

文章编号:1007-5321(2023)01-0090-07

DOI:10.13190/j.jbupt.2021-319

临时优劣重心反向融变的麻雀优化 WSN 定位算法

余修武, 商亚东, 刘永

(南华大学 资源环境与安全工程学院, 衡阳 421001)

摘要: 针对群智能优化算法在无线传感器网络 (WSN) 定位问题中迭代效率慢和容易陷入局部最优等问题, 提出了临时优劣重心反向融变的麻雀优化 WSN 定位算法。该算法利用节点估计距离构建盒子模型, 初步确定节点的位置区域, 缩小了前期的搜寻区域范围; 利用 Circle 混沌映射初始化种群, 使种群分布更加均匀; 并提出临时优劣重心反向学习策略, 在充分利用种群的搜索经验的同时也保持了种群的多样性; 结合融变策略使算法更容易跳出局部最优, 提高了全局搜寻的效率。仿真实验表明, 所提算法在定位精度和收敛效率方面均有较好的效果。

关键词: 无线传感器网络; 定位算法; 临时优劣重心; 麻雀搜索算法

中图分类号: TP212.9

文献标志码: A

WSN Localization Algorithm Based on Temporary Best and Worst Centroid Opposite Cross Mutation and Sparrow Optimization

YU Xiuwu, SHANG Yadong, LIU Yong

(School of Resource Environment and Safety engineering, University of South China, Hengyang 421001, China)

Abstract: To solve the issues of that swarm intelligence optimization algorithm has low iterative efficiency and is easy to fall into local optimum in wireless sensor network (WSN) localization, WSN localization algorithm is proposed based on temporary best and worst centroid opposite cross mutation and sparrow optimization. The algorithm uses the estimated distance of nodes to build a box model, determine the location area of the initial node, and narrow the scope of the previous search area, The Circle chaotic map is used to initialize the population and make the population distribution more uniform. A reverse learning strategy of temporary best and worst centroid is proposed to make full use of the search experience of the population while maintaining the diversity of the population. By combining the cross mutation strategy, the proposed algorithm is easier to jump out of the local optimum, which improves the efficiency of global search. The simulation results show that the proposed algorithm has better positioning accuracy and convergence efficiency.

Key words: wireless sensor network; location algorithm; temporary best and worst centroid; sparrow search algorithm

无线传感器网络 (WSN, wireless sensor network) 是一种可应用于复杂环境中的网络^[1], 与传统的网

络相比, WSN 的布置成本较低且具有强抗毁性, 因此可有效地解决复杂环境的监测问题。在整个网络

收稿日期: 2021-12-21

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

作者简介: 余修武 (1976—), 男, 教授, 硕士生导师。

通信作者: 商亚东 (1997—), 男, 硕士生, 邮箱: 497222015@qq.com。

中,精确的节点位置信息能优化网络的路由结构,均衡网络能耗,且有助于监测系统及时发现问题,并进行决策和处理。如果大批量部署带有定位模块的节点,将会提高整个网络的部署成本,所以如何利用有限的已知位置信息的锚节点来获取未知节点的位置信息是目前研究的一大热点。

目前 WSN 定位技术分为测距技术和非测距技术^[2]。测距技术是指根据传感器网络中已知位置信息的锚节点,通过接收的信号强度指示(RSSI, received signal strength indicator)、到达时间、到达时间差等信息估算其他未知节点的位置。非测距技术是指利用网络的拓扑结构和网络的连通度来估算距离,但估算的距离与网络的拓扑结构有很大的关系,误差较大。众多学者基于以上两种方法做了很多创新和改进工作。任克强等^[3]利用修正的 RSSI 和多节点协作定位的方法进行节点定位,但此方法利用已定位节点进行协作定位,会导致随后的节点误差逐渐积累。乐燕芬等^[4]利用指纹位置和 RSSI 值相结合减小了定位的误差,但在构建指纹库时,算法的计算量较大,增加了网络的能耗。林维维等^[5]利用校正矢量来优化 DV-Hop(distance vector-hop)协议,但算法在求解伪距离的过程中,求解的误差会随着节点稀疏度的增加而增大。尹雨晴等^[6]利用随机游走策略优化非测距定位协议,在大规模密集节点区域,该算法具有良好的定位性能,但前期随机性太强,不利于对稀疏节点的定位。

近年来,随着群智能优化算法的发展,有学者将其应用在 WSN 定位问题中。李昂等^[7]将模糊聚类和猫群算法相结合应用于室内定位中,提高了算法求解速度和精度。常鲁杰等^[8]提出了一种迭代粒子群优化的水下 WSN 节点自定位算法,引入几何约束来限制粒子群初始种群范围,提高了求解最优值的效率。上述研究中均利用群智能优化算法来求解定位问题,但算法中依然存在容易陷入局部最优、收敛速度较慢和求解精度低等问题。

综上所述,针对目前群智能优化算法在 WSN 节点定位中的问题,提出了一种临时优劣重心反向融变的麻雀优化 WSN 定位算法。该算法通过构建盒子模型,初步确定未知节点的大概区域;利用 Circle 混沌映射初始化种群,使种群分布更加均匀;提出临时优劣重心反向融变策略,充分利用种群的搜索经验的同时也保持了种群的多样性,提高了对区域全局搜寻的效率。仿真实验表明,所提算法在定位精

度和收敛效率方面均有较好的效果。

1 算法模型

1.1 测距定位模型

WSN 中传感器节点均可利用天线接收来自其他节点的 RSSI 值,然后根据节点间的 RSSI 值来计算两者间的距离,距离为 R 时接收到的 RSSI 值为

$$P(R) = P(R_0) - 10\theta \lg \left(\frac{R}{R_0} \right) + X_\sigma(\mu, \sigma^2) \quad (1)$$

其中: R_0 为参考距离, $P(R_0)$ 为参考节点接收到的 RSSI 值, θ 为路径损耗衰减因子, $X_\sigma(\mu, \sigma^2)$ 为均值为 μ 、方差为 σ^2 的高斯随机噪声。

设未知节点的坐标为 (x_i^u, y_i^u) ,通信范围内有 m 个锚节点,坐标为 (x_j^k, y_j^k) , $j = 1, 2, \dots, m$,测量得到未知节点与各锚节点的 RSSI 值,根据式(1)得第 i 个未知节点到第 j 个锚节点的估计距离 R_{ij} ,则第 i 个未知节点的估计位置为

$$\arg \min \frac{1}{m} \sum_{j=1}^m (\sqrt{(x_i^u - x_j^k)^2 + (y_i^u - y_j^k)^2} - R_{ij})^2 \quad (2)$$

1.2 盒子区域模型

利用 RSSI 值所求得距离具有一定误差,为了均衡误差,采用平均估计距离建立盒子区域模型。计算 n 次第 i 个未知节点和第 j 个锚节点之间的估计距离,并计算距离平均值为

$$\bar{R}_{ij} = \frac{1}{n} \sum_{a=1}^n R_{ij}^a \quad (3)$$

其中 R_{ij}^a 为第 a 次测量得到的估计距离。

第 i 个未知节点盒子区域表示为

$$\left. \begin{aligned} X_{\min} &= x_j^k - R_{ij}^{\max} \\ X_{\max} &= x_j^k + R_{ij}^{\max} \\ Y_{\min} &= y_j^k - R_{ij}^{\max} \\ Y_{\max} &= y_j^k + R_{ij}^{\max} \end{aligned} \right\} \quad (4)$$

$$(x_i^u, y_i^u) \in ((X_{\min}, Y_{\max}), (Y_{\min}, Y_{\max})) \quad (5)$$

其中: R_{ij}^{\max} 为最大距离值, X_{\min} , X_{\max} , Y_{\min} 和 Y_{\max} 为盒子区域边界,盒子区域构建如图 1 所示。

图中 R_{i1}^{\max} , R_{i2}^{\max} , R_{i3}^{\max} 为未知节点到锚节点的最大估计距离,但 RSSI 值容易受到外界干扰,随计算次数的增加,仍会有可能导致准确值落在盒子区域之外。RSSI 的测量误差服从正态分布,利用距离平均值 \bar{R}_{ij} 并结合统计学中置信区间修正盒子区域半径,考虑到出现概率较低,将置信度设置为 90%,最




图1 盒子搜索区域

后利用修正半径重新定义盒子区域,修正半径为

$$R_{ij-m} = R_{ij}^{\max} + \frac{1.64}{n} \sqrt{\sum_{a=1}^n (R_{ij}^a - \bar{R}_{ij})^2} \quad (6)$$

2 改进麻雀搜索算法

2.1 麻雀搜索算法

麻雀搜索算法 (SSA, sparrow search algorithm) 是根据自然界中麻雀群体的觅食和反捕行为而提出的一种新型群智能优化算法^[9],根据算法规则,发现者位置更新方式为

$$S_{ad}^{t+1} = \begin{cases} S_{ad}^t \exp\left(-\frac{\alpha}{\tau z}\right), & S_R < S_T \\ S_{ad}^t + Q, & S_R > S_T \end{cases} \quad (7)$$

其中: S_{ad}^t 为第 t 代第 α 个发现者的第 d 维位置, τ 为 $(0,1]$ 中的随机数, z 为最大迭代次数, S_R 为预警值, S_T 为安全值, Q 为服从正态分布的随机数。

跟随者位置更新方式为

$$S_{\beta d}^{t+1} = \begin{cases} Q \exp\left(\frac{S_{wd}^t - S_{\beta d}^t}{\alpha^2}\right), & \beta > \frac{1}{2}(N+P) \\ S_{\beta d}^t + \frac{1}{D} \sum_{d=1}^D (\text{rand} \{-1,1\}) |S_{\beta d}^t - S_{bd}^t|, & \text{其他} \end{cases} \quad (8)$$

其中: $S_{\beta d}^t$ 为第 t 代第 β 个跟随者的第 d 维位置, S_{wd}^t 为第 d 维全局最差位置, S_{bd}^t 为第 d 维全局最优位置, N 为麻雀种群数量, P 为当前发现者的个数, D 为个体位置总维度。

监察者位置更新方式为

$$S_{\eta d}^{t+1} = \begin{cases} S_{bd}^t + Q |S_{\eta d}^t - S_{bd}^t|, & f_{\eta} > f_b \\ S_{\eta d}^t + k \left(\frac{|S_{\eta d}^t - S_{wd}^t|}{(f_{\eta} - f_w) + \varepsilon} \right), & f_{\eta} = f_b \end{cases} \quad (9)$$

其中: $S_{\eta d}^t$ 表示第 t 代第 η 个监察者的第 d 维位置, f_{η} 为第 η 个监察者适应度值, f_b 为全局最优适应度值, f_w 为全局最差适应度值, k 为 $[-1,1]$ 中的随机数, ε 为趋近于0的值。

经过多次测试,SSA容易因某些种群个体在搜索某一维时陷入局部最优,从而导致算法在未搜索到最优值时就收敛,因此所提算法将对SSA的初始化和搜索过程进行改进。

2.2 Circle混沌映射初始化

SSA种群初始化时,在搜索空间内随机生成初始种群,这种随机生成的种群位置分布不均匀,极易导致算法在初始化阶段获得的样本值范围较小。聂瑞等^[10]利用Tent映射优化遗传算法,提高了算法的初始化效率,受该文献的启发,利用Circle混沌映射来初始化种群,定义为

$$\hat{S}_{id} = \text{mod} \left(S_{id} + 0.2 - \frac{\sin(2\pi S_{id})}{4\pi}, 1 \right) \quad (10)$$

其中 S_{id} 为第 i 个个体的第 d 维位置

利用Circle混沌映射初始化种群比随机分布种群更加均匀,提高了种群在初始化阶段获得最优位置的概率,增加了种群样本的多样性,一定程度上改善了算法易陷入局部最优的缺陷。

2.3 临时优劣重心反向策略优化发现者位置

Tizhoosh^[11]提出了反向策略,即设区间 $[l,u]$ 上存在数 q ,则数 q 的反向点定义为

$$\bar{q} = l + u - q \quad (11)$$

因反向模型未利用种群的搜索信息,由此引入重心与基于重心的反向点定义。设为空间中有 M 个点 G ,坐标为 (x_g^C, y_g^C) , $g=1,2,\dots,M$,则全局重心 C 坐标为

$$(x^C, y^C) = \left(\frac{x_1^G + x_2^G + \dots + x_M^G}{M}, \frac{y_1^G + y_2^G + \dots + y_M^G}{M} \right) \quad (12)$$

点 G 对应的重心反向点 \bar{G} 为

$$(\bar{x}_g^C, \bar{y}_g^C) = ((2x^C - x_g^C), (2y^C - y_g^C)) \quad (13)$$

反向点位于一个具有动态边界的搜索空间,记为 $(\bar{x}_g^C, \bar{y}_g^C) \in ((x_{\min}^G, y_{\min}^G), (x_{\max}^G, y_{\max}^G))$ 。当反向点小于边界最小值时,则重新计算反向点为

$$(\bar{x}_g^C, \bar{y}_g^C) = (x_{\min}^G + \rho x^C - \rho x_{\min}^G, y_{\min}^G + \rho y^C - \rho y_{\min}^G) \quad (14)$$

其中 ρ 为0或1的随机数,当反向点大于边界最大值时,则重新计算反向点为

$$(\bar{x}_g^C, \bar{y}_g^C) = (x^C + \rho x_{\max}^C - \rho x^C, y^C + \rho y_{\max}^C - \rho y^C) \quad (15)$$

个体在按照全局重心进行反向学习操作时,参考点只有一个重心,会降低种群的多样性。周凌云等^[12]利用邻域重心来求解反向种群,让群体在进行反向学习时有多个参考点。受此启发,笔者提出了临时优劣重心反向学习策略,需更新位置的个体利用当前最优个体、最劣个体和最劣个体的临时个体结合建立重心点进行反向学习,每个个体更新时所参考的重心点均不同,充分利用了群体的搜索经验,可探索更多的区域空间,保持一定的多样性。为方便理解,以二维坐标平面为例,临时优劣重心反向计算方式如图2所示。

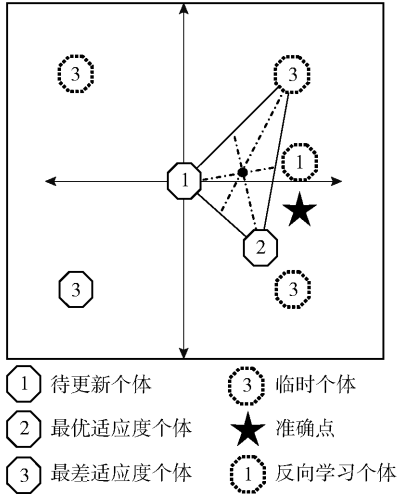


图2 临时优劣重心反向计算

种群在更新时,靠近准确点的个体适应度越优,1号个体为待更新个体,2号个体为当前最优适应度个体,3号个体为当前最差适应度个体,以1号个体为原点建立坐标轴,利用最差适应度个体 (x^w, y^w) 与待更新个体 (x_0^T, y_0^T) 的距离来重新确定临时个体:

$$(x_w^T, y_w^T) = (x_0^T \pm |x^w - x_0^T|, y_0^T \pm |y^w - y_0^T|) \quad (16)$$

其中: $w = 1, 2, \dots, 4$,得到4个临时个体位置后,分别计算其有待更新位置个体和最优适应度个体三者的重心,利用得到的4个重心点进行反向学习操作,取最优适应度个体位置进行更新。按照式(12)得到重心 \hat{C} 的位置为

$$(\hat{x}^C, \hat{y}^C) = \left(\frac{x^B + x^w + x_0^T}{3}, \frac{y^B + y^w + y_0^T}{3} \right) \quad (17)$$

其中: (x^B, y^B) 为最优适应度个体位置,待更新个体的临时优劣重心反向学习结果为

$$(\hat{x}_0^T, \hat{y}_0^T) = ((2\hat{x}^C - x_0^T), (2\hat{y}^C - y_0^T)) \quad (18)$$

当 $S_R < S_T$ 时,发现者通过式(18)进行反向学习,若反向学习后的适应度优于原发现者个体适应度,则按照反向学习后的个体位置进行更新。反之,则保留原个体位置,等待下一轮更新。此方法充分利用了群体的搜索经验,可探索更多的区域空间,保持了种群多样性。

2.4 融变策略优化监察者位置

融变策略与遗传算法的思想类同,步骤如下:

步骤1 第一轮种群初始化过程中,将监察者的适应度值按照从小到大依次排序。

步骤2 更新位置过程中,进行融合产生新个体:

$$\left. \begin{aligned} S_{\eta d}^t &= \varphi S_{\eta d}^t + (1 - \varphi) S_{bd}^t \\ S_{bd}^t &= \varphi S_{bd}^t + (1 - \varphi) S_{\eta d}^t \end{aligned} \right\} \quad (19)$$

其中 φ 为 $(0, 1]$ 中的随机数。

步骤3 计算个体适应度值,保存最优适应度个体。

步骤4 进行变异操作:

$$S_{\eta d}^t = X_{\eta d}^{\eta d} + r(X_{\max}^{\eta d} - X_{\min}^{\eta d}) \quad (20)$$

其中 r 为区间 $[0, 1]$ 的随机数, $X_{\max}^{\eta d}$ 和 $X_{\min}^{\eta d}$ 分别为第 η 个监察者在第 d 维进行变异时的边界最大值和最小值。

步骤5 计算变异个体的适应度值,与原个体对比,选择最优的适应度对应的个体,将其保存。

在融合过程中,随机数取值的跳跃性有助于算法跳出局部最优值,待更新个体向最优适应度个体位置进行随机游走。变异操作则保证在搜索区域边界范围内的情况下,利用边界最大值和最小值进行随机位置更新。融变策略在一定程度上减小了因过早收敛而使整个搜索区域范围缩小导致陷入局部最优的情况,并且能够维持种群内部监察者的多样性。

2.5 算法描述

所提的临时优劣重心反向融变的麻雀优化 WSN 定位算法步骤如下。

步骤1 初始化 WSN 中的锚节点自身的位置信息和 RSSI 值等。

步骤2 未知节点接收通讯范围内锚节点的数据信息,通过式(3)和式(4)计算未知节点与通讯范围内锚节点的距离平均值 \bar{R}_j 和盒子搜索区域。

步骤3 在盒子区域内,利用式(10)初始化麻雀种群,则个体适应度值为

$$f(S_p) = \frac{1}{m} \sum_{j=1}^m (R_{pj} - \overline{R_{pj}})^2 \tag{21}$$

其中 R_{pj} 为种群第 p 个个体到第 j 个锚节点的距离。

步骤 4 对种群适应度进行排序,记录最优适应度个体和最差适应度个体。

步骤 5 根据式(18)优化发现者位置。

步骤 6 根据式(19)和式(20)优化监察者位置。

步骤 7 记录全局最优适应度个体,若优于原最优个体,则更新最优个体位置,反之则进入下一轮迭代。

步骤 8 迭代完成,输出最优个体的位置信息。

算法流程如图 3 所示。

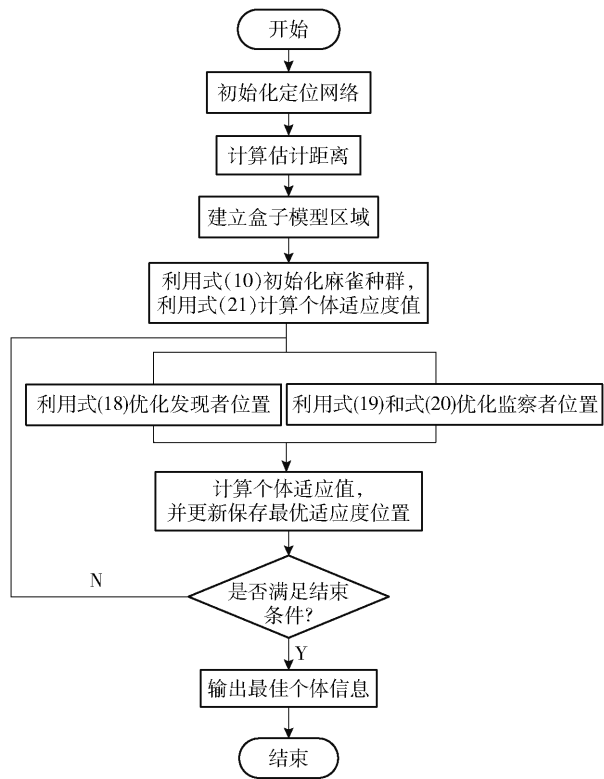


图 3 临时优劣重心反向融变的麻雀优化 WSN 定位算法流程

3 仿真实验与结果分析

3.1 参数设置

所提算法在 Matlab2018b 仿真环境下进行仿真分析,参数设置如表 1 所示。

3.2 仿真结果与分析

将所提出的临时优劣重心反向融变的麻雀优化 WSN 定位算法与 SSA、粒子群 (PSO, particle swarm optimization) 算法^[13]、灰狼优化 (GWO, grey wolf

表 1 仿真参数设置

参数	取值
仿真区域面积/m ²	(100,100)
锚节点个数	5~40
未知节点个数	100
节点传输范围/m	20
参考信号强度 $P(R_0)$ /dbm	-15
信息广播次数	0~10
σ	1
种群数量	30
迭代次数	50
S_T	0.6
发现者比例	0.7
监察者比例	0.2
加入者比例	0.1

optimizer) 算法^[14]进行比较。为避免误差,将分别进行 20 次仿真,计算均值。算法误差的评价函数计算公式为

$$F_e = \frac{1}{20} \sum_{e=1}^{20} \sqrt{(\hat{x}_i^u - x_i^u)^2 + (\hat{y}_i^u - y_i^u)^2} \tag{22}$$

其中: $(\hat{x}_i^u, \hat{y}_i^u)$ 为未知节点的真实坐标。

固定锚节点数量为 20,观察算法的迭代收敛情况,如图 4 所示。由图 4 可知,GWO 算法在迭代 30 次后逐渐收敛,其定位误差最终为 2.17 m,PSO 算法和 SSA 在迭代 20 次后收敛,误差分别为 1.31 m 和 1.05 m,而所提算法在迭代 15 次后收敛,收敛速度最快,且所提算法的最优估计位置的平均误差为 0.67 m,小于其他算法的定位误差。这是由于所提算法的盒子模型在初始化阶段便初步确定了未知节点的大概位置区域,利用 Circle 混沌映射初始化种群,使得初始化种群分布更加均匀。后续的更新过程中,临时优劣重心反向融变策略充分利用种群的




图 4 各算法的节点平均定位误差收敛情况

搜索经验,提高了算法寻优能力。

在 6 次 RSSI 接收次数下进行 30 次迭代,改变锚节点的数量,4 种算法的平均定位误差对比如图 5 所示。由图 5 可知,随着锚节点数量的增加,对未知节点的定位误差变小,当锚节点数量大于 25 后,误差趋于稳定,这表明在锚节点完全覆盖整个接收区域时,继续增加锚节点数量并不能使误差明显减小。这是由于锚节点数量较多时,节点获得较多重合的位置数据,对定位误差的改善作用较小。同时,增加锚节点数量将会明显地增加网络部署成本。由图 5 还可知,所提算法的平均误差最小为 0.56 m,比 GWO 算法降低了 63.58%,比 PSO 算法降低了 43.30%,比 SSA 降低了 36.78%。




图 5 各算法在不同数量锚节点时的平均定位误差对比

为验证所提算法的鲁棒性,固定锚节点个数为 25,进行 30 次迭代,改变 RSSI 的接收次数,4 种算法的定位误差对比如图 6 所示,随着接收次数的增大,定位误差逐渐减小,这说明通过多次 RSSI 值计算所得的距离会消除部分环境因素带来的误差,但在接受次数超过 6 次后,节点的误差趋于稳定。在同一接收次数情况下,所提算法的误差均小于其余算法。从整体来看,所提算法具有较好的鲁棒性和定位精度。




图 6 各算法在不同接收次数下的平均定位误差对比

3.3 算法时间复杂度

将所提算法与 SSA 的时间复杂度进行对比,结果如表 2 所示。

表 2 所提算法和 SSA 在各阶段的时间复杂度对比

阶段	SSA	所提算法
初始化阶段	$O(d+f(d))$	$O(d+f(d))$
更新发现者阶段	$O(d)$	$O(d)$
更新加入者阶段	$O(d)$	$O(d)$
更新监察者阶段	$O(d)$	$O(d)$
更新最优位置阶段	$O(d)$	$O(d)$

所提算法与 SSA 在每个阶段的时间复杂度相同,所以所提算法并未增加求解的时间复杂度。

4 结束语

针对群智能优化算法在 WSN 定位中迭代速度慢和容易陷入局部最优的问题,提出了一种临时优劣重心反向融变的麻雀优化 WSN 定位算法。算法通过盒子区域模型,初步确定节点的搜索区域,避免了前期不必要的搜寻,提高了搜寻效率;利用 Circle 混沌映射初始化种群使种群分布更加均匀,增加了种群样本的多样性;提出了临时优劣重心反向学习策略并结合融变策略,充分利用种群的搜索经验的同时也保持了种群的多样性,改善了算法容易陷入局部最优的缺陷。仿真结果表明,所提算法能够在不增加时间复杂度的情况下,提高对未知节点的定位精度和收敛的效率。

参考文献:

[1] 胡中栋,王俊岭,王振东,等. 山区复杂地形的无线传感器网络节点定位算法[J]. 北京邮电大学学报, 2019, 42(5): 113-118.
HU Z D, WANG J L, WANG Z D, et al. Node localization algorithm of wireless sensor networks for complex terrain in mountain areas[J]. Journal of Beijing University of Posts and Telecommunications, 2019, 42(5): 113-118.
[2] 余修武,张可,刘永. 基于罚函数与水波优化的 WSN 定位算法[J]. 北京邮电大学学报, 2020, 43(4): 106-112.
YU X W, ZHANG K, LIU Y. Localization algorithm based on penalty function and water wave optimization for WSN[J]. Journal of Beijing University of Posts and Telecommunications, 2020, 43(4): 106-112.

- [3] 任克强, 潘翠敏. RSSI 模型参数动态修正的协作定位算法[J]. 华中科技大学学报(自然科学版), 2020, 48(2): 97-102.
REN K Q, PAN C M. Collaborative localization algorithm based on dynamic correction of RSSI model parameters[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2020, 48(2): 97-102.
- [4] 乐燕芬, 汤卓, 盛存宝, 等. 基于多分布密度位置指纹的高效室内定位算法研究[J]. 通信学报, 2019, 40(1): 172-179.
LE Y F, TANG Z, SHENG C B, et al. Fast and resource efficient method for indoor localization based on fingerprint with varied scales[J]. Journal on Communications, 2019, 40(1): 172-179.
- [5] 林维维, 姚英彪, 邹柯, 等. 基于校正矢量的分布式 DV-Hop 求精算法[J]. 计算机研究与发展, 2019, 56(3): 585-593.
LIN W W, YAO Y B, ZOU K, et al. Correction vector based distributed DV-Hop localization refinement algorithm[J]. Journal of Computer Research and Development, 2019, 56(3): 585-593.
- [6] 尹雨晴, 高守婉, 王小旗, 等. 基于随机游走的无线传感器网络节点定位方法[J]. 北京邮电大学学报, 2018, 41(2): 75-80.
YIN Y Q, GAO S W, WANG X Q, et al. Node localization with random walk for wireless sensor networks[J]. Journal of Beijing University of Posts and Telecommunications, 2018, 41(2): 75-80.
- [7] 李昂, 付敬奇, 沈华明, 等. 基于模糊聚类和猫群算法的室内定位算法[J]. 仪器仪表学报, 2020, 41(1): 185-194.
LI A, FU J Q, SHEN H M, et al. Indoor positioning algorithm based on fuzzy clustering and cat swarm optimization[J]. Chinese Journal of Scientific Instrument, 2020, 41(1): 185-194.
- [8] 常鲁杰, 刘明雍, 张立川, 等. 迭代粒子群优化的水下无线传感器网络节点自定位算法[J]. 西北工业大学学报, 2017, 35(4): 648-654.
CHANG L J, LIU M Y, ZHANG L C, et al. A localization method for underwater wireless sensor networks based on modified particle swarm optimization algorithms[J]. Journal of Northwestern Polytechnical University, 2017, 35(4): 648-654.
- [9] 薛建凯. 一种新型的群智能优化技术的研究与应用: 麻雀搜索算法[D]. 上海: 东华大学, 2020: 15-20.
XUE J K. Research and application of a novel swarm intelligence optimization technique: sparrow search algorithm[D]. Shanghai: Donghua University, 2020: 15-20.
- [10] 聂瑞, 章卫国, 李广文, 等. 基于 Tent 映射的自适应混沌混合多目标遗传算法[J]. 北京航空航天大学学报, 2012, 38(8): 1010-1016.
NIE R, ZHANG W G, LI G W, et al. Adaptive chaotic hybrid multi-objective genetic algorithm based on Tent map[J]. Journal of Beijing University of Aeronautics and Astronautics, 2012, 38(8): 1010-1016.
- [11] TIZHOOSH H R. Opposition-based learning: a new scheme for machine intelligence[C]//International Conference on International Conference on Computational Intelligence for Modelling, Control & Automation. New York: IEEE, 2005: 695-701.
- [12] 周凌云, 丁立新, 彭虎, 等. 一种邻域重心反向学习的粒子群优化算法[J]. 电子学报, 2017, 45(11): 2815-2824.
ZHOU L Y, DING L X, PENG H, et al. Neighborhood centroid opposition-based particle swarm optimization[J]. Acta Electronica Sinica, 2017, 45(11): 2815-2824.
- [13] 黄越洋, 井元伟, 张嗣瀛, 等. 基于样本均值和中位值的粒子群优化定位算法[J]. 东北大学学报(自然科学版), 2018, 39(7): 913-917.
HUANG Y Y, JING Y W, ZHANG S Y, et al. Particle swarm optimization localization algorithm based on sample mean and median[J]. Journal of Northeastern University(Natural Science), 2018, 39(7): 913-917.
- [14] 龙文, 蔡绍洪, 焦建军, 等. 一种改进的灰狼优化算法[J]. 电子学报, 2019, 47(1): 169-175.
LONG W, CAI S H, JIAO J J, et al. An improved grey wolf optimization algorithm[J]. Acta Electronica Sinica, 2019, 47(1): 169-175.