

控制与决策

Control and Decision

融合柯西折射反向学习和变螺旋策略的 WSN 象群定位算法

余修武, 黄露平, 刘永, 李佩

引用本文:

余修武, 黄露平, 刘永, 李佩. 融合柯西折射反向学习和变螺旋策略的 WSN 象群定位算法[J]. 控制与决策, 2022, 37(12): 3183–3189.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.0315>

您可能感兴趣的其他文章

Articles you may be interested in

[多策略融合的改进麻雀搜索算法及其应用](#)

Improved sparrow search algorithm with multi-strategy integration and its application

控制与决策. 2022, 37(1): 87–96 <https://doi.org/10.13195/j.kzyjc.2021.0582>

[基于反向学习的群居蜘蛛优化 WSN 节点定位算法](#)

WSN node localization based on social spider optimization and opposition based learning

控制与决策. 2021, 36(10): 2459–2466 <https://doi.org/10.13195/j.kzyjc.2020.0258>

[混合柯西变异和均匀分布的蝗虫优化算法](#)

Hybrid Cauchy mutation and uniform distribution of grasshopper optimization algorithm

控制与决策. 2021, 36(7): 1558–1568 <https://doi.org/10.13195/j.kzyjc.2019.1609>

[嵌入 Circle 映射和逐维小孔成像反向学习的鲸鱼优化算法](#)

Whale optimization algorithm for embedded Circle mapping and one-dimensional oppositional learning based small hole imaging

控制与决策. 2021, 36(5): 1173–1180 <https://doi.org/10.13195/j.kzyjc.2019.1362>

[具有重组学习和混合变异的动态多种群粒子群优化算法](#)

Dynamic multi-population particle swarm optimization algorithm with recombined learning and hybrid mutation

控制与决策. 2021, 36(12): 2871–2880 <https://doi.org/10.13195/j.kzyjc.2020.0898>

融合柯西折射反向学习和变螺旋策略的 WSN 象群定位算法

余修武^{1,2,3†}, 黄露平¹, 刘永^{1,2,3}, 李佩¹

- (1. 南华大学 资源环境与安全工程学院, 湖南 衡阳 421001;
2. 铀矿冶放射性控制技术湖南省工程研究中心, 湖南 衡阳 421001;
3. 湖南省铀尾矿库退役治理工程技术研究中心, 湖南 衡阳 421001)

摘要: 针对现有无线传感器网络 (WSN) 优化算法在定位过程中收敛速率慢和误差大的问题, 提出一种基于柯西折射反向学习和变螺旋机制的象群节点定位算法. 首先, 利用具有遍历性和随机性的 Logistic 混沌映射初始化种群, 丰富种群多样性, 加快算法收敛速率. 然后, 将折射反向学习机制与柯西变异相融合以随机扰动族长位置, 避免算法陷入局部最优. 最后, 在氏族分离过程中引入自适应变螺旋策略更新病态大象位置, 提升算法全局搜索能力. 仿真结果表明, 与现有 WSN 优化算法相比, 所提出的改进象群优化算法在定位精度和收敛速率方面得到明显提升.

关键词: 无线传感器网络; 象群算法; 折射反向学习; 柯西变异; 变螺旋策略

中图分类号: TP273 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2021.0315

引用格式: 余修武, 黄露平, 刘永, 等. 融合柯西折射反向学习和变螺旋策略的 WSN 象群定位算法 [J]. 控制与决策, 2022, 37(12): 3183-3189.

Cauchy refraction opposition-based learning and variable helix mechanism of elephant herding localization algorithm in WSN

YU Xiu-wu^{1,2,3†}, HUANG Lu-ping¹, LIU Yong^{1,2,3}, LI Pei¹

- (1. School of Resource & Environment and Safety Engineering, University of South China, Hengyang 421001, China;
2. Hunan Province Engineering Technology Research Center of Uranium Tailings Treatment, Hengyang 421001, China;
3. Hunan Province Engineering Research Center of Radioactive Control Technology in Uranium Mining and Metallurgy, Hengyang 421001, China)

Abstract: Aiming at the problem of slow convergence and large errors in the positioning process of the existing wireless sensor network (WSN) optimization algorithm, this paper proposes a Cauchy refraction opposition-based learning and variable helix mechanism of elephant herding localization algorithm. Firstly, the population is initialized by using Logistic chaotic map with ergodicity and randomness to enrich the population diversity and accelerate the algorithm convergence rate. Secondly, the refraction opposition-based learning mechanism is combined with Cauchy mutation to randomly disturb the position of the patriarch to prevent the algorithm from falling into the local optimum. Finally, an adaptive variable helix strategy is introduced to update the position of ill elephants in the process of clan separation, which improves the global search ability. The simulation results show that the improved elephant herding optimization algorithm proposed in this paper has significantly improved positioning accuracy and convergence rate compared with the existing WSN optimization algorithm.

Keywords: wireless sensor network; elephant herding optimization; refraction opposition-based learning; Cauchy variation; variable helix strategy

0 引言

随着物联网技术的快速发展, 由大量低成本传感器以自组织和多跳方式构成的无线传感器网

络^[1-3](wireless sensor network, WSN) 在环境监测^[4-5]、卫星网络^[6]及智能电网^[7]等领域得以广泛应用. 在传感器节点进行数据采集和传输时需结合其自身

收稿日期: 2021-02-24; 录用日期: 2021-07-29.

基金项目: 湖南省重点研发计划项目 (2018SK2055); 国家自然科学基金项目 (11875164); 湖南省市联合自然科学基金项目 (2021JJ50093).

†通讯作者. E-mail: yxw2008xy@163.com.

位置信息以保证数据有效可靠. 因此, 定位技术作为 WSN 的核心技术具有十分重要的研究意义.

对未知节点进行定位时, 依据是否需要通过物理测量来获得节点间的距离或角度信息, 可将定位算法分为基于测距的定位算法和无需测距的定位算法. 基于测距的定位算法是依靠距离信息估计未知节点坐标, 定位误差较低, 但其通信成本较高, 不适用于大范围监测定位. 无需测距的定位算法利用网络连通性确定节点位置, 定位成本低. 常见的无需测距定位算法主要有: 质心算法、距离矢量定位算法^[8](distance vector-hop, DV-Hop)、近似三角形内点测试法^[9](approximate point-in-triangulation test, APIT)以及 Amorphous 算法^[10]等.

近年来, 由于计算复杂性增强, 具有机制灵活、求解高效等特点的启发式优化算法受到众多学者青睐. 在 WSN 定位过程中引入启发式优化算法, 可将节点定位问题转化为求解函数优化问题, 有效提升定位准确性. 文献[11]通过对测量的信号接收强度值进行拟合以得到信号传播模型, 从而得到未知节点与信标节点间的距离, 再利用天牛须算法对未知节点定位; 文献[12]针对无源时差定位问题, 采用樽海鞘群算法求解未知节点坐标, 有效提升了收敛速率; 文献[13]在根据优化目标建立数学模型的基础上, 利用修改步长和拒绝概率参数的改进布谷鸟搜索算法快速定位未知节点. 上述启发式优化算法与传统算法相比, 定位性能更优, 但大多算法的收敛速率和求解精度仍有待提升.

针对现有 WSN 定位优化算法定位误差大和收敛速率慢的问题, 本文提出一种融合柯西折射反向学习和变螺旋策略的象群定位算法(Cauchy refraction opposition-based learning and variable helix mechanism of elephant herding localization algorithm, CRHE). 利用 Logistic 混沌映射初始化种群, 使大象个体均匀遍历 WSN 搜索空间, 并将折射反向学习与柯西变异相结合对族长进行随机扰动, 提升算法寻优能力, 再采用变螺旋机制更新病态大象位置. 仿真结果表明, CRHE 算法相较传统优化算法有更佳的定位性能和寻优能力.

1 节点定位模型

作为 WSN 无需测距定位算法之一, Amorphous 算法利用节点间的跳段距离表示其直线距离, 从而得到节点坐标. 该算法可分为3个阶段.

1) 计算未知节点与各信标节点间的最小跳数.

信标节点将包含编号 ID、坐标以及跳数(初始化为0)的数据包发送至整个 WSN 网络中的邻居节点; 邻居节点接收并记录节点到每个信标节点间的最小跳数, 忽视同一信标节点跳数较大的数据包, 再将跳数加1之后转发至该节点的邻居节点. 重复以上步骤, 直至 WSN 网络中所有节点都获得信标节点坐标及到信标节点的跳数.

2) 计算平均跳距. 假设 WSN 网络中节点通信半径为 R , 由下式可得平均跳距 HopSize:

$$\text{HopSize} = R \left(1 + e^{-n_{\text{local}}} - \int_{-1}^1 e^{-\frac{n_{\text{local}}}{\pi} (\arccos t - t\sqrt{1-t^2})} dt \right), \quad (1)$$

$$n_{\text{local}} = N\pi R^2 / S. \quad (2)$$

其中: n_{local} 为网络连通度, N 为网络总节点数, S 为网络区域面积.

由此可得未知节点 i 与信标节点 j 间的距离

$$\text{Length}_{(i,j)} = \text{HopSize}_i \times \text{hop}_{(i,j)}. \quad (3)$$

其中: HopSize_i 为未知节点 i 的平均跳距, $\text{hop}_{(i,j)}$ 为未知节点 i 与信标节点 j 间的最小跳数.

3) 计算未知节点坐标. 利用极大似然估计法可得坐标为 (x_s, y_s) 的未知节点 s 到坐标为 (x_k, y_k) 的信标节点 $k(k = 1, 2, \dots, n)$ 的距离关系, 即

$$\begin{cases} (x_1 - x_s)^2 + (y_1 - y_s)^2 = d_1^2, \\ (x_2 - x_s)^2 + (y_2 - y_s)^2 = d_2^2, \\ \vdots \\ (x_n - x_s)^2 + (y_n - y_s)^2 = d_n^2. \end{cases} \quad (4)$$

将式(4)中的方程组化为矩阵形式 $\mathbf{AX} = \mathbf{B}$, 利用最小二乘法可得未知节点坐标, 即

$$\hat{\mathbf{X}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{B}. \quad (5)$$

极大似然估计法得到的未知节点与信标节点间的距离存在一定误差, 如下式所示:

$$|r_k - d_k| < \varepsilon_k. \quad (6)$$

其中: r_k 表示未知节点与信标节点间的实际距离; d_k 表示未知节点与信标节点间的计算距离; ε_k 表示节点间的测距误差.

由此, 可将 WSN 节点定位问题转换为函数约束优化问题, 测量误差目标函数, 即适应度函数 $f(x, y)$ 如下式所示:

$$f(x, y) = \min \left[\sum_{k=1}^n \left| \sqrt{(x_k - x)^2 + (y_k - y)^2} - d_k \right| \right], \quad (7)$$

其中 (x, y) 为未知节点的实际坐标. $f(x, y)$ 取最小值时,即可得未知节点的最优位置.

2 象群算法

象群算法(elephant herding optimization, EHO)是一种新型群体智能优化算法,其基本思想是利用自然界中大象畜牧行为的特性,以象群氏族为单位,由母象带领其氏族进行局部搜索,离开氏族的雄象执行全局探索,从而很好解决寻优问题.因此,象群算法主要分为两个步骤:氏族更新以及氏族分离.

2.1 氏族更新

随机初始化大象种群并将其划分为 n 个氏族,每个氏族中有 m 头大象,在迭代过程中大象个体 i 的位置会随该氏族女象族长的位置进行移动,如下式所示:

$$x_{\text{new},i} = x_i + \alpha \cdot (x_{\text{best}} - x_i) \cdot \gamma. \quad (8)$$

其中: $x_{\text{new},i}$ 为更新后大象 i 的位置; x_i 为上一代大象个体 i 的位置; x_{best} 为女象族长迭代 i 次后的位置; α 为女象族长对氏族中大象个体影响的比例因子,其取值范围为 $[0, 1]$; γ 为 $[0, 1]$ 上的随机数.

女象族长的位置受该氏族中心位置的影响,如下式所示:

$$x_{\text{best}} = \beta \cdot x_{\text{center}}, \quad (9)$$

$$x_{\text{center},j} = \sum_{i=1}^{n_k} x_{i,j} / n_k. \quad (10)$$

其中:权重因子 $\beta \in [0, 1]$; $x_{\text{center},j}$ 表示在 j 维空间中氏族的中心位置, $j \in [1, D]$, D 为空间维度; n_k 表示氏族大象数量.

2.2 氏族分离

雄性大象长大之后会离开氏族执行全局探索,适应度最差的病态大象会移动到新的位置进行随机搜索,其位置更新如下所示:

$$x_{\text{worst}} = x_{\text{min}} + \text{rand} \times \{x_{\text{max}} - x_{\text{min}} + 1\}. \quad (11)$$

其中: x_{max} 和 x_{min} 分别表示搜索空间的上下界, $\text{rand} \in [0, 1]$.

3 改进象群算法

3.1 混沌初始化

象群算法采用随机法初始化种群,使大象个体无法在搜索空间内均匀分布,从而导致算法在迭代初期寻优效果不佳,搜索速率降低.将具有遍历性和随机性特点的混沌映射引入象群算法,可以丰富种群多样性,提升收敛速度,并改善全局搜索能力.本文采用

Logistic混沌映射来初始化种群,其数学模型如下所示:

$$y_{s+1} = \mu y_s (1 - y_s). \quad (12)$$

其中: y_s 为第 s 次迭代产生的取值范围为 $[0, 1]$ 的混沌变量;控制参数 $\mu \in [0, 4]$,当 $\mu = 4$ 时,变量会遍历整个搜索空间,即系统处于完全混沌状态.在所有象群完成迭代后,对 y_s 进行逆映射可得初始化种群

$$x_s = L_s + (U_s - L_s)y_s, \quad (13)$$

其中 L_s 和 U_s 分别为搜索空间的上下界.

3.2 混合折射反向学习与柯西变异

在象群算法中,女象族长位置的更新依赖于每次迭代过程中氏族的更新,选取氏族最优适应度位置替代目标位置,并未主动对目标位置进行扰动更新,易使算法陷入局部极值.因此,本文提出一种折射反向学习与柯西变异混合策略以随机扰动目标位置,保持种群多样性,增强算法的寻优能力.

3.2.1 折射反向学习

反向学习的核心思想是通过比较当前解与其方向解,选择两者中的较优解引领下一代进行寻优,以减小陷入局部最优的概率.折射算法在迭代前期有较好的寻优效果,随着迭代次数的增加,其反向解亦可能陷入局部最优区域.结合光的折射原理而提出的折射反向学习(refracted opposition-based learning, ROBL)^[14]可在原有基础上有效扩大算法搜索空间,其原理如图1所示.




图1 折射反向学习原理

图1中,已知解在 x 轴上的搜索区间为 $[a, b]$,原点 o 为 $[a, b]$ 上的中点,法线为 y 轴,入射角和折射角分别为 α 和 β ,入射光线和折射光线的长度分别为 l 和 l^* .由此,可得折射率

$$n = \frac{\sin \alpha}{\cos \beta} = \frac{\frac{a+b}{2} - x}{x^* - \frac{a+b}{2}} \cdot \frac{l^*}{l}. \quad (14)$$

令 $\delta = l/l^*$,代入式(14)并将其拓展到多维空间

可得折射方向解

$$x_{i,j}^* = \frac{a_j + b_j}{2} + \frac{a_j + b_j}{2\delta} - \frac{x_{i,j}}{\delta}. \quad (15)$$

其中: $x_{i,j}$ 表示该氏族中第 i 头大象在 j 维上的位置, $x_{i,j}^*$ 表示 $x_{i,j}$ 的折射反向解, a_j 和 b_j 分别表示搜索空间在 j 维上的下界和上界.

在折射反向学习过程中,可通过调节 δ 和折射率 n 改变折射解的位置,从而跳出局部极值并向全局最优区域靠近.

3.2.2 柯西变异

柯西分布是一个数学期望不存在的连续型概率分布,其分布函数由峰值向两端缓慢降低,与 x 轴无限接近但不相交,使其能在短时间内对当前解进行扰动,快速搜索该区域内的优良解.将具有优秀全局搜索能力的柯西变异融入象群算法,优化族长位置,可避免算法过早收敛,提升全局搜索能力.标准柯西分布函数如下所示:

$$f(x) = \frac{1}{\pi(1+x^2)}. \quad (16)$$

求得当前最优解后,利用柯西变异算子对族长位置进行扰动,得到族长新位置

$$x_{\text{newbest}} = x_{\text{best}} + x_{\text{best}} \times \text{Cauchy}(0, 1). \quad (17)$$

3.2.3 混合机制

为了提升算法的寻优能力,等概率交替执行折射反向学习和柯西变异机制,对女象族长位置 $x_{\text{newbest},i}$ 进行动态更新,混合策略计算公式如下:

$$x_{\text{newbest},i} = \begin{cases} \frac{a+b}{2} + \frac{a+b}{2\delta} - \frac{x_i}{\delta}, & \lambda < 0.5; \\ x_{\text{best}} + x_{\text{best}} \times \text{Cauchy}(0, 1), & \lambda \geq 0.5. \end{cases} \quad (18)$$

其中 λ 为 $[0, 1]$ 上的随机数.

本文利用折射反向学习机制,拓宽算法搜索区域以发掘更多潜在最优解,提高算法寻优性能;通过柯西变异对族长位置进行随机扰动,可帮助算法跳出局部最优,提升算法搜索速率.为进一步提升 CRHE 算法的收敛精度,选用贪婪算法决定是否对族长位置进行更新.若变异后族长适应度优于原族长,则更新族长位置,反之则不更新族长位置.

3.3 自适应螺旋搜寻策略

针对象群算法全局搜索能力不足这一问题,受鲸鱼优化算法的启发,借鉴鲸鱼螺旋式搜寻猎物的过程,引入自适应螺旋搜寻策略改进象群中病态大象的位置,提升全局搜索能力.鲸鱼螺旋搜索模型如下所示:

$$\begin{cases} X_{t+1} = \hat{X}_t + D \cdot e^{np} \cos(2\pi p), \\ D = |2r \cdot \hat{X}_t - X_t|. \end{cases} \quad (19)$$

其中: X_{t+1} 为迭代搜寻 $t+1$ 次时的鲸鱼位置; \hat{X}_t 为全局最优位置; η 为决定螺旋形状的常数; p 和 r 均为区间 $[0, 1]$ 上均匀分布的随机数.

将螺旋搜索应用至病态大象位置更新之中,同时引入惯性权重 ω ,可在迭代后期逐渐增强族长影响力,使其快速收敛到最优位置,提升算法收敛速度.随迭代次数变化的惯性权重如下所示:

$$\omega_t = 0.2 \cos\left(\frac{\pi}{2} \cdot \left(1 - \frac{t}{t_{\text{max}}}\right)\right). \quad (20)$$

惯性权重 ω 随迭代次数的增加呈动态变化.在算法搜索初期,族长对病态大象影响较小,病态大象可充分进行全局搜索;在迭代中后期,族长对病态大象的影响力逐渐加强,使病态大象向最优位置靠近,加快收敛速率.

鲸鱼在每次螺旋搜索时是以固定螺旋路径向猎物靠近,易使其陷入局部最优.因此,将螺旋常数 η 改进为随迭代次数而变化的参数,动态调整螺旋形状,以拓宽象群全局搜索区域,从而提升算法全局搜索能力.变螺旋参数 η^* 模型如下所示:

$$\eta^* = e^{5 \cos\left(\pi \cdot \left(1 - \frac{t}{t_{\text{max}}}\right)\right)}. \quad (21)$$

由式(21)可知,随着迭代次数的增加,螺旋形状随之减小.算法初期时病态大象在尽可能大的区域进行全局搜索,在迭代后期则逐渐逼近最优解,使算法全局搜索能力和寻优精度均有提升.因此,病态大象的位置更新如下式所示:

$$x_{\text{worst}} = \omega_t \cdot x_{\text{best}} + \eta^* \cdot D \cdot e^p \cos(2\pi p). \quad (22)$$

3.4 CRHE算法描述

本文利用反向学习与柯西变异相混合机制以及自适应螺旋策略对象群算法进行改进,并提出基于柯西折射反向学习和变螺旋机制的 WSN 象群定位算法 CRHE. CRHE 算法主要有以下几个步骤:

step 1: 在 $M \times M$ 的区域里随机布设 n 个未知节点,信标节点个数为 N . 信标节点向周围广播包含自身 ID 及坐标的数据包.

step 2: 未知节点接收来自通信范围内各信标节点的广播,并记录信标节点 ID 和坐标.

step 3: 未知节点利用信标节点位置信息,根据式(4)、(6)以及(7)生成未知节点估计坐标及适应度函数 $f(x, y)$,将其作为初始值代入 CRHE 算法.

CRHE 算法流程如图 2 所示.

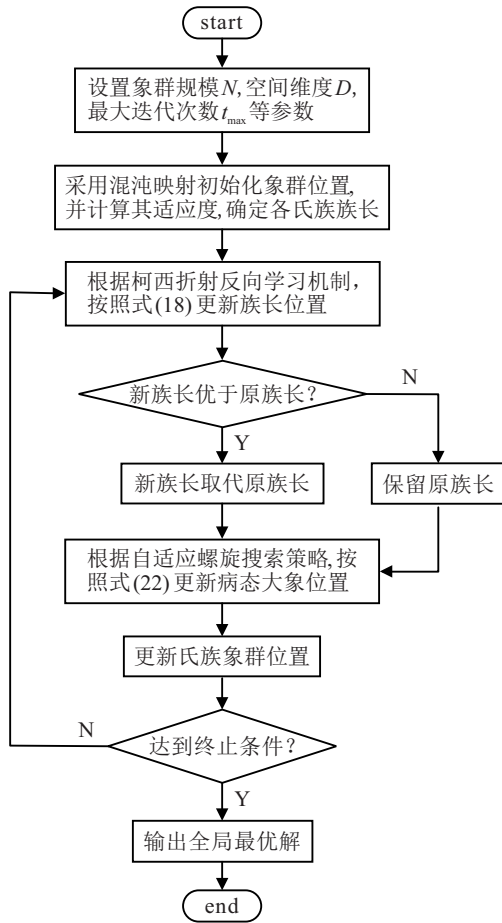


图2 CRHE算法流程

3.5 算法时间复杂度分析

假定参数初始化(种群规模为 N , 空间维度为 n) 执行时间为 c_1 , 产生均匀分布的时间为 c_2 , 求得适应度函数所需时间为 $f(n)$, 可得象群算法初始阶段的时间复杂度如下所示:

$$O(c_1 + N(nc_2 + f(n))) = O(n + f(n)). \quad (23)$$

设大象个体、族长以及病态大象在每一维位置更新所需时间相同, 都为 c_3 , 迭代后比较优劣和择优更新时间分别为 c_4 和 c_5 , 则象群算法在寻优阶段的时间复杂度如下所示:

$$O(N(nc_3 + f(n) + c_4) + c_5) = O(n + f(n)). \quad (24)$$

因此, 象群算法求解每代最优解的时间总复杂度为

$$T(n) = O(n + f(n)) + O(n + f(n)) = O(n + f(n)). \quad (25)$$

在CRHE算法中, 初始化阶段时间复杂度与象群算法基本相同. 假设在寻优阶段大象个体位置更新时间为 e_1 , 折射反向学习和柯西变异混合机制更新族长位置时间为 e_2 , 新族长与原族长择优比较时间为 e_3 , 自适应变螺旋策略更新病态大象位置时间为 e_4 , 则该阶段的时间复杂度如下所示:

$$O(N(ne_1 + f(n) + c_4) + c_5 + N(e_2 + e_4) + e_3) = O(n + f(n)). \quad (26)$$

因此, CRHE算法求解每一代最优解的时间总复杂度为

$$T(n) = O(n + f(n)) + O(n + f(n)) = O(n + f(n)). \quad (27)$$

综上所述, CRHE算法相较象群算法在时间复杂度上一致.

4 仿真结果与分析


为验证CRHE算法的有效性, 通过Matlab软件对算法进行模拟仿真, 并与WSN中经典粒子群算法^[15](particle swarm optimization, PSO)、人工蜂群算法^[16](artificial bee colony, ABC)、灰狼优化算法^[17](grey wolf optimizer, GWO)以及EHO算法进行对比. 在 $50\text{ m} \times 50\text{ m}$ 的仿真区域内, 以式(7)为目标函数估计节点位置, 并利用归一化平均定位误差 error 对算法性能进行评价, 如下所示:

$$\text{error} = \sum_{i=1}^Q \sqrt{(x_i - \bar{x}_i)^2 + (y_i - \bar{y}_i)^2} / Q. \quad (28)$$


其中: Q 是节点总数, (x_i, y_i) 是未知节点实际坐标, (\bar{x}_i, \bar{y}_i) 是未知节点估计坐标.

4.1 迭代次数仿真

设CRHE算法中象群有6个氏族, 每个族群中有10头大象. 同样, 设定PSO、ABC、GWO和EHO算法的种群规模为60, 迭代50次. 经仿真实验可得, 各算法迭代次数与平均适应度及平均定位误差的关系如图3所示.



(a) 平均适应度与迭代次数的关系



(b) 平均定位误差与迭代次数的关系

图3 迭代次数仿真

从图3可以看出:在5种算法中,ABC算法收敛速率相对较快,大约迭代15次后收敛,但求解精度最差,平均适应度值和定位误差分别收敛于4.21和2.29 m; PSO算法、GWO算法及EHO算法均在迭代20次左右收敛,而CRHE算法在迭代10次左右收敛,在这5种算法中拥有最快的收敛速度; PSO算法、GWO算法和EHO算法的平均适应度值最终分别收敛于3.12、3.18和3.87,均高于CRHE算法的收敛平均适应度值2.91; CRHE算法的平均定位误差收敛于1.74 m,而PSO算法、GWO算法与EHO算法的平均定位误差则分别收敛于1.82 m、1.76 m和1.83 m. 因此,本文提出的CRHE算法与ABC算法、PSO算法、GWO算法及EHO算法4种算法相比,有更快的收敛速率和更优的定位精度.

4.2 种群数量对定位精度的影响

假设在仿真区域内随机布设100个传感器节点,任意两节点都能实现相互通信,信标节点比例为15%,节点通信半径为20 m,迭代次数为50. 在仿真实验中改变算法种群规模可得到种群数量对算法定位精度的影响,如图4所示.




图4 种群数量与定位误差的关系

从图4可以看出,随着种群规模加大,节点定位误差呈下降趋势. 其中CRHE算法在种群数量达到60左右时基本达到稳定状态,当种群数量达到100之后,其余4种算法的定位误差无明显变化. 同时,当改变种群数量各算法定位误差趋于稳定时,CRHE算法在5种算法中拥有更低的误差值. 由此可见,在寻优过程中,CRHE算法能以较快速率实现高精度定位.

4.3 信标节点数量对定位精度的影响

在仿真区域内布设100个未知节点,设置信标节点数从5变化至30,通信半径定为20 m,迭代50次. 通过改变信标节点数量可得到各算法的定位误差变化曲线,如图5所示.

从图5可以看出,5种算法的定位误差均随着信标节点数量的增加而逐渐减小,且CRHE算法在不同信标节点数量条件下的定位误差明显低于其余




图5 信标节点数与定位误差的关系

算法. CRHE算法的定位误差最终收敛于0.33 m,与ABC算法、PSO算法、GWO算法和EHO算法相比,其定位精度分别提升了65.9%、35.3%、28.3%和37.7%. 同时,当信标节点比例达到15%左右时,CRHE算法最先趋于稳定.

4.4 节点通信半径对定位精度的影响

在仿真区域内布设100个未知节点,25个信标节点,将通信半径从10 m递增至40 m,得到各个算法的定位误差对比如图6所示.




图6 通信半径与定位误差的关系

随着节点通信半径的增加,WSN网络的连通范围拓宽,算法的定位误差也随之降低. 从图6可以看出,CRHE算法的整体定位误差明显小于其余4种算法,当节点通信半径达到20 m时,CRHE算法的定位误差不再明显变化. 在相同通信半径条件下,CRHE算法定位误差最小,其次为PSO算法、GWO算法、EHO算法,其中定位误差最大的为ABC算法.

4.5 节点总数对定位精度的影响

设置节点通信半径为20 m,信标节点数为20(包含于节点总数内),迭代次数为50. 图7对比了100个未知节点时,各算法在不同节点总数下的定位误差.




图7 节点总数与定位误差的关系

从图7可以看出,5种算法的定位误差均随着传感器节点总数的增加而逐渐减小,且CRHE算法的定位精度明显优于其余4种算法。CRHE算法的平均定位误差为0.37 m,相较于ABC算法、PSO算法、GWO算法及EHO算法的平均定位误差0.93 m、0.51 m、0.47 m和0.59 m,分别减小了60.2%、27.5%、21.3%和37.3%,进一步表明了CRHE算法有更高的定位精度和稳定性。

5 结论

针对启发式优化算法在WSN定位过程中求解精度不高和搜索速率较低的问题,本文提出了一种基于柯西折射反向学习和变螺旋机制的WSN象群定位算法。首先,在Amorphous节点定位模型的基础上利用Logistic混沌映射得到初始化种群;然后,将折射方向与柯西变异相结合引入至象群算法中,使族长位置受全局最优解影响,避免陷入局部最优;最后,通过嵌入惯性权重的变螺旋机制更新病态大象位置,使算法全局搜索能力得以提升。仿真实验表明,在未增加时间复杂度的情况下,CRHE算法与现有WSN优化算法相比拥有更高的搜索速率和定位精度。

参考文献(References)

- [1] Prashar D, Jyoti K. Distance error correction based hop localization algorithm for wireless sensor network[J]. *Wireless Personal Communications*, 2019, 106(3): 1465-1488.
- [2] Yu X W, Zhou L X, Li X Y. A novel hybrid localization scheme for deep mine based on wheel graph and chicken swarm optimization[J]. *Computer Networks*, 2019, 154: 73-78.
- [3] Kalaivani S, Tharini C. Analysis and implementation of novel Rice Golomb coding algorithm for wireless sensor networks[J]. *Computer Communications*, 2020, 150: 463-471.
- [4] Durante G, Beccaro W, Peres H. IoT protocols comparison for wireless sensors network applied to marine environment acoustic monitoring[J]. *IEEE Latin America Transactions*, 2018, 16(11): 2673-2679.
- [5] Preethi K, Tamilarasan R. Monitoring of air pollution to establish optimal less polluted path by utilizing wireless sensor network[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2021, 12(6): 6375-6386.
- [6] Kuruba P, Dushyantha N D. Polygon based topology formation and information gathering in satellite based wireless sensor network[J]. *Wireless Personal Communications*, 2020, 115(1): 203-237.
- [7] 孙伟, 余浩, 杨建平, 等. 智能电网可靠性需求约束下无线发射功率模型预测控制[J]. *电力系统自动化*, 2020, 44(3): 185-193.
(Sun W, Yu H, Yang J P, et al. Model predictive control of wireless transmit power constrained by reliability requirement of smart grid[J]. *Automation of Electric Power Systems*, 2020, 44(3): 185-193.)
- [8] Kanwar V, Kumar A. DV-Hop-based range-free localization algorithm for wireless sensor network using runner-root optimization[J]. *The Journal of Supercomputing*, 2021, 77(3): 3044-3061.
- [9] 余修武, 余昊, 刘永, 等. 基于加权混合滤波和重心法的APIT定位算法[J]. *北京邮电大学学报*, 2019, 42(4): 32-37.
(Yu X W, Yu H, Liu Y, et al. APIT location algorithm based on weighted hybrid filtering and center of gravity method[J]. *Journal of Beijing University of Posts and Telecommunications*, 2019, 42(4): 32-37.)
- [10] Hu W, Yuan S N. Amorphous localization algorithm optimized by genetic tabu search[J]. *Chinese Journal of Sensors and Actuators*, 2019, 32(6): 940-944.
- [11] Liu Y, Qian Z H, Jia D. Universal localization algorithm based on beetle antennae search in indoor environment[J]. *Journal of Electronics & Information Technology*, 2019, 41(7): 1565-1571.
- [12] Chen T, Wang M X, Huang X S. Time difference of arrival passive location based on salp swarm algorithm[J]. *Journal of Electronics & Information Technology*, 2018, 40(7): 1591-1597.
- [13] Li N, Jia W. Localization of cuckoo algorithm in wireless sensor network[J]. *Journal of Data Acquisition and Processing*, 2020, 35(2): 315-321.
- [14] Zhao F Q, Zhang L X, Zhang Y, et al. An improved water wave optimisation algorithm enhanced by CMA-ES and opposition-based learning[J]. *Connection Science*, 2020, 32(2): 132-161.
- [15] 黄越洋, 张嗣瀛, 井元伟, 等. 基于TDOA和RSS的可行域粒子滤波非视距定位算法[J]. *控制与决策*, 2017, 32(8): 1415-1420.
(Huang Y Y, Zhang S Y, Jing Y W, et al. Non-line of sight localization algorithm based on TDOA and RSS by feasible region particle filter[J]. *Control and Decision*, 2017, 32(8): 1415-1420.)
- [16] Bansal J C, Gopal A, Nagar A K. Stability analysis of artificial bee colony optimization algorithm[J]. *Swarm and Evolutionary Computation*, 2018, 41: 9-19.
- [17] Yan F, Xu J Z, Yun K. Dynamically dimensioned search grey wolf optimizer based on positional interaction information[J]. *Complexity*, 2019, 2019: 1-36.

作者简介

余修武(1976—),男,教授,博士,从事智能监测系统研究, E-mail: yxw2008xy@163.com;

黄露平(1997—),女,硕士生,从事无线传感器网络定位技术的研究, E-mail: 853561165@qq.com;

刘永(1971—),男,教授,博士生导师,从事退役放射性尾矿库监测及治理等研究, E-mail: liuyong81668@163.com;

李佩(1995—),男,硕士生,从事无线传感器网络路由算法的研究, E-mail: 1808291529@qq.com.