

# 控制与决策

Control and Decision

## 基于反向学习的群居蜘蛛优化WSN节点定位算法

余修武, 张可, 刘永, 肖人榕

引用本文:

余修武, 张可, 刘永, 等. 基于反向学习的群居蜘蛛优化WSN节点定位算法[J]. *控制与决策*, 2021, 36(10): 2459–2466.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0258>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 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>

### 基于局部搜索的反向学习竞争粒子群优化算法

Opposition-based learning competitive particle swarm optimizer with local search

*控制与决策*. 2021, 36(4): 779–789 <https://doi.org/10.13195/j.kzyjc.2019.1150>

### 基于虚拟力移动锚节点的3D-DVHop-ACR定位算法

3D-DVHop-ACR localization algorithm based on virtual force moving anchor nodes

*控制与决策*. 2021, 36(10): 2409–2417 <https://doi.org/10.13195/j.kzyjc.2020.0323>

### 基于超级节点的分布式传感器节点定位算法

A distributed sensor nodes localization algorithm based on super nodes

*控制与决策*. 2020, 35(12): 2898–2906 <https://doi.org/10.13195/j.kzyjc.2019.0219>

# 基于反向学习的群居蜘蛛优化 WSN 节点定位算法

余修武<sup>1,2†</sup>, 张可<sup>1</sup>, 刘永<sup>1,2</sup>, 肖人榕<sup>1</sup>

- (1. 南华大学 资源环境与安全工程学院, 湖南 衡阳 421001;  
2. 湖南省铀尾矿库退役治理技术工程技术研究中心, 湖南 衡阳 421001)

**摘要:** 针对启发优化算法在 WSN 节点定位问题中定位精度不高和收敛速度较慢的缺陷, 提出基于反向学习的群居蜘蛛优化 WSN 节点定位算法. 为减少前期随机搜索, 所提出算法首先通过 Bounding-box 方法得到未知节点可能存在的区域, 在该区域初始化启发个体, 并将加权中心反向学习策略与群居蜘蛛群优化算法相结合, 求解未知节点估计位置, 提高算法全局搜索能力. 仿真结果表明, 相比于传统算法, 所提出算法收敛速度更快, 节点定位精度更高.

**关键词:** 无线传感器网络; 节点定位; 群居蜘蛛优化; 反向学习; Bounding-box 方法; 启发算法

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0258

开放科学(资源服务)标识码(OSID):



**引用格式:** 余修武, 张可, 刘永, 等. 基于反向学习的群居蜘蛛优化 WSN 节点定位算法[J]. 控制与决策, 2021, 36(10): 2459-2466.

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

YU Xiu-wu<sup>1,2†</sup>, ZHANG Ke<sup>1</sup>, LIU Yong<sup>1,2</sup>, XIAO Ren-rong<sup>1</sup>

- (1. School of Resource & Environment and Safety Engineering, University of South China, Hengyang 421001, China;  
2. Hunan Engineering Research Center for Uranium Tailings Decommission and Treatment, Hengyang 421001, China)

**Abstract:** To improve the weakness of low localization accuracy and slow rate of convergence in the heuristic-based node localization algorithm, WSN node localization based on social spider optimization and opposition based learning is proposed. For reducing random search in the previous stage, a strategy of Bounding-box is firstly performed by determining a square area where the heuristic individual will be initialized. Then weighted center opposition based learning is introduced to original social spider optimization to find the best-estimated location of nodes and improve the global searching ability. Simulation results show that compared with the traditional algorithm, the proposed algorithm has faster convergence speed and higher node localization accuracy.

**Keywords:** wireless sensor network; node localization; social spider optimization; opposition based learning; Bounding-box method; heuristic algorithm

## 0 引言

无线传感器网络(WSN)是由许多价格低廉的传感器节点组成的具有低功耗、自组织的分布式传感网络,已经广泛应用于环境监测、医疗、军事等领域<sup>[1]</sup>. 获取精确节点位置信息有助于对监测区域中的突发事件进行事前预警、事中决策与事后处理<sup>[2]</sup>. 此外,许多路由协议都是在获取所有节点地理位置信息的前提下运行,因此 WSN 节点定位技术具有十分重要的意义.

目前,WSN 节点定位算法主要分为两类:一类是

基于测距的定位算法(range-based),另一类是基于非测距的定位算法(range-free)<sup>[3]</sup>. 其中非测距定位算法主要依靠网络的连通性间接确定未知节点位置,通信与能耗开销较低,但定位精度受节点布置密度与均匀度的影响很大<sup>[4]</sup>. 基于测距的定位算法主要是利用距离信息来估算未知节点的位置,其定位精度与测距方法的准确度有关. 基于测距的定位算法中主要的测距方法有信号强度指示(RSSI)、到达时间(TOA)、到达时间差(TDOA)<sup>[5-6]</sup>等,其中基于 RSSI 的测距方法,由于实现简单且无需额外硬件设施的特

收稿日期: 2020-03-09; 修回日期: 2020-06-11.

基金项目: 国家自然科学基金项目(11875164); 湖南省重点研发计划项目(2018SK2055); 国家应急管理部安全生产重特大事故防治关键技术科技项目(hunan-0001-2018AQ); 湖南省研究生科研创新项目(CX20190721).

†通讯作者. E-mail: yxw2008xy@163.com.

性受到了广泛关注. 许多研究人员在基于RSSI定位算法方面做了许多工作, 如文献[7]将压缩感知理论应用到节点定位中, 利用网格代表节点的位置, 将节点位置的RSSI矩阵视为稀疏信号, 再利用压缩感知对信号进行重构得到其位置, 但是信号重构的精准度无法保证, 导致误差较大; 文献[8]提出利用双定位标签减少RSSI波动的影响, 构造优化函数求解最优位置, 但该方法需要额外的硬件设备, 增加了定位的成本. 文献[9]通过RSSI的测距信息利用Bounding-box方法确定边界, 在该边界中细分网格逐一搜索确定估计位置, 该方法的定位精度受到网格大小的影响, 较小的网格划分能提高定位精度, 但同时也会增加算法的计算量. 文献[10]改进了牛顿高斯迭代法以求解节点位置, 有效地减少了迭代的计算量, 但在高噪声环境下定位精度较差. 近些年来, 随着计算能力的提升, 启发优化算法引起了广泛的关注, 不少研究人员将其应用于WSN节点定位问题中, 如文献[11]建立求解位置的目标函数, 利用鸡群优化算法(CSO)求解最优节点估计位置. 文献[12]改进布谷鸟优化算法求解未知节点估计位置, 提高了算法的收敛速度与求解精度. 文献[13]根据信标节点的测量模型和视距传播概率建立目标函数, 并利用粒子群算法求解最优位置. 上述基于启发优化算法的节点方法将节点定位问题转化为优化问题并建立目标函数, 利用启发优化算法求解节点最优估计位置, 相较于传统算法有更优的定位表现, 但大多算法依然存在收敛速度较慢、求解精度低的问题.

针对目前启发优化算法在WSN节点定位问题中存在收敛速度慢以及求解精度较低的问题, 本文提出基于反向学习的群居蜘蛛优化WSN节点定位算法. 所提出算法首先利用Bounding-box方法确定初始搜索区域, 减少前期随机搜索, 并将加权反向学习策略与群居蜘蛛算法相结合, 求解节点估计位置, 提高算法求解能力. 仿真结果表明, 所提出算法能有效减少前期不必要的随机搜索, 求解的收敛速度和节点的定位精度均优于传统方法.

## 1 测距与定位模型

距离是影响无线信号强度(received signal strength indicator, RSSI)的主要因素之一, 节点以相同的信号发射功率发送信号时, 距离越大信号强度越小, 反之则信号强度越大. 在WSN中, 节点之间的通信载体为无线信号, 节点可利用信号接收器获取其通信范围内其他节点的RSSI, 不需要额外的硬件设备. 因此, 利用RSSI测距是一种简单廉价的测距方

法. 不考虑噪声条件下, 根据信号衰减对数模型, 距离为 $d$ 时接收信号强度为

$$P(d) = P(d_0) - 10\eta \lg\left(\frac{d}{d_0}\right). \quad (1)$$

其中:  $P(d_0)$ 为参考距离 $d_0$ 处的信号强度值,  $\eta$ 为只与环境因素相关的路径衰减指数.

设节点 $S_i$ 的位置未知, 其通信范围内有 $m$ 个锚节点, 坐标为 $(x_j, y_j)$ ,  $j = 1, 2, \dots, m$ , 测量得到 $S_i$ 与各锚节点 $S_j$ 的RSSI值, 根据信号传播模型得到估计距离 $d_{ij}$ , 那么未知节点 $S_i$ 的估计位置 $(\hat{x}_i, \hat{y}_i)$ 为

$$\arg \min_{(\hat{x}_i, \hat{y}_i)} \sum_{j=1}^m (\sqrt{(\hat{x}_i - x_j)^2 + (\hat{y}_i - y_j)^2} - d_{ij})^2. \quad (2)$$

## 2 定位算法的设计与实现

### 2.1 Bounding-box 确定搜索区域

Bounding-box算法的基本思想是通过测量与未知节点的距离, 利用距离确定未知节点可能存在的矩形区域, 最后以所有矩形区域的重叠部分质心作为未知节点的估计位置. 该算法虽然简单容易实现, 但其定位精度相对较低. 文献[14]提出利用Bounding-box方法初始化启发优化算法个体来提高收敛速度, 避免定位过程中的翻转歧义现象, 但由于测距误差的影响, 未知节点真实位置可能会落在Bounding-box区域之外, 降低了收敛速度与求解精度. 为了避免该现象, 本文通过多次信号测量与补偿测量距离改进Bounding-box方法, 确定搜索区域. 在搜索区域中初始化启发算法个体, 提高收敛速度与求解精度. 假设未知节点通信范围内有 $m$ 个锚节点, 不考虑测距误差, 可以得到未知节点坐标 $(x_i, y_i)$ 满足下式

$$\begin{cases} x_i \in [x_j - d_{ij}, x_i + d_{ij}], \\ y_i \in [y_j - d_{ij}, y_i + d_{ij}], \end{cases} \quad (3)$$

其中 $j = 1, 2, \dots, m$ . 改进Bounding-box方法确定搜索区域过程如图1所示.




图1 搜索区域的确定

图1中,  $d_{1i}$ 、 $d_{2i}$ 、 $d_{3i}$ 分别为锚节点1、2、3与未知节点 $i$ 的RSSI测量距离. 由于RSSI非常容易受到外

界干扰,即使在位置不变的情况下节点接收到的发射功率也存在跳变现象,导致 $d_{ij} < d_{ij\_real}$ ( $d_{ij\_real}$ 为节点 $i, j$ 的真实距离),此时未知节点真实位置可能位于矩形边框之外. 为了避免这种现象,本文通过多次测量结合统计理论中的置信区间降低 $d_{ij} < d_{ij\_real}$ 现象的概率. 许多工作证明RSSI的测量误差服从高斯分布,因此可以通过多次测量得到测距均值与误差,进一步求得置信区间. 假设通过 $n$ 次测量得到节点 $i, j$ 的距离为 $\{\hat{d}_1, \hat{d}_2, \dots, \hat{d}_n\}$ , 距离样本的均值和标准差分别为

$$\bar{d}_{ij} = \frac{\sum_{k=1}^n \hat{d}_k}{n}, \quad (4)$$

$$\sigma_d = \sqrt{\frac{\sum_{k=1}^n (\hat{d}_k - \mu d_{ij})^2}{n}}. \quad (5)$$

根据式(4)和(5)可以得到95%的置信区间大小, 补偿后的边界距离为

$$d_{ij\_c} = \bar{d}_{ij} + 1.96 \frac{\sigma}{\sqrt{n}}. \quad (6)$$

最后以补偿后的边界作为测量距离, 根据Bounding-box方法得到未知节点搜索区域.

## 2.2 群居蜘蛛优化算法

群居蜘蛛优化算法是一种新颖的生物启发优化算法. 该算法模拟群居蜘蛛之间的协作行为, 将搜索空间类比为蜘蛛网, 生成雌性、雄性两类蜘蛛搜索个体, 按照不同的搜索准则在空间进行搜索, 有效避免了个体在优势群体周围聚集而陷入局部最优, 通过婚配行为进行信息交换产生新个体, 最终实现寻优的目的<sup>[15]</sup>. SSO算法的基本步骤如下.

**step 1:** 蜘蛛种群参数设定. 设蜘蛛群体总数量为 $N$ , 雌性蜘蛛的数量 $N_f$ 和雄性蜘蛛的数量 $N_m$ 可计算为

$$\begin{cases} N_f = \text{floor}[(0.9 - \text{rand} \times 0.5) \times N], \\ N_m = N - N_f. \end{cases} \quad (7)$$

其中:  $\text{rand}$ 为 $[0, 1]$ 之间的随机数,  $\text{floor}$ 为取整数部分.

**step 2:** 种群初始化. 设求解空间有 $D$ 个维度, 蜘蛛群体由雄性子种群 $\text{SM} = \{\text{SM}_1, \text{SM}_2, \dots, \text{SM}_{N_m}\}$ 和雌性子种群 $\text{SF} = \{\text{SF}_1, \text{SF}_2, \dots, \text{SF}_{N_f}\}$ 组成, 通过随机的方式初始化所有蜘蛛位置, 如下所示:

$$\begin{cases} \text{SM}_{ij} = \text{lb}_j + \text{rand} \times (\text{ub}_j - \text{lb}_j), \\ \text{SF}_{ij} = \text{lb}_j + \text{rand} \times (\text{ub}_j - \text{lb}_j). \end{cases} \quad (8)$$

其中:  $\text{ub}_j, \text{lb}_j$ 分别为求解空间在 $j(j \in \{1, 2, \dots, D\})$ 维度的上界和下界. 根据所有蜘蛛的位置可以计算

婚配半径为

$$r = \frac{\sum_{j=1}^D (\text{SP}_j^{\max} - \text{SP}_j^{\min})}{2D}. \quad (9)$$

其中:  $\text{SP}$ 为全体蜘蛛种群, 由所有雄性蜘蛛和雌性蜘蛛组成,  $\text{SP} = [\text{SF}, \text{SM}]$ ;  $\text{SP}_j^{\max}, \text{SP}_j^{\min}$ 分别为蜘蛛种群在第 $j$ 维的最大值与最小值.

**step 3** 雌性蜘蛛个体位置迭代. 雌性蜘蛛个体之间通过震动传递信息, SSO算法通过模拟震动吸引或排斥其他个体. 在最小值优化问题中, 个体 $\text{FS}_i$ 权重为 $\omega_i$ , 其对个体 $\text{FS}_c$ 的震动感知能力计算如下:

$$\omega_i = \frac{J(\text{FS}_i) - \text{worst}(J)}{\text{best}(J) - \text{worst}(J)}, \quad (10)$$

$$\text{vib}_{c,i} = \omega_i e^{-d_{ci}^2}. \quad (11)$$

其中:  $J(\text{FS}_i)$ 为蜘蛛 $\text{FS}_i$ 的目标函数值,  $\text{worst}(J)$ 为种群中目标函数最大值,  $\text{best}(J)$ 为种群中目标函数最小值,  $d_{ci}$ 为蜘蛛个体 $\text{FS}_i$ 与 $\text{FS}_c$ 的距离.

雌性蜘蛛个体迭代通过下式进行:

$$\text{SF}_i^{T+1} = \begin{cases} \text{SF}_i^T + \alpha \text{vib}_{c,i} (\text{SP}_c - \text{SF}_i^T) + \\ \beta \text{vib}_{b,i} (\text{SF}_b - \text{SF}_i^T) + \delta (\text{rand} - 0.5), \text{rand} \leq \text{PF}; \\ \text{SF}_i^T - \alpha \text{vib}_{c,i} (\text{SP}_c - \text{SF}_i^T) - \\ \beta \text{vib}_{b,i} (\text{SF}_b - \text{SF}_i^T) + \delta (\text{rand} - 0.5), \text{otherwise.} \end{cases} \quad (12)$$

其中:  $\alpha, \beta, \delta$ 和 $\text{rand}$ 为 $[0, 1]$ 之间的随机数,  $T$ 为迭代次数,  $\text{SP}_c$ 为距离个体 $\text{SF}_i$ 最近且高于其权重的蜘蛛个体,  $\text{SF}_b$ 为雌性子种群中权重最高的个体.

**step 4:** 雄性蜘蛛个体位置迭代. 在雄性子种群中存在两类蜘蛛, 一类是雄性支配蜘蛛, 另一类是雄性非支配蜘蛛. 支配蜘蛛具有吸引与其靠近的雌性蜘蛛的能力, 非支配雄性蜘蛛则有向支配蜘蛛中心靠近的趋势, 通过下式模拟两类雄性蜘蛛行为:

$$\text{SM}_i^{T+1} = \begin{cases} \text{SM}_i^T + \gamma \left( \frac{\sum_{k=1}^{N_m} \text{SM}_k^T \times \omega_k}{\sum_{k=1}^{N_m} \omega_k} \right), \omega_k \leq \omega_{\text{mid}}; \\ \text{SM}_i^T + \gamma \text{vib}_{f,i} (\text{SF}_f - \text{SM}_i^T) + \delta (\text{rand} - 0.5), \\ \text{otherwise.} \end{cases} \quad (13)$$

其中:  $\text{SF}_f$ 为距离 $\text{SM}_i$ 最近的雌性蜘蛛,  $\gamma$ 与 $\delta$ 为 $[0, 1]$

之间的随机数,  $\omega_{\text{mid}}$  为雄性蜘蛛群体权重的中位数.

step 5: 婚配行为. 在所有个体迭代完成后雌性支配个体将进行婚配行为. 雄性支配个体婚配半径  $r$  内的所有雌性蜘蛛按照权重  $\omega$  分配婚配概率  $P_m$ , 如下所示:

$$P_m = \frac{\omega_{\text{FS}_i}}{\sum \omega}. \quad (14)$$

由式(14)得到所有婚配雌性个体概率, 根据概率在每个维度上按照轮盘赌的方式选取婚配对象, 新个体在该维度的值即为选中雌性蜘蛛在该维度的值. 得到新个体后, 计算其适应度值, 若优于父代, 则替换父代中适应度值较劣的个体. 最后判断是否达到迭代终止条件, 若达到条件则输出最优个体, 否则进入下一轮迭代.

### 2.3 加权中心反向学习策略

反向学习 (opposition-based learning, OBL) 策略在 2005 年由 Tizhoosh<sup>[16]</sup> 提出, 该策略广泛应用于各类算法中, 有效提高了求解全局最优的效率<sup>[17]</sup>. 反向学习策略的基本思想为: 在搜索过程中, 同时考虑初始位置与其相对于中心的反向位置, 增强群体个体的多样性, 进而提高算法的全局搜索能力. 定义点  $P = (p^1, p^2, \dots, p^d)$  为  $D$  维空间的一点,  $p^d \in [p_{\text{min}}^d, p_{\text{max}}^d]$ ,  $p_{\text{min}}^d, p_{\text{max}}^d$  分别为点  $P$  在维度  $d$  的最小值和最大值, 则点  $P$  的反向点在维度  $d$  上的值为

$$\hat{p}^d = p_{\text{min}}^d + p_{\text{max}}^d - p^d. \quad (15)$$

文献[18]提出, 搜索群体以均值混合中心作为反向学习的对称中心, 引导种群进化, 其中均值混合中心以全部搜索个体平均值与部分较优个体平均值的适应度较优值所确定. 由于混合均值中心位于群体的中心位置, 在搜索过程中可以整合个体位置, 前期促使群体向中心靠拢, 加快收敛速度, 收敛后能帮助个体跳出群体最优, 从而有更大概率搜索到全局最优解. 受其思想的启发, 本文提出加权中心反向学习策略, 其基本思想为: 对种群中全部个体根据其适应度值给定权重, 根据权重与个体位置计算得到群体的加权中心, 以加权中心作为反向学习的对称中心. 由于考虑了所有个体的适应度值, 加权中心更能反应群体在当前环境的集中趋势. 因此, 本文以加权中心作为反向学习的对称中心来引导种群进化.

在求解 WSN 定位问题中, 个体的适应度值  $J(\text{SP}_i)$  为目标函数值, 求解加权中心时个体权重计算如下:

$$W_i = \frac{1}{J(\text{SP}_i)} / \sum_{i=1}^m \frac{1}{J(\text{SP}_i)}. \quad (16)$$

加权中心在维度  $d$  上的值计算如下:

$$\bar{C}^d = \sum_{i=1}^m W_i \cdot \text{SP}_i^d. \quad (17)$$

其中  $\text{SP}_i^d$  为个体  $i$  在维度  $d$  上的值.

与式(15)原理类似, 通过式(18)计算得到点  $P$  在维度  $d$  上以加权中心为对称点的反向点位置, 即

$$\bar{p}^d = k(\bar{C}^d - p^d) + \bar{C}^d. \quad (18)$$

其中:  $p^d$  为点  $P$  在  $d$  维度上的值,  $\bar{p}^d$  为点  $P$  经过加权中心反向学习后在维度  $d$  上的值,  $k \in [0, 1]$  为动态学习因子.

加权中心反向学习如图2所示, 点  $P$  为搜索个体位置, 点  $O$  为加权中心. 若动态学习因子  $k$  越小, 则反向学习点越靠近点  $O$ , 如  $P_1$ ; 若  $k$  越大, 则反向学习点以点  $P$  对称方向远离点  $O$ , 如  $P_2$ . 因此,  $k$  值越小, 加权反向学习的探索范围越小, 集中在加权中心  $O$  附近, 反之探索范围越大.




图2 加权中心反向学习

### 2.4 OLSSO算法描述

利用加权中心反向学习策略改进 SSO 算法, 并提出基于反向学习的群居蜘蛛优化 WSN 节点定位算法 (OLSSO). 算法主要由以下步骤组成.

step 1: 在网络部署后, 锚节点周期性向周围广播, 广播数据中包含节点 ID、地理位置等.

step 2: 未知节点接收来自各锚节点的广播数据, 并保存锚节点 ID、地理位置、接收数据包的 RSSI 强度值信息, 记录接收来自该锚节点数据包的次数.

step 3: 若节点接收到锚节点数据次数达到预设值, 则通过式(4)和(6)得到 Bounding-box 区域, 根据信号强度值计算与各锚节点的估计距离  $\bar{d}_{ij}$ .

step 4: 在 Bounding-box 区域中初始化搜索个体, 通过加权中心反向学习策略改进的 SSO 算法求解最佳估计位置. 求解过程中启发个体  $s$  的适应度函数为

$$J(s) = \frac{1}{m} \sum_{i=1}^m (\bar{d}_{ij} - d_{ij})^2. \quad (19)$$

其中:  $m$  为锚节点个数,  $d_{ij}$  为启发个体到各锚节点的距离. 改进 SSO 算法流程如图3所示.

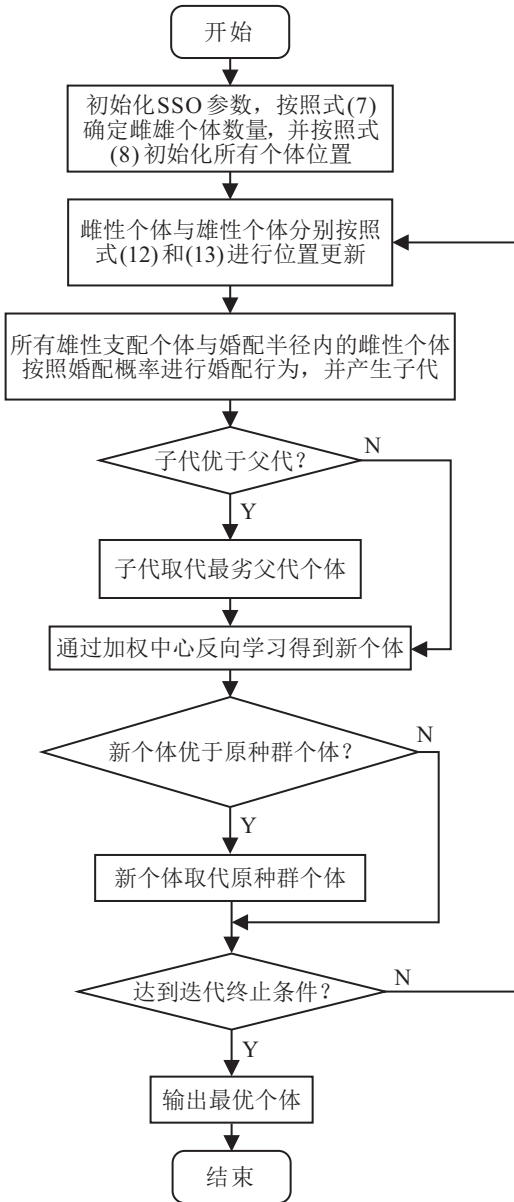


图3 算法流程

2.5 算法时间复杂度分析

时间复杂度间接反应了算法执行的时间长短. 在SSO算法中, 假设初始化参数(在种群规模为 $N$ , 空间维度为 $n$ 的条件下)所需要的执行时间为 $x_1$ , 产生均匀分布的时间为 $x_2$ , 求适应度值所需时间为 $f(n)$ , 则SSO算法初始阶段的时间复杂度为

$$O(x_1 + N(nx_2 + f(n))) = O(n + f(n)). \quad (20)$$

设雌性和雄性个体每一维度迭代更新需要的执行时间相同, 均为 $x_3$ , 迭代后比较优劣和择优的时间为 $x_4$ , 计算婚配半径 $r$ 的时间为 $x_5$ , 婚配过程的时间消耗为 $x_6$ , 则该阶段算法的时间复杂度为

$$O(N(nx_3 + f(n)) + x_4 + x_5 + x_6) = O(n + f(n)). \quad (21)$$

所以, SSO算法求解每一代最优的总时间复杂度为

$$T(n) = O(n + f(n)) + O(n + f(n)) = O(n + f(n)). \quad (22)$$

在改进SSO算法中, 算法初始化阶段所需的时间与SSO算法基本一致, 因此改进算法初始化阶段的时间复杂度与式(20)相同. 在算法循环部分, 假设加权中心的计算时间为 $z_1$ , 个体加权反向中心学习位置的计算时间为 $z_2$ , 学习个体与初始个体的比较择优过程计算时间为 $z_3$ , 则该循环部分的时间复杂度为

$$O(N(nx_3 + f(n)) + x_4 + x_5 + x_6 + N(z_2 + z_3) + z_1) = O(n + f(n)). \quad (23)$$

因此, 改进SSO算法求解每一代最优的总时间复杂度为

$$T(n) = O(n + f(n)) + O(n + f(n)) = O(n + f(n)). \quad (24)$$

综上所述, 改进SSO算法的改进策略相对于初始SSO算法没有增加算法求解的时间复杂度.

3 仿真实验与分析

3.1 信号模型与参数设置

仿真中传感器节点信号衰减模型采用带噪声的对数模型, 即

$$P(d) = P(d_0) - 10\eta \lg\left(\frac{d}{d_0}\right) + N_\sigma. \quad (25)$$

其中:  $N_\sigma$  为均值是0, 标准差是 $\sigma$ 的高斯随机噪声,  $\eta$  为路径衰减指数,  $d_0$  为参考距离,  $P(d_0)$  为参考距离下接收的信号强度. 此外, 采用平均定位误差(mean localization error, MLE)评价定位算法的性能, 有

$$MLE = \frac{1}{n} \sum_{i=1}^n \sqrt{(x - \hat{x})^2 + (y - \hat{y})^2}. \quad (26)$$

在Matlab平台进行仿真实验, 对比迭代次数、锚节点个数、信号噪声与测量次数对算法定位效果的影响. 假设整个布置区域内任意两个节点都能互相通信, 实验默认参数设置如表1所示.

表1 实验参数设置

参数名称	取值
仿真区域	50m×50m
锚节点数量	6 ~ 16
待定位节点数量	200
参考距离 $d_0$ /m	1
参考距离信号强度 $P(d_0)$ /dbm	-15
信号测量次数	5 ~ 20
信号噪声标准差 $\sigma$	0.5 ~ 4
启发个体数量	10
迭代次数	30
动态学习因子 ( $k$ )	1

### 3.2 实验结果与分析

为了验证所提出算法的有效性,将所提出的基于反向学习的群居蜘蛛优化定位算法(OLSSO)与经典的遗传算法(GA)、人工蜂群算法(ABC)、粒子群优化算法(PSO)和群居蜘蛛优化算法(SSO)进行对比. 算法均以式(19)为目标函数估计节点位置.

设置锚节点数量为10,信号测量次数为5次,信号噪声标准差 $\sigma$ 为1,迭代次数为50次. 图4对比了不同动态学习因子 $k$ 对算法求解的影响,图5和图6分别对比了不同算法的迭代次数对平均适应度与平均定位误差(MLE)的影响.




图4 动态学习因子 $k$ 对算法求解的影响




图5 迭代次数与平均适应度




图6 迭代次数与平均定位误差

由图4可见,算法的平均适应度值随着迭代的进行不断减少, $k$ 较小时算法收敛速度较慢,如当 $k = 0.25$ 时,算法经35次迭代逐渐收敛,平均适应度最终

收敛于2.4左右. 而当 $k = 1$ 时,算法在20次迭代后收敛,平均适应度最终收敛于1.8左右. 这主要是因为求解的目标函数在全局最优附近存在较多的局部最优,当 $k$ 较小时,反向学习策略主要在靠近加权中心点附近区域搜索,容易使大量启发搜索个体陷入局部最优,导致搜索收敛速度较慢;当 $k$ 较大时,反向学习策略促使搜索个体在加权中心周围更广区域进行搜索求解,避免大量启发搜索个体落入局部最优,提高了算法的全局最优的求解能力.

由图5和图6可见,所有算法中GA算法在迭代10次左右收敛,收敛速度最快,但求解精度最差,平均适应度值和平均定位误差最终分别收敛于3.98和2.19. ABC算法、PSO算法和SSO算法都在25次左右的迭代后收敛,而所提出的OLSSO算法在15次左右的迭代后收敛,收敛速度最快. OLSSO算法的平均适应度值收敛于1.86,优于GA算法的3.98,ABC算法的1.95,PSO算法的1.91和SSO算法的1.91. OLSSO算法的平均定位误差收敛于0.84,相比于GA算法的2.19,ABC算法的0.91,PSO算法的0.88和SSO算法的0.86定位精度更高. OLSSO算法更优的求解能力,一方面是因为Bounding-box方法能快速确定节点所在区域,减少了算法前期不必要的搜索;另一方面是因为加权中心反向学习策略提高了算法全局最优的求解能力.

设置锚节点数量为6~16,信号测量次数为5次,信号噪声标准差 $\sigma$ 为1. 图7对比了在不同锚节点数量条件下不同算法的平均定位误差. 由图7可见,算法的平均定位误差随着锚节点数量的增加而降低,并且在所有锚节点数量相同的条件下平均定位误差最小的为OLSSO算法,其次分别为SSO算法、PSO算法、ABC算法,定位效果最差的是GA算法. 此外,所有算法的平均定位误差都随着锚节点数量的增加而逐渐降低,这主要是因为更多的锚节点能提供更多的定位信息. 因此,可以通过适当增加锚节点的数量提高算法定位的精度.

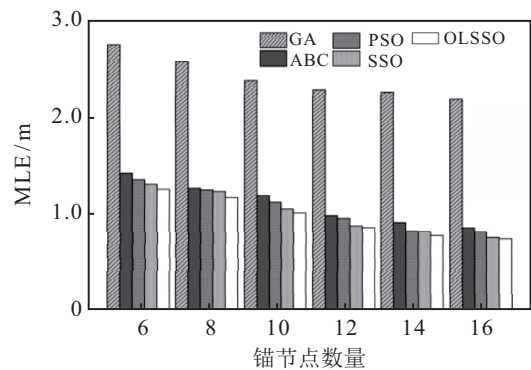


图7 锚节点数量与平均定位误差

设置测量次数为5次,图8对比了SSO算法与OLSSO算法在不同信号噪声条件下200个待定位节点定位误差的分布情况。由图8可见,随着噪声的增加,SSO与OLSSO的定位误差逐渐增加,其中OLSSO的定位误差与中位数都低于SSO,因此OLSSO在定位精度上优于SSO。在噪声较小时两种算法的箱体

大小相当,噪声较大时OLSSO的箱体宽度小于SSO,OLSSO的四分位距较小,因此所提出定位算法的鲁棒性相较于SSO更优。

设置噪声标准差为2和4,测量次数分别为10和20次。图9对比了SSO算法与OLSSO算法的误差累计曲线(cumulative distribution function, CDF)。由图9可见,在相同测量次数下,OLSSO的CDF曲线始终在SSO的上方,在相同测量次数条件下OLSSO算法的定位精度优于SSO。其他因素不变,测量次数为20次的CDF曲线始终在测量次数为10次的上方,为了提高算法的定位精度,特别在信号噪声较大的环境中,可以适当增加测量次数来提高定位精度。

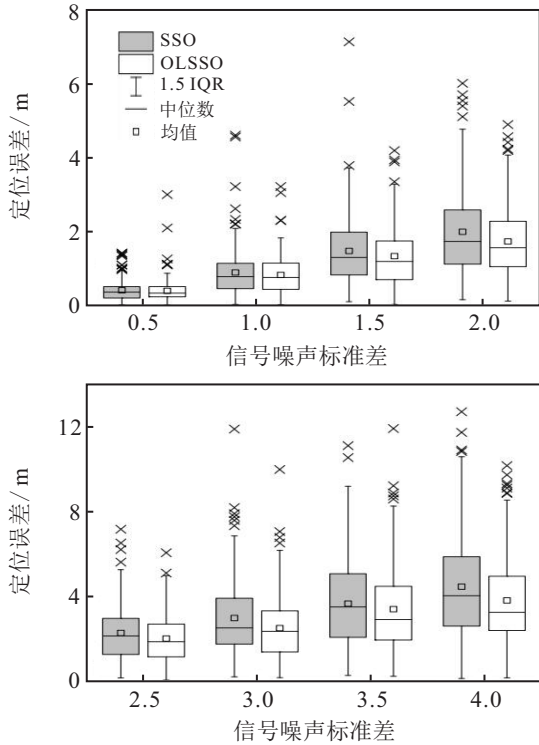


图8 信号噪声与误差

### 4 结论

本文针对启发优化算法在WSN节点定位问题中定位精度不高和收敛速度较慢的缺陷,提出了基于反向学习的群居蜘蛛优化WSN节点定位算法。为减少前期随机搜索,所提出算法首先通过Bounding-box方法得到未知节点可能存在的区域,在该区域初始化启发个体,并将加权中心反向学习策略与群居蜘蛛群优化算法相结合,求解未知节点估计位置,提高算法全局搜索能力。仿真结果表明,相比于传统算法,所提出算法收敛速度更快,节点定位精度更高。

### 参考文献(References)

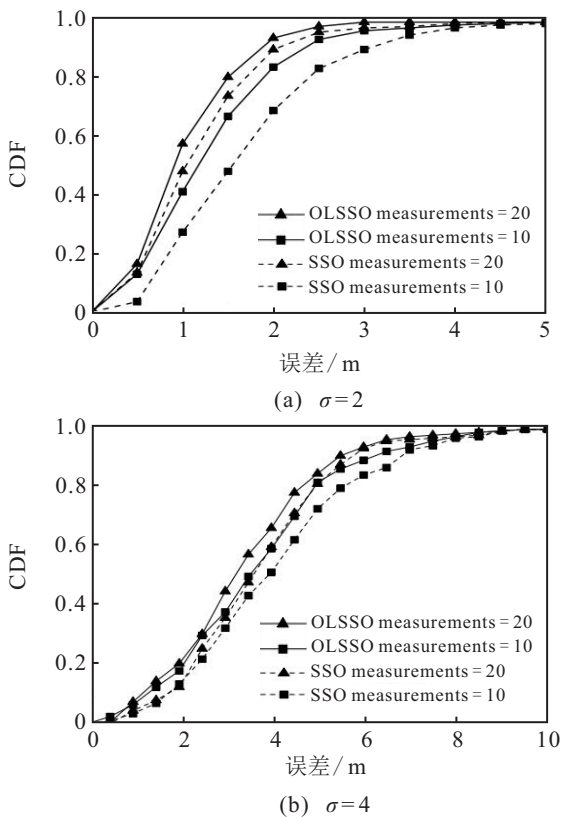


图9 误差累积曲线

[1] 余修武, 张枫, 范飞生, 等. WSN铀尾矿库核污染监测GAF交圆改进型路由[J]. 电子科技大学学报, 2017, 46(6): 825-829.  
(Yu X W, Zhang F, Fan F S, et al. An improved routing algorithm based on intersecting circle and GAF for uranium tailings nuclear pollution monitoring in WSN[J]. Journal of University of Electronic Science and Technology of China, 2017, 46(6): 825-829.)

[2] 钱志鸿, 孙大洋, Leung V. 无线网络定位综述[J]. 计算机学报, 2016, 39(6): 1237-1256.  
(Qian Z H, Sun D Y, Leung V. A survey on localization model in wireless networks[J]. Chinese Journal of Computers, 2016, 39(6): 1237-1256.)

[3] Fresno José, Guillermo R, Martínez-Tarifa Juan, et al. Survey on the performance of source localization algorithms[J]. Sensors, 2017, 17(11): 2666-2691.

[4] Yang X, Xiong L, Weiping W, et al. Efficient DV-HOP localization for wireless cyber-physical social sensing system: A correntropy-based neural network learning scheme[J]. Sensors, 2017, 17(12): 135-152.

[5] Abouzar P, Michelson D G, Hamdi M. RSSI-based distributed self-localization for wireless sensor networks used in precision agriculture[J]. IEEE Transactions on

- Wireless Communications, 2016, 15(10): 6638-6650.
- [6] 邵小强, 李康乐, 陈熙, 等. 基于改进卡尔曼滤波和参数拟合的矿井TOA定位方法[J]. 煤炭学报, 2019, 44(5): 1616-1624.  
(Shao X Q, Li K L, Chen X, et al. MTOA positioning method of coalmine based on Kalman filter and parameter fitting[J]. Journal of China Coal Society, 2019, 44(5): 1616-1624.)
- [7] Wei Y, Li W, Chen T. Node localization algorithm for wireless sensor networks using compressive sensing theory[J]. Personal and Ubiquitous Computing, 2016, 20(5): 809-819.
- [8] 胡青松, 曹灿, 吴立新, 等. 面向矿井目标的双标签高精度定位方法[J]. 中国矿业大学学报, 2017, 46(2): 437-442.  
(Hu Q S, Cao C, Wu L X, et al. A dual-tag high precision localization method for coal mine objects[J]. Journal of China University of Mining & Technology, 2017, 46(2): 437-442.)
- [9] 姚英彪, 曾嵘, 易志强. 基于边框定界的WSN分布式全搜索定位算法[J]. 通信学报, 2012, 33(Z2): 135-140.  
(Yao Y B, Cao R, Yi Z Q. Bounding box based distributed search localization algorithm for WSN[J]. Journal on Communications, 2012, 33(Z2): 135-140.)
- [10] Müller C, Alves D I, Uchôa-Filho B F, et al. Improved solution for node location multilateration algorithms in wireless sensor networks[J]. Electronics Letters, 2016, 52(13): 1179-1181.
- [11] Shayokh M A, Shin S Y. Bio inspired distributed WSN localization based on chicken swarm optimization[J]. Wireless Personal Communications, 2017, 97(4): 5691-5706.
- [12] Jing C, Linyuan X. An effective cuckoo search algorithm for node localization in wireless sensor network[J]. Sensors, 2016, 16(9): 1390-1407.
- [13] 刘韵婷, 张嗣瀛, 井元伟. 基于粒子群优化的无线传感器网络非视距节点定位算法[J]. 控制与决策, 2015, 30(6): 1106-1110.  
(Liu Y T, Zhang S Y, Jing Y W. Non-line of sight node localization algorithm based on particle swarm optimization for wireless sensor networks[J]. Control and Decision, 2015, 30(6): 1106-1110.)
- [14] Li D, Wen X B. An improved PSO algorithm for distributed localization in wireless sensor networks[C]. International Conference on Software. Tianjin: IET, 2014: 4-6.
- [15] Erik Cuevas, Miguel Cienfuegos, Daniel Zaldívar, et al. A swarm optimization algorithm inspired in the behavior of the social-spider[J]. Expert Systems with Applications, 2013, 40(16): 6374-6384.
- [16] Tizhoosh H R. Opposition-based learning: A new scheme for machine intelligence[J]. International Conference on Computational Intelligence for Modelling. Piscataway: IEEE, 2005: 695-701.
- [17] Wang H, Wu Z, Rahnamayan S, et al. Enhancing particle swarm optimization using generalized opposition-based learning[J]. Information Sciences, 2011, 181(20): 4699-4714.
- [18] 孙辉, 邓志诚, 赵嘉, 等. 混合均值中心反向学习粒子群优化算法[J]. 电子学报, 2019, 47(9): 1809-1818.  
(Sun H, Deng Z C, Zhao J, et al. Hybrid mean center opposition-based learning particle swarm optimization[J]. Acta Electronica Sinica, 2019, 47(9): 1809-1818.)

### 作者简介

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

张可(1997—), 男, 硕士生, 从事无线传感器网络节点定位的研究, E-mail: zhangkeblue@163.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、尾矿库安全等研究, E-mail: liuyong81668@163.com;

肖人榕(1994—), 男, 硕士生, 从事无线传感器网络路由算法的研究, E-mail: 173423985@qq.com.

(责任编辑: 郑晓蕾)