



(12) 发明专利

(10) 授权公告号 CN 113468817 B

(45) 授权公告日 2023. 08. 22

(21) 申请号 202110788967.0
(22) 申请日 2021.07.13
(65) 同一申请的已公布的文献号
申请公布号 CN 113468817 A

G06Q 50/06 (2012.01)
G06N 3/006 (2023.01)
G06N 3/0499 (2023.01)
G06N 3/08 (2023.01)

(43) 申请公布日 2021.10.01
(73) 专利权人 淮阴工学院
地址 223000 江苏省淮安市经济技术开发区
枚乘东路1号

(56) 对比文件
CN 112819238 A, 2021.05.18
CN 107516150 A, 2017.12.26
CN 112686464 A, 2021.04.20
CN 112733462 A, 2021.04.30
CN 110348631 A, 2019.10.18
CN 111105045 A, 2020.05.05
CN 110555548 A, 2019.12.10
Caiyang Yu, Mengxiang Chen等.SGOA:
annealing-behaved grasshopper optimizer
for global tasks.Engineering with
Computers.2021,第38卷3761-3788.

(72) 发明人 胡浩文 夏鑫 王晓露 张楚
彭甜 刘康 吕文卓

(74) 专利代理机构 南京苏高专利商标事务所
(普通合伙) 32204
专利代理师 柏尚春

(51) Int. Cl.
H02J 3/00 (2006.01)
H02J 3/38 (2006.01)
G06Q 10/04 (2023.01)

审查员 毛晓羽

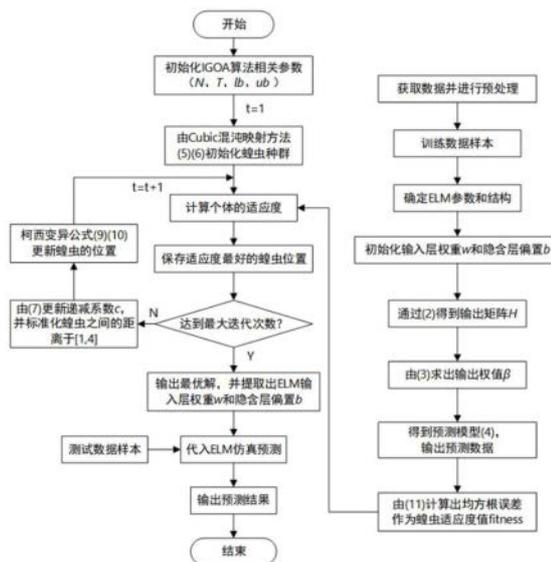
权利要求书4页 说明书9页 附图1页

(54) 发明名称

一种基于IGOA优化ELM的超短期风电功率预测方法

(57) 摘要

本发明公开一种基于IGOA优化ELM的超短期风电功率预测方法,包括:从风电场数据采集与监视控制系统获取到历史风速和风电功率数据,对数据进行预处理,并选取训练数据样本和测试数据样本,建立ELM预测模型;对GOA进行改进,采用Cubic混沌映射方法对GOA的种群进行初始化;通过一种基于正弦函数的调整参数控制策略来更新递减系数;在蝗虫个体位置更新处引入柯西变异操作,得到IGOA;利用IGOA优化ELM的参数,获得最优参数;将获得的最优参数和测试数据样本输入到ELM预测模型中得到预测结果,并选取风电预测中常用的三种评价指标:均方根误差RMSE、平均绝对误差MAE和最大绝对值误差Emax,对模型的预测性能进行评价。本发明有效地预测超短期风电功率,提高预测模型精度。



CN 113468817 B

1. 一种基于IGOA优化ELM的超短期风电功率预测方法,其特征在于,包括以下步骤:

步骤1:从风电场数据采集与监视控制系统获取到历史风速和风电功率数据,对数据进行预处理,并选取训练数据样本和测试数据样本,建立ELM预测模型;

所述步骤1中对数据预处理具体包括:

步骤1.1.1:如果采集到的功率数据比风电装机容量大,用风电装机容量代替,如果采集到的功率数据是负数,则用零代替;

步骤1.1.2:对于相邻时刻之间缺失的数据,用相邻两数据的平均值替代,对于异常数据,用其前一时刻的数据替代;

步骤1.1.3:根据式(1)对数据进行归一化处理:

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中: y 为归一化后的数据, x 为原始数据, x_{\max} 和 x_{\min} 分别为原始数据中最大值和最小值,归一化范围为 $[0,1]$;

步骤2:对GOA进行改进,采用Cubic混沌映射方法对GOA的种群进行初始化;

步骤3:通过基于正弦函数的调整参数控制策略来更新递减系数;

所述步骤3中具体包括:

在算法前期递减系数 c 下降缓慢,能够全局搜索到全局最优解的大概范围;在算法后期递减系数 c 下降迅速,算法快速收敛到局部最优解,基于正弦函数的调整参数控制策略如公式(2)所示:

$$\begin{cases} c = c_{\max} - (c_{\max} - c_{\min}) \cdot \sin\left(\left(\frac{t}{T}\right)^k \cdot \frac{\pi}{u}\right), \\ c_{\max} = 1, c_{\min} = 0.00004 \end{cases} \quad (2)$$

式中, t 为算法当前迭代次数, T 为最大迭代次数, k 、 u 为调节参数;

步骤4:在蝗虫个体位置更新处引入柯西变异操作,得到IGOA;

步骤5:利用IGOA优化ELM的参数,获得最优参数;

所述步骤5具体包括:

步骤5.1:初始化相关算法参数:设置蝗虫种群数 N 、空间维度 D 、最大迭代次数 T 、搜索空间的上界 ub 、下界 lb 和当前迭代次数 $t=1$,并采用混沌理论初始化生成当前蝗虫所在的空间位置 X_i^d ;

步骤5.2:通过公式(3)计算经过ELM网络训练的预测值 y_i 与训练样本实际值 t_i 的均方根误差,作为蝗虫适应度值 $fitness$,将当前适应度值最小的蝗虫位置保存到变量 \hat{T}_d ;

$$fitness = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2} \quad (3)$$

步骤5.3:判断当前迭代次数 t 是否达到最大迭代次数 T ;若达到,则执行步骤5.5,否则执行步骤5.4;

步骤5.4:通过调整参数控制策略公式(2)更新递减系数 c ,标准化蝗虫之间的距离于 $[1,4]$,柯西变异公式更新蝗虫的位置,当前迭代次数 $t=t+1$,并返回ELM网络训练得到新的预测值,再根据公式(3)更新蝗虫的适应度值,与当前最优解进行比较,若优于当前最优解

则更新 \hat{T}_d ，否则执行步骤5.3；

步骤5.5: 输出最优解 \hat{T}_d ，从中提取出ELM网络所需的输入层权重 w 和隐含层偏置 b ；

步骤6: 将获得的最优参数和测试数据样本输入到ELM预测模型中得到预测结果，并选取风电预测中常用的三种评价指标: 均方根误差RMSE、平均绝对误差MAE和最大绝对值误差 E_{\max} ，对模型的预测性能进行评价。

2. 根据权利要求1所述的一种基于IGOA优化ELM的超短期风电功率预测方法，其特征在于，所述步骤1中建立ELM预测模型具体包括：

步骤1.2.1: 将训练数据样本 $\{x_i, t_i\}_{i=1}^N \in R^n \times R^m$ ，其中， x_i 和 t_i 为训练数据真实值， N 为输入层节点数， n 和 m 为向量空间维数，隐含层的激活函数 $g(\blacksquare)$ 和隐含层节点数 L ，输入到算法模型中；

步骤1.2.2: 确定输入层权重 $w_i \in [-1, 1]$ 和隐含层偏置 $b_i \in [0, 1]$ ；

步骤1.2.3: 根据式(4)计算隐含层的输出矩阵 H ，

$$H = \begin{pmatrix} g(w_1 x_1 + b_1) & \cdots & g(w_L x_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(w_1 x_N + b_1) & \cdots & g(w_L x_N + b_L) \end{pmatrix}_{N \times L} \quad (4)$$

其中， $H = \{h_1, h_2, \dots, h_i\}$ ， $h_i = g(w_i x_i + b_i)$ 为隐含层第 i 个神经元的输出；

步骤1.2.4: 求解输出权值 β ，通过最小二乘解获得，即式(5)：

$$\begin{cases} \beta = H^* T \\ H^* = (H^T H)^{-1} H^T \beta = \begin{pmatrix} \beta_{11} \cdots \beta_{1M} \\ \vdots \ddots \vdots \\ \beta_{L1} \cdots \beta_{LM} \end{pmatrix}_{L \times M} \\ T = \begin{pmatrix} t_1^T \\ \vdots \\ t_N^T \end{pmatrix} = \begin{pmatrix} t_{11} \cdots t_{1M} \\ \vdots \ddots \vdots \\ t_{N1} \cdots t_{NM} \end{pmatrix}_{N \times M} \end{cases} \quad (5)$$

式中： H^* 为矩阵 H 的Moore-Penrose的广义逆；

步骤1.2.5: 由输出权值得到ELM预测模型，即式(6)：

$$y_i = \sum_{i=1}^L \beta_i g(w_i x + b_i) \quad (6)$$

式中： β_i 为隐含层第 i 个节点与输出层之间的连接权值， w_i 为输入层与隐含层第 i 个节点之间的连接权值， b_i 为隐含层第 i 个节点的偏置。

3. 根据权利要求1所述的一种基于IGOA优化ELM的超短期风电功率预测方法，其特征在于，所述步骤2具体包括：

步骤2.1: 设在 D 维空间中有若干个蝗虫种群中的个体，经过Cubic混沌映射公式(7)产生蝗虫种群中的个体，即 $Y = (y_1, y_2, \dots, y_n)$ ，且其取值范围为 $y_n \in (0, 1)$ ；

$$y_{n+1} = a \cdot y_n \cdot (1 - y_n^2), \quad 0 < y_n < 1, \quad n = 1, 2, 3, \dots \quad (7)$$

式中, a 为控制参数;

步骤2.2: 将蝗虫种群的个体每一维进行迭代 $N-1$ 次, 从而产生 $N-1$ 个人工蝗虫种群的个体;

步骤2.3: 当所有的人工蝗虫种群中个体迭代完成, 按照式(8)映射到解空间中:

$$X_i^d = \frac{y_i^d \cdot (ub^d - lb^d) \cdot i}{N} + lb^d \quad (8)$$

式中: N 为蝗虫种群数, ub^d 、 lb^d 为搜索空间的上、下界, y_i^d 是第 i 个人工蝗虫种群的个体的第 d 维坐标, X_i^d 是第 i 个人工蝗虫种群的个体的第 d 维的位置。

4. 根据权利要求3所述的一种基于IGOA优化ELM的超短期风电功率预测方法, 其特征在于, 所述步骤2.1中, Cubic映射的混沌性与所述控制参数的取值有关, $a=2.6$ 时, Cubic映射具有混沌遍历性。

5. 根据权利要求1所述的一种基于IGOA优化ELM的超短期风电功率预测方法, 其特征在于, 所述调节参数选用 $k=2$, $u=2$ 。

6. 根据权利要求1所述的一种基于IGOA优化ELM的超短期风电功率预测方法, 其特征在于, 所述步骤4中具体包括:

在蝗虫个体位置更新处添加柯西变异操作, 变异后的蝗虫增加种群多样性, 根据柯西标准分布函数式(9), 对最优个体构建柯西变异公式(10), 变异后蝗虫个体位置更新公式为(11)所示:

$$F(\lambda, 0, 1) = \frac{1}{\pi \cdot (1 + \lambda^2)} \quad (9)$$

$$\hat{T}_d^\xi = \hat{T}_d \cdot \frac{1}{\pi \cdot \left(1 + \left(\frac{t}{T}\right)^2\right)} \quad (10)$$

$$X_i^d = \begin{cases} c \left(\sum_{j=1, j \neq i}^N c \frac{ub^d - lb^d}{2} s(d_{ij}(t)) \frac{x_j^d(t) - x_i^d(t)}{d_{ij}(t)} \right) + \hat{T}_d^\xi \cdot r, & r \leq p \\ c \left(\sum_{j=1, j \neq i}^N c \frac{ub^d - lb^d}{2} s(d_{ij}(t)) \frac{x_j^d(t) - x_i^d(t)}{d_{ij}(t)} \right) + \hat{T}_d, & r > p \end{cases} \quad (11)$$

式中: $x_i^d(t)$ 为算法迭代到第 t 次时第 d 维第 i 个蝗虫的位置, $x_j^d(t)$ 为算法迭代到第 t 次时第 d 维第 j 个蝗虫的位置, $d_{ij}(t)$ 是蝗虫种群在第 t 次迭代时第 i 个蝗虫和第 j 个蝗虫之间的距离, \hat{T}_d 是当前最优个体位置, \hat{T}_d^ξ 是经过柯西变异后的最优蝗虫位置, r 是 $(0, 1)$ 上的随机数, p 为变异概率, 经试验选用 $p=0.7$ 。

7. 根据权利要求1所述的一种基于IGOA优化ELM的超短期风电功率预测方法, 其特征在于, 所述步骤6中RMSE、MAE和 E_{\max} 三种评价指标公式分别如下:

$$RMSE = \frac{\sqrt{\sum_{i=1}^n (P_{ti} - P_{yi})^2}}{P_{cap} \cdot \sqrt{n}} \quad (12)$$

$$MAE = \frac{\sum_{i=1}^n |P_{ti} - P_{yi}|}{P_{cap} \cdot n} \quad (13)$$

$$E_{\max} = \max(|P_{ti} - P_{yi}|) \quad (14)$$

式中： n 为样本个数， P_{ti} 为*i*时刻的实际功率， P_{yi} 为*i*时刻的预测功率， P_{cap} 为风电场开机总容量。

一种基于IGOA优化ELM的超短期风电功率预测方法

技术领域

[0001] 本发明涉及风电功率预测领域,尤其涉及一种基于IGOA优化ELM的超短期风电功率预测方法。

背景技术

[0002] 随着风力发电技术日臻成熟,风电单机容量和并网型风电场规模不断扩大,风电占电力系统发电总量的比例也逐年增加。风电场穿透功率不断加大,给电力系统带来的一系列问题日益突出,严重威胁、电力系统安全、稳定、经济、可靠运行。对风电功率进行及时准确的预测,可以显著增强电力系统的安全性、稳定性、经济性和可控性。

[0003] 极限学习机(Extreme Learning Machine,ELM)用来训练单隐藏层前馈神经网络(SLFN)与传统的SLFN训练算法不同,该算法随机产生输入层权重及隐含层偏置,且在训练过程中无需调整,只需要设置隐含层神经元的个数便可以获得唯一的最优解。但是由于梯度下降法需要多次迭代,从而达到修正权值和阈值的目的,因此训练过程耗时较长,同时容易陷入局部极小值。为此需要一种更高效的优化算法来提高极限学习机的预测精度。

[0004] 蝗虫算法(Grasshopper Optimization Algorithm,GOA)是由Saremi等于2017年提出的一种元启发式仿生优化算法,但是在算法后期容易陷入局部极值点,收敛速度变慢,导致预测精度降低。为此引进Cubic混沌映射方法、通过一种基于正弦函数的调整参数控制策略来更新递减系数以及在蝗虫个体位置更新处引入柯西变异操作来改进传统蝗虫算法,然后再利用改进蝗虫算法优化极限学习机并获取最优参数,建立新的极限学习机预测模型,实现超短期风电功率预测。

发明内容

[0005] 发明目的:本发明的目的是针对现有技术的不足,提出一种基于IGOA优化ELM的超短期风电功率预测方法,解决现有ELM预测模型存在参数难以确定,易陷入局部最优等技术问题,提高预测模型精度。

[0006] 技术方案:一种基于IGOA优化ELM的超短期风电功率预测方法,包括以下步骤:

[0007] 步骤1:从风电场数据采集与监视控制系统获取到历史风速和风电功率数据,对数据进行预处理,并选取训练数据样本和测试数据样本,建立ELM预测模型;

[0008] 步骤2:对GOA进行改进,采用Cubic混沌映射方法对GOA的种群进行初始化;

[0009] 步骤3:通过一种基于正弦函数的调整参数控制策略来更新递减系数;

[0010] 步骤4:在蝗虫个体位置更新处引入柯西变异操作,得到IGOA;

[0011] 步骤5:利用IGOA优化ELM的参数,获得最优参数;

[0012] 步骤6:将获得的最优参数和测试数据样本输入到ELM预测模型中得到预测结果,并选取风电预测中常用的三种评价指标:均方根误差RMSE、平均绝对误差MAE和最大绝对值误差 E_{\max} ,对模型的预测性能进行评价。

[0013] 进一步地,步骤1中对数据预处理具体包括:

[0014] 步骤1.1.1:如果采集到的功率数据比风电装机容量大,用风电装机容量代替,如果采集到的功率数据是负数,则用零代替;

[0015] 步骤1.1.2:对于相邻时刻之间缺失的数据,用相邻两数据的平均值替代,对于异常数据,用其前一时刻的数据替代;

[0016] 步骤1.1.3:根据式(1)对数据进行归一化处理:

$$[0017] \quad y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

[0018] 式中: y 为归一化后的数据, x 为原始数据, x_{\max} 和 x_{\min} 分别为原始数据中最大值和最小值,归一化范围为 $[0,1]$ 。

[0019] 进一步地,步骤1中建立ELM预测模型具体包括:

[0020] 步骤1.2.1:将训练数据样本 $\{x_i, t_i\}_{i=1}^N \in R^n \times R^m$,其中, x_i 和 t_i 为训练数据真实值, N 为输入层节点数, n 和 m 为向量空间维数,隐含层的激活函数 $g(\blacksquare)$ 和隐含层节点数 L ,输入到算法模型中;

[0021] 步骤1.2.2:确定输入层权重 $w_i \in [-1,1]$ 和隐含层偏置 $b_i \in [0,1]$;

[0022] 步骤1.2.3:根据式(2)计算隐含层的输出矩阵 H ,

$$[0023] \quad H = \begin{pmatrix} g(w_1 x_1 + b_1) & \cdots & g(w_L x_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(w_1 x_N + b_1) & \cdots & g(w_L x_N + b_L) \end{pmatrix}_{N \times L} \quad (2)$$

[0024] 其中, $H = \{h_1, h_2, \dots, h_i\}$, $h_i = g(w_i x_i + b_i)$ 为隐含层第 i 个神经元的输出。

[0025] 步骤1.2.4:求解输出权值 β ,通过最小二乘解获得,即式(3):

$$[0026] \quad \begin{cases} \beta = H^* T \\ H^* = (H^T H)^{-1} H^T \beta = \begin{pmatrix} \beta_{11} \cdots \beta_{1M} \\ \vdots \ddots \vdots \\ \beta_{L1} \cdots \beta_{LM} \end{pmatrix}_{L \times M} \\ T = \begin{pmatrix} t_1^T \\ \vdots \\ t_N^T \end{pmatrix} = \begin{pmatrix} t_{11} \cdots t_{1M} \\ \vdots \ddots \vdots \\ t_{N1} \cdots t_{NM} \end{pmatrix}_{N \times M} \end{cases} \quad (3)$$

[0027] 式中: H^* 为矩阵 H 的Moore-Penrose的广义逆;

[0028] 步骤1.2.5:由输出权值得到ELM预测模型,即式(4):

$$[0029] \quad y_i = \sum_{i=1}^L \beta_i g(w_i x + b_i) \quad (4)$$

[0030] 式中: β_i 为隐含层第 i 个节点与输出层之间的连接权值, w_i 为输入层与隐含层第 i 个节点之间的连接权值, b_i 为隐含层第 i 个节点的偏置。

[0031] 进一步地,步骤2具体包括:

[0032] 步骤2.1:设在 D 维空间中有若干个蝗虫种群中的个体,经过Cubic混沌映射公式

(5)产生蝗虫种群中的个体,即 $Y = (y_1, y_2, \dots, y_n)$,且其取值范围为 $y_n \in (0, 1)$;

$$[0033] \quad y_{n+1} = a \cdot y_n \cdot (1 - y_n^2), \quad 0 < y_n < 1, \quad n = 1, 2, 3, \dots \quad (5)$$

[0034] 式中, a 为控制参数。

[0035] 步骤2.2:将蝗虫种群的个体每一维进行迭代 $N-1$ 次,从而产生 $N-1$ 个人工蝗虫种群的个体;

[0036] 步骤2.3:当所有的人工蝗虫种群中个体迭代完成,按照式(6)映射到解空间中:

$$[0037] \quad X_i^d = \frac{y_i^d \cdot (ub^d - lb^d) \cdot i}{N} + lb^d \quad (6)$$

[0038] 式中: N 为蝗虫种群数, ub^d 、 lb^d 为搜索空间的上、下界, y_i^d 是第 i 个人工蝗虫种群的个体的第 d 维坐标, X_i^d 是第 i 个人工蝗虫种群的个体的第 d 维的位置。

[0039] 进一步地,步骤2.1中,Cubic映射的混沌性与控制参数的取值有关, $a=2.6$ 时,Cubic映射具有较好的混沌遍历性。

[0040] 进一步地,步骤3中具体包括:

[0041] 传统蝗虫算法的递减系数 c 用于平衡全局搜索和局部开发的作用,且与迭代次数成正比,但是并不能满足算法在不同时期的实际要求:在算法前期要求递减系数 c 比较大且下降缓慢,能够有能力和时间进行全局搜索到全局最优解的大概范围;在算法后期要求递减系数 c 较小且下降迅速,算法快速收敛到局部最优解,基于正弦函数的调整参数控制策略如公式(7)所示:

$$[0042] \quad \begin{cases} c = c_{\max} - (c_{\max} - c_{\min}) \cdot \sin\left(\left(\frac{t}{T}\right)^k \cdot \frac{\pi}{u}\right), \\ c_{\max} = 1, c_{\min} = 0.00004 \end{cases} \quad (7)$$

[0043] 式中, t 为算法当前迭代次数, T 为最大迭代次数, k 、 u 为调节参数。

[0044] 进一步地,调节参数选用 $k=2$, $u=2$ 。

[0045] 进一步地,步骤4中具体包括:

[0046] 传统算法中蝗虫个体根据当前自身与种群间其他个体间的距离和最优个体的位置来更新下一步自身位置,在后期易陷入局部最优的问题,为此在蝗虫个体位置更新处添加柯西变异操作,变异后的蝗虫增加种群多样性,有助于算法跳出局部最优,寻找到新的最优解。根据柯西标准分布函数式(8),对最优个体构建柯西变异公式(9),变异后蝗虫个体位置更新公式为(10)所示:

$$[0047] \quad F(\lambda, 0, 1) = \frac{1}{\pi \cdot (1 + \lambda^2)} \quad (8)$$

$$[0048] \quad \hat{T}_d^\xi = \hat{T}_d \cdot \frac{1}{\pi \cdot \left(1 + \left(\frac{t}{T}\right)^2\right)} \quad (9)$$

$$[0049] \quad X_i^d = \begin{cases} c \left(\sum_{j=1, j \neq i}^N c \frac{ub^d - lb^d}{2} s(d_{ij}(t)) \frac{x_j^d(t) - x_i^d(t)}{d_{ij}(t)} \right) + \widehat{T}_d^\xi \cdot r, & r \leq p \\ c \left(\sum_{j=1, j \neq i}^N c \frac{ub^d - lb^d}{2} s(d_{ij}(t)) \frac{x_j^d(t) - x_i^d(t)}{d_{ij}(t)} \right) + \widehat{T}_d, & r > p \end{cases} \quad (10)$$

[0050] 式中： $x_i^d(t)$ 为算法迭代到第t次时第d维第i个蝗虫的位置， $x_j^d(t)$ 为算法迭代到第t次时第d维第j个蝗虫的位置， $d_{ij}(t)$ 是蝗虫种群在第t次迭代时第i个蝗虫和第j个蝗虫之间的距离， \widehat{T}_d 是当前最优个体位置， \widehat{T}_d^ξ 是经过柯西变异后的最优蝗虫位置，r是(0,1)上的随机数，p为变异概率，经试验选用p=0.7。

[0051] 进一步地，步骤5具体包括：

[0052] 步骤5.1:初始化相关算法参数:设置蝗虫种群数N、空间维度D,最大迭代次数T、搜索空间的上界ub、下界lb和当前迭代次数t=1,并采用混沌理论初始化生成当前蝗虫所在的空间位置 X_i^d ;

[0053] 步骤5.2:通过公式(11)计算经过ELM网络训练的预测值 y_i 与训练样本实际值 t_i 的均方根误差,作为蝗虫适应度值fitness,将当前适应度值最小的蝗虫位置保存到变量 \widehat{T}_d ;

$$[0054] \quad fitness = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2} \quad (11)$$

[0055] 步骤5.3:判断当前迭代次数t是否达到最大迭代次数T;若达到,则执行步骤5.5,否则执行步骤5.4;

[0056] 步骤5.4:通过调整参数控制策略(7)更新递减系数c,标准化蝗虫之间的距离于[1,4],柯西变异公式(9)和(10)更新蝗虫的位置,当前迭代次数t=t+1,并返回ELM网络训练得到新的预测值,再根据公式(11)更新蝗虫的适应度值,与当前最优解进行比较,若优于当前最优解则更新 \widehat{T}_d ,否则执行步骤5.3;

[0057] 步骤5.5:输出最优解 \widehat{T}_d ,从中提取出ELM网络所需的输入层权重w和隐含层偏置b。

[0058] 进一步地,步骤6中RMSE、MAE和 E_{\max} 三种评价指标公式分别如下:

$$[0059] \quad RMSE = \frac{\sqrt{\sum_{i=1}^n (P_{ti} - P_{yi})^2}}{P_{cap} \cdot \sqrt{n}} \quad (12)$$

$$[0060] \quad MAE = \frac{\sum_{i=1}^n |P_{ti} - P_{yi}|}{P_{cap} \cdot n} \quad (13)$$

$$[0061] \quad E_{\max} = \max(|P_{ti} - P_{yi}|) \quad (14)$$

[0062] 式中:n为样本个数, P_{ti} 为i时刻的实际功率, P_{yi} 为i时刻的预测功率, P_{cap} 为风电场开机总容量。

[0063] 有益效果:与现有技术相比,本发明具有如下显著的优点:首先对GOA采用Cubic混

沌映射方法初始化蝗虫的位置 X_i^d 、构建基于正弦函数的调整参数控制策略的递减系数 c 和在蝗虫个体位置更新处添加柯西变异操作,使变异后的蝗虫可以增加种群多样性,加快收敛速度,帮助算法跳出局部最优,寻找到新的最优解,增强算法可靠性;然后利用IGOA对ELM的参数进行优化,从而达到提高预测模型精度的目的。

附图说明

[0064] 图1为本发明提供的基于IGOA优化ELM的超短期风电功率预测方法流程图。

具体实施方式

[0065] 为了使本发明的目的、技术方案及优点更加清楚明白,以下结合附图及实施例,对本发明进行进一步详细说明。

[0066] 针对现有技术的不足,本发明首先对GOA采用Cubic混沌映射方法初始化蝗虫的位置、构建基于正弦函数的调整参数控制策略的递减系数 c 和在蝗虫个体位置更新处添加柯西变异操作,使变异后的蝗虫可以增加种群多样性,加快收敛速度,帮助算法跳出局部最优,寻找到新的最优解,增强算法可靠性,然后利用IGOA对ELM的参数进行优化,建立新的ELM预测模型。

[0067] 本发明以某风电场2021年5月份连续250h的实测数据为实施例,进行实例仿真,以验证本发明的效果。图1为本发明提供的基于IGOA优化ELM的超短期风电功率预测模型流程图,实施步骤如下:

[0068] 步骤1:从风电场数据采集与监视控制系统获取到5月份连续250h、采样时间分辨率为10min的历史风速和风电功率数据,对数据进行一系列预处理,并选取训练数据样本和测试数据样本,建立ELM预测模型。

[0069] 其中对数据进行一系列预处理包括:

[0070] 步骤1.1.1:如果采集到的功率数据比风电装机容量大,用风电装机容量代替,如果采集到的功率数据是负数,则用零代替;

[0071] 步骤1.1.2:对于相邻时刻之间缺失的数据,用相邻两数据的平均值替代,对于异常数据,用其前一时刻的数据替代;

[0072] 步骤1.1.3:为了让数据处理更方便,根据式(1)对数据进行归一化处理。

$$[0073] \quad y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

[0074] 式中: y 为归一化后的数据, x 为原始数据, x_{\max} 和 x_{\min} 分别为原始数据中最大值和最小值,归一化范围为 $[0, 1]$ 。

[0075] 建立ELM预测模型包括:

[0076] 步骤1.2.1:将训练数据样本 $\{x_i, t_i\}_{i=1}^N \in R^n \times R^m$, x_i 和 t_i 为训练数据真实值, N 为输入层节点数, n 和 m 为向量空间维数,隐含层的激活函数 $g(\blacksquare)$ 和隐含层节点数 L ,输入到算法模型中;

[0077] 步骤1.2.2:确定输入层权重 $w_i \in [-1, 1]$ 和隐含层偏置 $b_i \in [0, 1]$;

[0078] 步骤1.2.3:计算隐含层的输出矩阵 H ,即式(2):

$$[0079] \quad H = \begin{pmatrix} g(w_1x_1 + b_1) & \cdots & g(w_Lx_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(w_1x_N + b_1) & \cdots & g(w_Lx_N + b_L) \end{pmatrix}_{N \times L} \quad (2)$$

[0080] 其中, $H = \{h_1, h_2, \dots, h_i\}$, $h_i = g(w_i x_i + b_i)$ 为隐含层第 i 个神经元的输出。

[0081] 步骤1.2.4: 求解输出权值 β , 可通过最小二乘解获得, 即式 (3):

$$[0082] \quad \begin{cases} \beta = H^* T \\ H^* = (H^T H)^{-1} H^T \beta = \begin{pmatrix} \beta_{11} \cdots \beta_{1M} \\ \vdots \quad \ddots \quad \vdots \\ \beta_{L1} \cdots \beta_{LM} \end{pmatrix}_{L \times M} \\ T = \begin{pmatrix} t_1^T \\ \vdots \\ t_N^T \end{pmatrix} = \begin{pmatrix} t_{11} \cdots t_{1M} \\ \vdots \quad \ddots \quad \vdots \\ t_{N1} \cdots t_{NM} \end{pmatrix}_{N \times M} \end{cases} \quad (3)$$

[0083] 式中: H^* 为矩阵 H 的 Moore-Penrose 的广义逆;

[0084] 步骤1.2.5: 由输出权值得到 ELM 预测模型, 即式 (4):

$$[0085] \quad y_i = \sum_{i=1}^L \beta_i g(w_i x + b_i) \quad (4)$$

[0086] 式中: β_i 为隐含层第 i 个节点与输出层之间的连接权值, w_i 为输入层与隐含层第 i 个节点之间的连接权值, b_i 为隐含层第 i 个节点的偏置。

[0087] 步骤二: 对 GOA 进行改进, 采用 Cubic 混沌映射方法对 GOA 的种群进行初始化。

[0088] 其中 Cubic 混沌映射方法对 GOA 的种群进行初始化包括:

[0089] 步骤2.1: 设在 D 维空间中有若干个蝗虫种群中的个体, 经过 Cubic 混沌映射公式 (5) 产生蝗虫种群中的个体, 即 $Y = (y_1, y_2, \dots, y_n)$, 且其取值范围为 $y_n \in (0, 1)$;

$$[0090] \quad y_{n+1} = a \cdot y_n \cdot (1 - y_n^2), \quad 0 < y_n < 1, \quad n = 1, 2, 3, \dots \quad (5)$$

[0091] 式中 a 为控制参数; Cubic 映射的混沌性与参数 a 的取值有关, 经查阅相关资料和试验, 本发明中选用 $a = 2.6$ 时, Cubic 映射具有较好的混沌遍历性。

[0092] 步骤2.2: 然后将蝗虫种群的个体每一维进行迭代 $N-1$ 次, 从而产生 $N-1$ 个人工蝗虫种群的个体;

[0093] 步骤2.3: 最后当所有的人工蝗虫种群中个体迭代完成时, 再按照式 (6) 映射到解空间中:

$$[0094] \quad X_i^d = \frac{y_i^d \cdot (ub^d - lb^d) \cdot i}{N} + lb^d \quad (6)$$

[0095] 上式中: N 为蝗虫种群数, ub^d 、 lb^d 为搜索空间的上、下界, y_i^d 是第 i 个人工蝗虫种群的个体的第 d 维坐标, X_i^d 是第 i 个人工蝗虫种群的个体的第 d 维的位置。

[0096] 步骤三: 然后通过一种基于正弦函数的调整参数控制策略来更新递减系数。

[0097] 传统蝗虫算法的递减系数 c 用于平衡全局搜索和局部开发的作用,且与迭代次数成正比,但是并不能满足算法在不同时期的实际要求:在算法前期要求递减系数 c 比较大且下降缓慢,足够有能力和时间进行全局搜索到全局最优解的大概范围;在算法后期要求递减系数 c 较小且下降迅速,让算法快速收敛到局部最优解。为此提出一种基于正弦函数的调整参数控制策略,公式如(7)所示:

$$[0098] \quad \begin{cases} c = c_{\max} - (c_{\max} - c_{\min}) \cdot \sin\left(\left(\frac{t}{T}\right)^k \cdot \frac{\pi}{u}\right), \\ c_{\max} = 1, c_{\min} = 0.00004 \end{cases} \quad (7)$$

[0099] 式中, t 为算法当前迭代次数, T 为最大迭代次数, k 、 u 为调节参数,经试验本发明选用 $k=2$, $u=2$ 。

[0100] 步骤四:最后在蝗虫个体位置更新处引入柯西变异操作。

[0101] 传统算法中蝗虫个体根据当前自身与种群间其他个体间的距离和最优个体的位置来更新下一步自身位置,在后期易陷入局部最优的问题,为此在蝗虫个体位置更新处添加柯西变异操作,变异后的蝗虫可以增加种群多样性,有助于算法跳出局部最优,寻找到新的最优解。根据柯西标准分布函数式(8),对最优个体构建柯西变异公式(9),变异后蝗虫个体位置更新公式为(10)所示:

$$[0102] \quad F(\lambda, 0, 1) = \frac{1}{\pi \cdot (1 + \lambda^2)} \quad (8)$$

$$[0103] \quad \widehat{T}_d^\xi = \widehat{T}_d \cdot \frac{1}{\pi \cdot \left(1 + \left(\frac{t}{T}\right)^2\right)} \quad (9)$$

$$[0104] \quad X_i^d = \begin{cases} c \left(\sum_{j=1, j \neq i}^N c \frac{ub^d - lb^d}{2} s\left(d_{ij}(t)\right) \frac{x_j^d(t) - x_i^d(t)}{d_{ij}(t)} \right) + \widehat{T}_d^\xi \cdot r, & r \leq p \\ c \left(\sum_{j=1, j \neq i}^N c \frac{ub^d - lb^d}{2} s\left(d_{ij}(t)\right) \frac{x_j^d(t) - x_i^d(t)}{d_{ij}(t)} \right) + \widehat{T}_d, & r > p \end{cases} \quad (10)$$

[0105] 式中: $x_i^d(t)$ 为算法迭代到第 t 次时第 d 维第 i 个蝗虫的位置, $x_j^d(t)$ 为算法迭代到第 t 次时第 d 维第 j 个蝗虫的位置, $d_{ij}(t)$ 是蝗虫种群在第 t 次迭代时第 i 个蝗虫和第 j 个蝗虫之间的距离, \widehat{T}_d 是当前最优个体位置, \widehat{T}_d^ξ 是经过柯西变异后的最优蝗虫位置, r 是(0,1)上的随机数, p 为变异概率,经试验选用 $p=0.7$ 。

[0106] 步骤五:利用IGOA优化ELM的参数,获得最优参数。

[0107] 其中利用IGOA优化ELM的参数,获得最优参数包括:

[0108] 步骤5.1:初始化相关算法参数:设置蝗虫种群数 N 、空间维度 D 、最大迭代次数 T 、搜索空间的上界 ub 、下界 lb 和当前迭代次数 $t=1$,并采用混沌理论初始化生成当前蝗虫所在的空间位置 X_i^d ;

[0109] 步骤5.2:通过公式(11)计算经过ELM网络训练的预测值 y_i 与训练样本实际值 t_i 的均方根误差,作为蝗虫适应度值 $fitness$,并且将当前适应度值最小的蝗虫位置保存到变量

\widehat{T}_d ;

$$[0110] \quad fitness = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2} \quad (11)$$

[0111] 步骤5.3:判断当前迭代次数t是否达到最大迭代次数T。若达到,则执行步骤S5,否则执行步骤S4;

[0112] 步骤5.4:通过调整参数控制策略公式(7)更新递减系数c,标准化蝗虫之间的距离于[1,4],柯西变异公式(9)和(10)更新蝗虫的位置,当前迭代次数 $t=t+1$,并返回ELM网络训练得到新的预测值,再根据公式(11)更新蝗虫的适应度值,与当前最优解进行比较,若优于当前最优解则更新 \widehat{T}_d ,否则执行步骤S3;

[0113] 步骤5.5:输出最优解 \widehat{T}_d ,并从中提取出ELM网络所需的输入层权重w和隐含层偏置b。

[0114] 步骤六:将获得的最优参数和测试数据样本输入到ELM预测模型中得到预测结果,并选取风电预测中常用的三种评价指标:均方根误差RMSE、平均绝对误差MAE和最大绝对值误差 E_{\max} ,对模型的预测性能进行评价。

[0115] 其中RMSE、MAE和 E_{\max} 三种评价指标公式分别为(12)~(14):

$$[0116] \quad RMSE = \frac{\sqrt{\sum_{i=1}^n (P_{ti} - P_{yi})^2}}{P_{cap} \cdot \sqrt{n}} \quad (12)$$

$$[0117] \quad MAE = \frac{\sum_{i=1}^n |P_{ti} - P_{yi}|}{P_{cap} \cdot n} \quad (13)$$

$$[0118] \quad E_{\max} = \max(|P_{ti} - P_{yi}|) \quad (14)$$

[0119] 式中:n为样本个数, P_{ti} 为i时刻的实际功率, P_{yi} 为i时刻的预测功率, P_{cap} 为风电场开机总容量。

[0120] 对获取到的数据进行预处理后,将前175h的1050个样本用于训练,后75h的450个样本用于预测,分别对未优化ELM、GOA-ELM和IGOA-ELM进行误差评价分析,结果如表1所示:

[0121] 表1

	模型	RMSE (%)	MAE (%)	E_{\max} (kW)
[0122]	未优化 ELM	19.72	16.97	10372.37
	GOA-ELM	17.70	14.42	8955.02
	IGOA-ELM	14.62	11.62	8444.38

[0123] 由表1可知,IGOA-ELM模型和GOA-ELM模型的RMSE、MAE及 E_{\max} 都比未优化ELM模型小,说明预测效果比未优化ELM模型好,提高了ELM模型预测精度,有效地对超短期风电功率进行了预测。

[0124] 本发明针对现有ELM预测模型存在参数难以确定,易陷入局部最优等技术问题,首先对GOA采用Cubic混沌映射方法初始化蝗虫的位置、构建基于正弦函数的调整参数控制策略的递减系数c和在蝗虫个体位置更新处添加柯西变异操作,使变异后的蝗虫可以增加种

群多样性,加快收敛速度,帮助算法跳出局部最优,寻找到新的最优解,增强算法可靠性,然后利用IGOA对ELM的参数进行优化,建立新的ELM预测模型,并以风电功率预测为实例,有效地对超短期风电功率进行了预测,验证了本发明的效果。

[0125] 本发明未作详细阐述的内容属于本专业领域技术人员公知的已有技术。

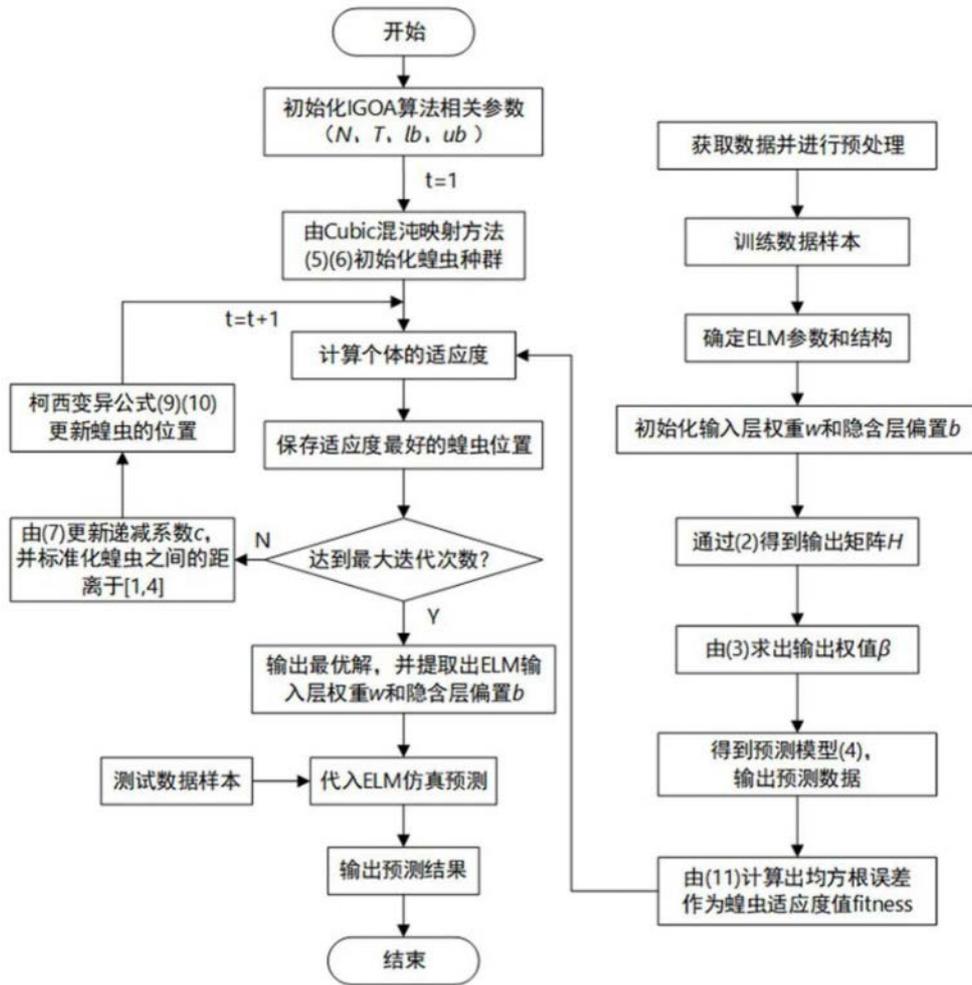


图1