花数主要用于增强全局探索能力。

[0078] d、从烟花、爆炸火花及高斯变异火花种群中选择*N*个烟花个体形成候选种群。选择方法如下:选择适应度值最小的 $\min(f(x_i))$ 个体 x_k 直接为下一代烟花种群个体,其余的*N*-1个烟花个体采取轮盘赌方式。

[0079] e、判断是否满足终止条件,若是,则执行下一步,否则跳转至b。

[0080] f、输出全局最优个体和适应值,算法结束。

[0081] g、将得到的最优权值和阈值带入BP神经网络中进行训练,得到最优预测模型。

[0082] 其中,在此次与BP神经网络模型、GA-BP神经网络模型的对比实验中,所有模型迭代次数均为100,烟花算法关键参数如表1所示:

[0083] 表1

参数名	参数说明	参数值
N	烟花种群的大小	5
d	烟花爆炸半径调节常数	20
m	烟花爆炸火花数调节常数	8
Im	烟花爆炸火花个数上界值	5
bm	烟花爆炸火花个数下界值	1
g	高斯变异火花数	5
T	最大迭代数	100

[0085] 4、BP神经网络权值和阈值的更新公式为:

$$[0086] \quad \omega_{ij} = \omega_{ij} + \eta H_j (1 - H_j) x_i \sum_{k=1}^m \omega_{jk} e_k, \quad i = 1, 2, \dots, n; \quad j = 1, 2, \dots, l$$

$$[0087] \quad \omega_{jk} = \omega_{jk} + \eta H_j e_k, \quad j = 1, 2, \dots, l; \quad k = 1, 2, \dots, m$$

$$[0088] \quad a_j = a_j + \eta H_j (1 - H_j) x_i \sum_{k=1}^m \omega_{jk} e_k, \quad j = 1, 2, \dots, l$$

[0089] $b_k = b_k + \eta e_k, k = 1, 2, \dots, m$

[0090] 其中, ω_{ij} 、 a 为输入层和隐含层间的连接权值和隐含层阈值, ω_{jk} 、 b 为隐含层和输出层之间的连接权值和阈值, H_j 为隐含层输出, η 为学习率。

[0091] 网络学习率是神经网络的关键参数之一, 学习率过低, 损失函数的变化速度就越慢, 收敛时间就越长, 而且容易陷入局部最优; 学习率过高, 在算法优化的前期可以加速学习, 使得模型更容易接近局部或全局最优解, 但是在后期会有较大的波动, 甚至会出现损失函数的值在最优解附近徘徊的情况。动量因子主要是为了加快网络的收敛速度, 本研究中网络学习率和动量因子的选取是多次调试出来的。迭代次数主要考虑到运行时间和网络是否充分迭代更新, 迭代次数过大会导致运行时间过长, 迭代次数过小, 运行快但会导致迭代不充分, 网络还有优化的空间, 迭代次数一般取100-500, 视运行情况而定。参数设置如表2所示:

[0092] 表2

参数名称	参数说明	参数值
lr	网络学习率	0.02
mc	附件动量因子	0.09
epochs	训练最大迭代数	200
goal	训练目标最小误差	0.001

[0094] 步骤6: 根据预测模型对光伏发电功率进行预测。

[0095] 步骤5中训练结束后, 保存模型文件, 对所述测试集中的数据进行测试, 并对预测结果进行误差指标检查, 检查公式如下:

[0096] $e_k = Y_k - O_k, k = 1, 2, \dots, m$

[0097] 其中, Y_k 为网络的预测值, O_k 为实际值, 检查误差指标, 若未满足规定的误差性能指标且迭代次数未达到规定的上限值时, 重复步骤(4), 直到满足终止条件。

[0098] 如图4所示: 分别对BP神经网络模型、GA-BP神经网络模型与FWA-BP神经网络模型进行实验, 实验采用相同的实验环境及迭代次数。其中模型预测误差指标对比如下表3所示:

[0099] 表3

	BP	GA-BP	FWA-BP
RMSE (均方根误差)	0.80	0.73	0.59
MAE (平均绝对误差)	0.65	0.58	0.51
MSE (均方误差)	0.64	0.53	0.35
MAPE% (平均绝对百分比误差)	118.14	33.80	6.01

[0101] 从图4中不同算法功率预测结果对比图可以看出: 与传统的BP神经网络和GA-BP神经网络相比, 本发明提出的FWA优化BP神经网络模型对光伏发电功率的预测结果更接近于实际值, 能够较好的实现对光伏发电功率的预测, 进一步通过具体的预测误差指标分析, 如上表3所列, 可以看出在四种误差指标下, FWA-BP神经网络的误差都是最小的, 模型性能最好。

[0102] 以上实施例仅用以说明本发明的技术方案而非限制, 尽管参照较佳实施例对本发明进行了详细说明, 本领域的普通技术人员应当理解, 可以对本发明的技术方案进行修改

或者等同替换,而不脱离本发明技术方案的精神和范围。

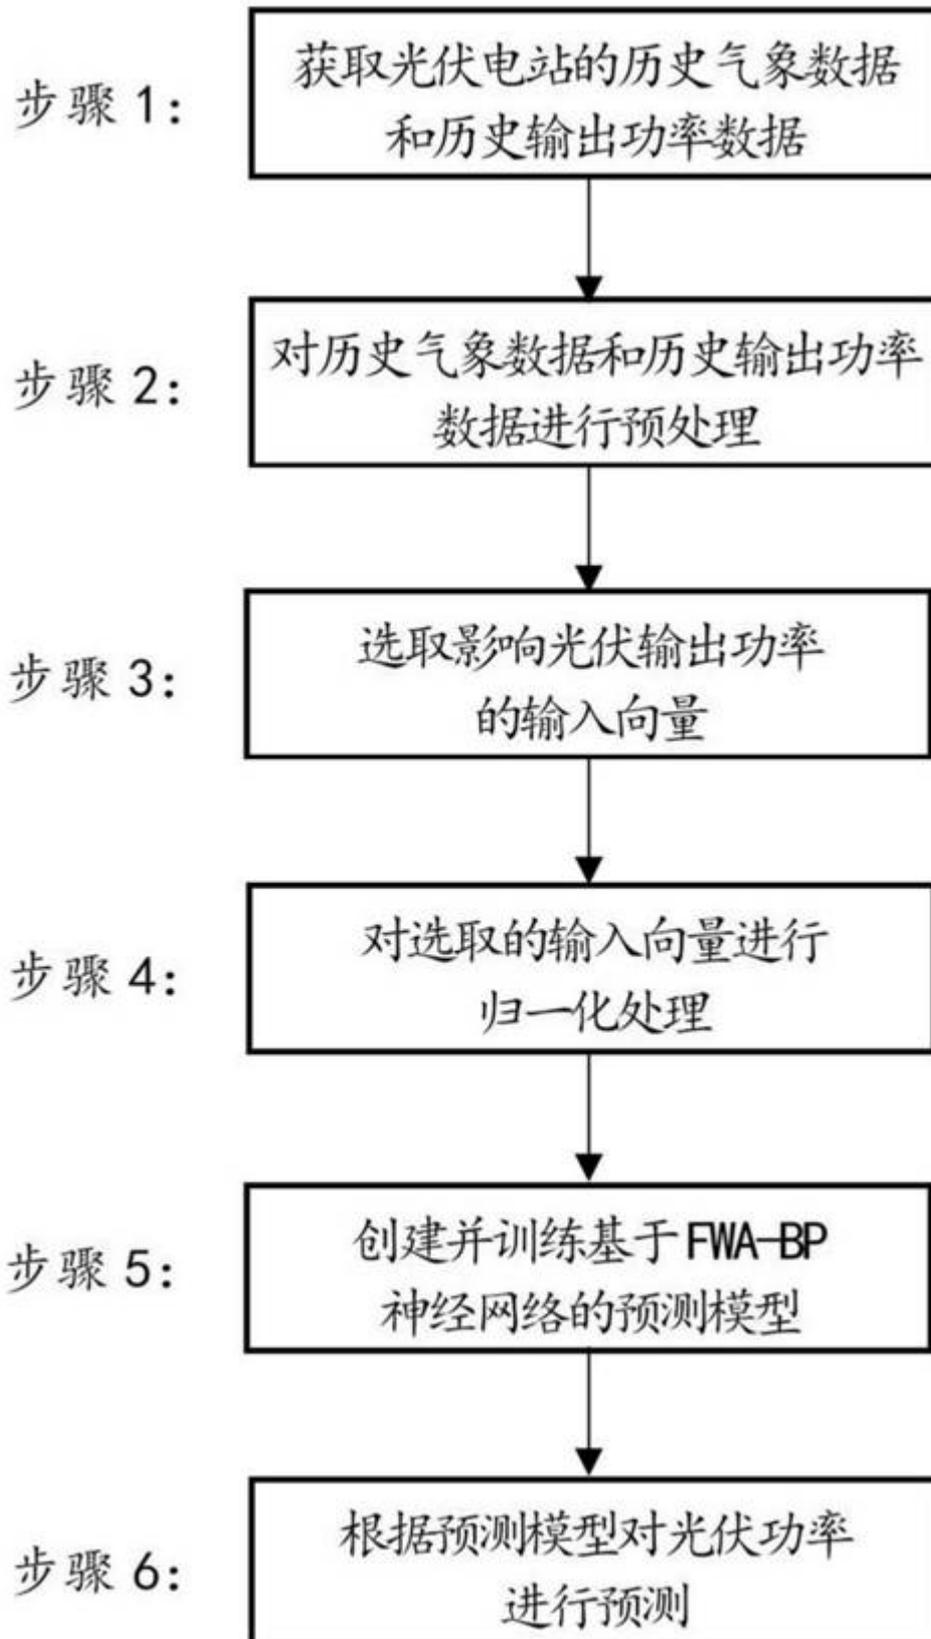


图1

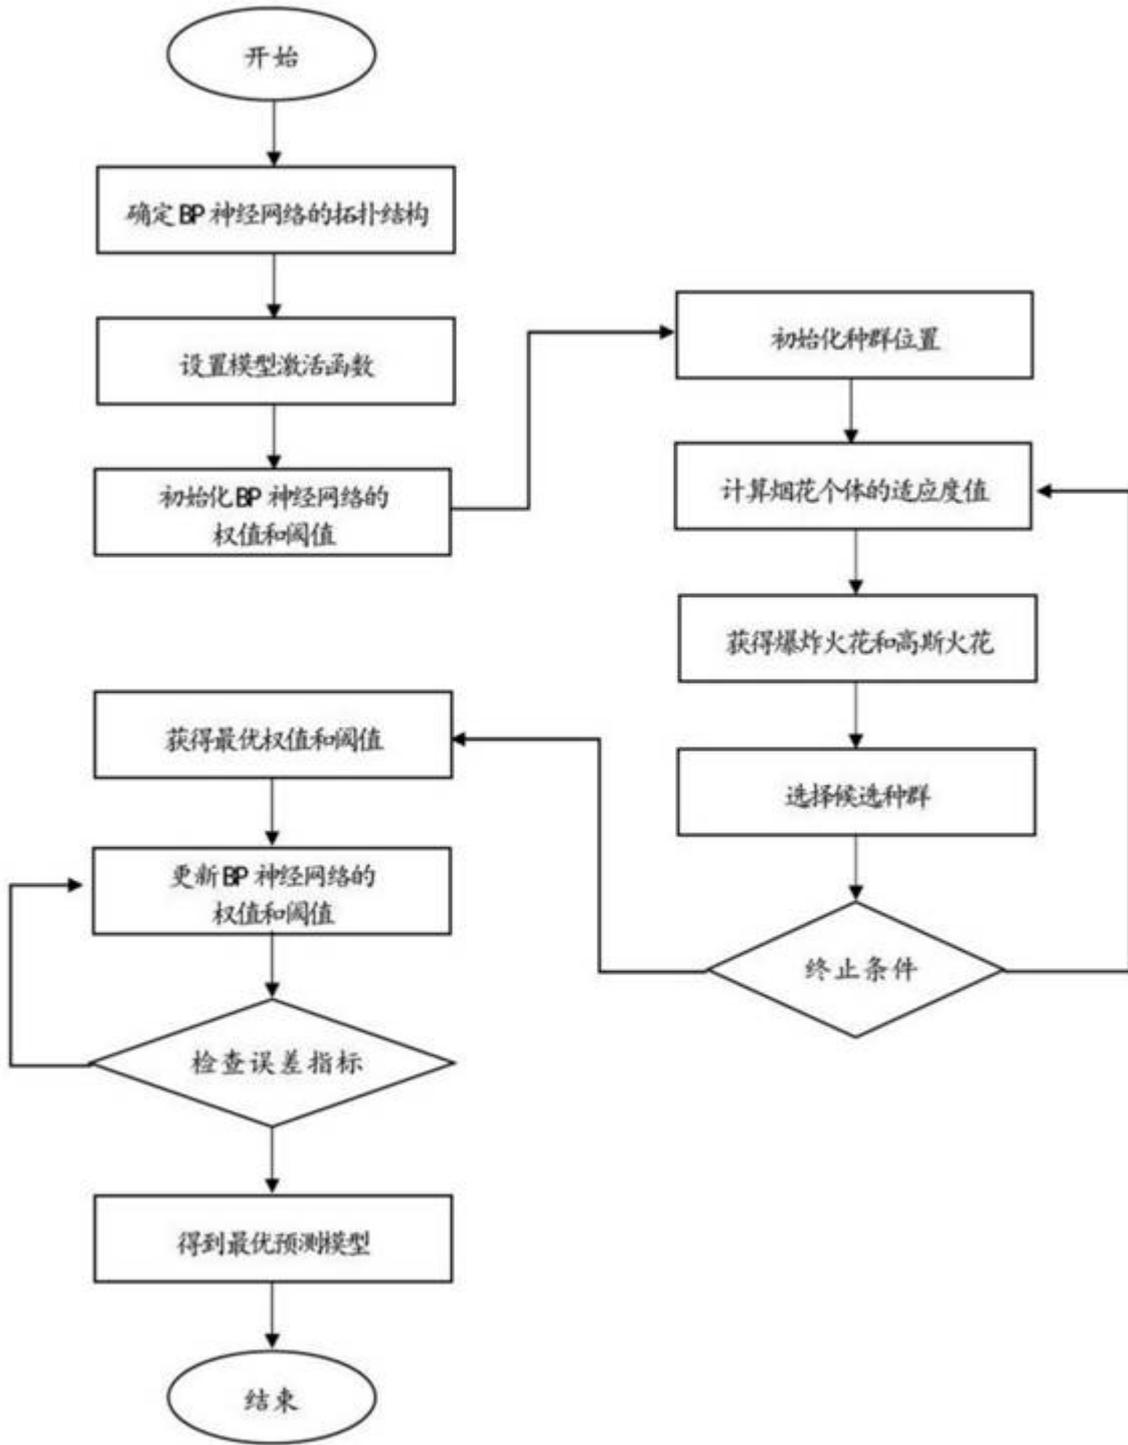


图2

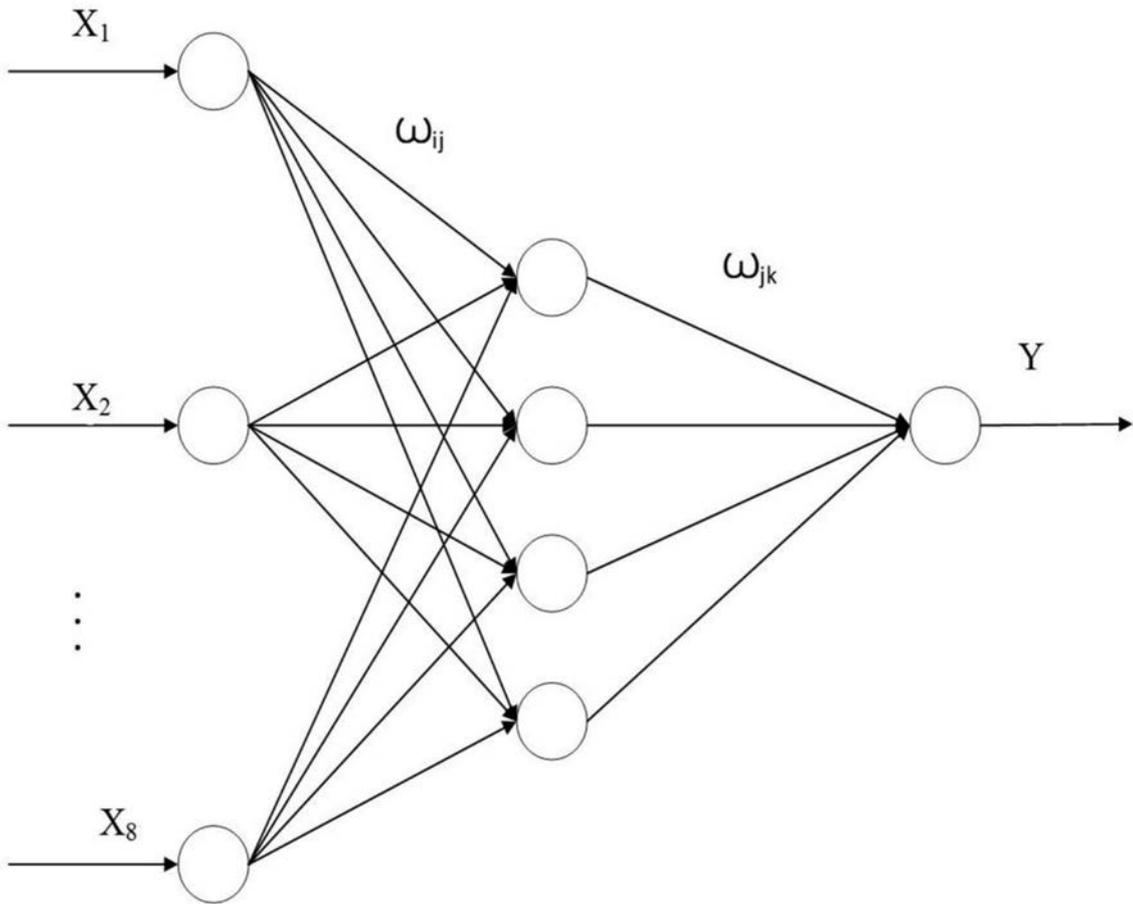


图3

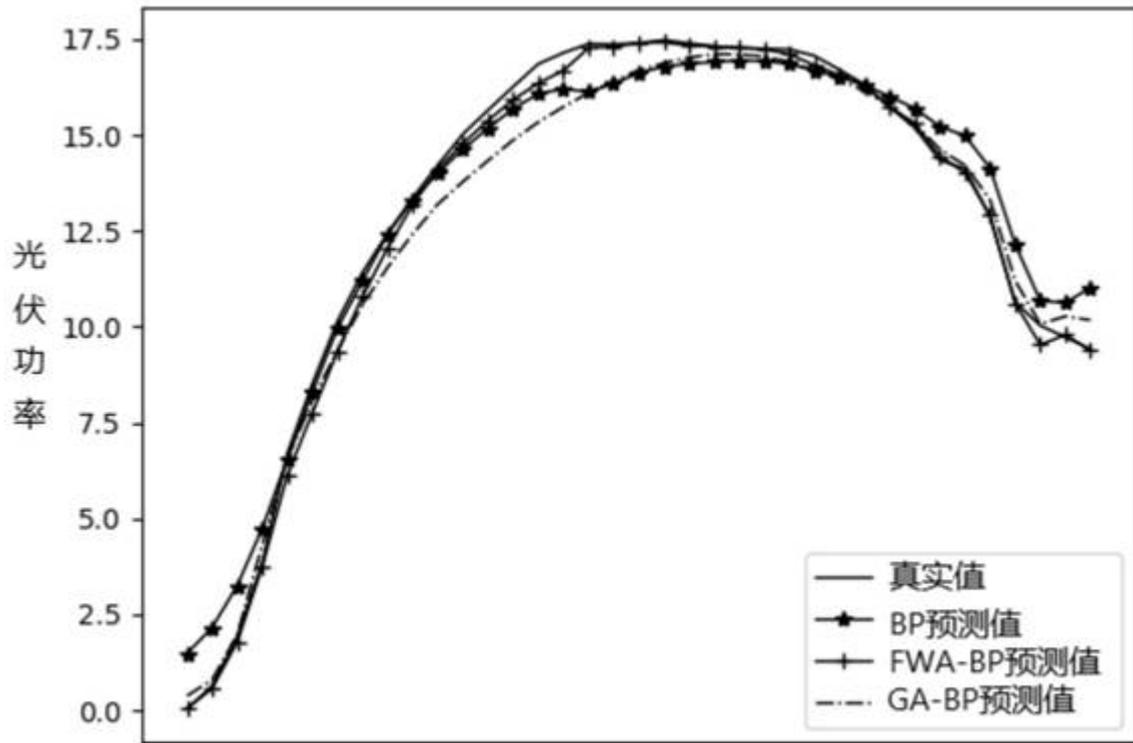


图4