

DOI:10.19651/j.cnki.cmt.2107387

融合跳距修正与麻雀搜索的改进 DV-Hop 算法

颜慧超 曾子维 王刚

(辽宁科技大学 计算机与软件工程学院 鞍山 114051)

摘要: 针对 WSN 节点定位中 DV-Hop 算法存在较大定位误差的问题,深入分析产生误差的原因,提出了一种基于跳距改进和麻雀优化 DV-Hop 定位算法(ISSA-DH)。该算法首先通过通信半径细化精确跳数,并添加加权修正因子来降低平均跳距的误差;然后通过估计距离和实际距离的偏差量进一步加权修正跳距;再利用改进的麻雀算法取代最小二乘法,把无线传感器的定位问题转化为求解最优问题,进而得到未知节点的位置。通过仿真,在不同的条件下 ISSA-DH 算法较 DV-Hop 算法和改进算法(DCAI DV-Hop)定位误差平均下降 50.3%、34.3%,证明 ISSA-DH 算法能够有效减少定位误差。

关键词: 节点定位;DV-Hop;跳数修正;跳距修正;麻雀搜索算法

中图分类号: TP393 **文献标识码:** A **国家标准学科分类代码:** 510.3030

Improved DV-Hop algorithm combining hop distance correction and sparrow search algorithm

Yan Huichao Zeng Ziwei Wang Gang

(School of Computer Science and Software Engineering, University of Science and Technology Liaoning, Anshan 114051, China)

Abstract: On the basis of analyzing on localization error of DV-Hop algorithm in WSN, an improved DV-Hop algorithm (ISSA-DH) combining hop distance improvement and sparrow search algorithm is proposed. Firstly, the accurate hop number is refined by communication radius, and the weighted correction factor is added to reduce the error of average hop distance. Then the hop distance is further weighted by the deviation between the estimated distance and the actual distance. Then the improved sparrow algorithm is used to replace the least square method, and the localization problem of wireless sensor is transformed into an optimal problem to obtain the position of the unknown node. Simulation experiments show that under different conditions, the localization error of ISSA-DH algorithm was reduced by 50.3% and 34.3%, compared to the DV-Hop algorithm and improved algorithm (DCAI DV-Hop).

Keywords: node localization; DV-Hop; hop count correction; hop distance correction; sparrow search algorithm

0 引言

随着物联网技术的发展,无线传感器网络在许多领域都起着重要作用,被广泛应用于环境检测、病人追踪、军事侦测、森林消防等领域中。单个实体或传感器节点在实体场景应用中如无法获取位置信息,所传输数据往往失去功用。因此传感器节点定位问题至关重要,值得深入研究^[1]。

根据定位方式的不同,无线传感器网络(wireless sensor network, WSN)定位可分为两类:测距定位和非测距定位。基于测距定位的算法能量开销大,对节点硬件要求高,且易受环境干扰^[2]。而无需测距的定位算法,则具有成本低、能耗低、实现简单、硬件少的优点^[3]。为了解决这些基础经典算法定位精度差问题,国内外学者进行了大量

深入研究。Liu 等^[4]提出一种改进距离向量跳(distance vector hop, DV-Hop)算法,利用改进距离搜索空间的人工蜂群算法来提高定位精度,减少了计算量但是收敛效果不佳。徐慧娟^[5]提出利用相近度修改跳距大小并与遗传模拟退火算法相结合来优化 DV-Hop,增强了定位能力,但也增加了计算量。Messous 等^[6]提出的改进算法是基于未知节点递归计算,通过锚节点的平均跳距使用优化后的公式,将估计距离误差降到最低。Bing 等^[7]提出一种基于三通信半径修正节点跳数的改进算法,该算法提高了定位精度但是能耗却增大。褚银菲等^[8]结合接收信号强度值提出一种测距修正的差分进化定位算法,提高了定位精度但在搜索范围存在局限性。

本文基于以上研究,针对定位性能存在的问题,从跳

数、跳距和坐标计算方法这 3 个方面对算法进行优化。在麻雀算法和 DV-Hop 算法优势互补基础上,提出一种跳距改进和麻雀搜索相结合的定位算法。仿真分析表明所提出算法具有较好定位性能。

1 节点定位问题描述

1.1 定位模型

在 WSN 中,设存在 m 个锚节点, n 个未知节点。锚节点坐标 $(x_i, y_i) (i = 1, 2, 3, \dots, m)$, 未知节点的坐标为 $P(x, y)$ 。根据 DV-Hop 算法可以求出未知节点与 m 个信标节点之间的距离为 d_1, d_2, \dots, d_m , 但在实际应用中受到环境和算法本身的影响存在测距误差分别为 $\eta_1, \eta_2, \dots, \eta_m$, 那么未知节点 $P(x, y)$ 的位置约束条件表示为:

$$\begin{cases} d_1 - \eta_1 \leq \sqrt{(x - x_1)^2 + (y - y_1)^2} \leq d_1 + \eta_1 \\ d_2 - \eta_2 \leq \sqrt{(x - x_2)^2 + (y - y_2)^2} \leq d_2 + \eta_2 \\ \vdots \\ d_m - \eta_m \leq \sqrt{(x - x_m)^2 + (y - y_m)^2} \leq d_m + \eta_m \end{cases} \quad (1)$$

1.2 DV-Hop 误差分析

DV-Hop 算法通过跳数与平均跳距的乘积获得节点间距离,再利用距离来计算未知节点的坐标。计算跳数时,通信半径内的所有邻居节点跳数将直接记为一跳会产生很大的误差。且无线传感器网络中节点分布是不均匀的,两个节点之间的路径并不是都是直线往往是几个折线,需要经过多跳才能通信。求解未知节点位置时通常采用三边测量法和极大似然估计法。但是在未知节点与周围的 3 个锚节点共线时,三边测量法就无法实现节点定位。而极大似然估计法对偏差较为敏感,由方程 $AX=b$ 可知矩阵 A 或者 b 的任意一个产生偏移都将对定位产生影响。分析可得影响 DV-Hop 定位精度的主要 3 因素:跳数、平均跳距和节点位置计算方法^[9-10]。

1.3 适应度函数

基于上述讨论,由于测距误差 η 的存在,根据式(1)可将定位问题转化为误差函数的最优问题。解 (x, y) , 得式(2),其最小情况 $\min f(x, y)$ 即为未知点的最优解。智能算法对于此类非线性寻优问题具有快速且高效的优势,本文采用一种改进的麻雀搜索算法(improved sparrow search algorithm, ISSA)来求解节点位置问题。

$$f(x, y) = \sum_{i=1}^m \left| \sqrt{(x_i - x)^2 + (y_i - y)^2} - d_i \right| \quad (2)$$

2 ISSA-DH 定位算法

通过分析影响 DV-Hop 算法定位精度的因素,提出了 ISSA-DH 定位算法。该算法主要针对跳数、平均跳距和节点位置计算方法这 3 方面提出改进。

2.1 ISSA

1) SSA

麻雀搜索算法(sparrow search algorithm, SSA)是一种

新型群智能优化算法,该算法受到生物界麻雀捕食和反捕食的行为启发于 2020 年提出^[11]。在种群中,麻雀可分为发现者和跟随者。发现者负责搜索食物,并为跟随者提供方向指引。发现者一般占种群数量的 10%~20%,剩余的麻雀则作为跟随者^[12]。

发现者大规模搜索觅食区域,并根据式(3)更新位置:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha T}\right), & R_2 < ST \\ X_{i,j}^t + Q \cdot L, & R_2 \geq ST \end{cases} \quad (3)$$

其中, t 为当前迭代次数; Q 为服从标准正态分布的随机数; L 为 $1 \times d$ 的元素均为 1 的矩阵; α 为 $(0, 1]$ 的均匀随机数; T 为最大的迭代次数; R_2 为预警值; ST 为安全值。

跟随者位置更新如下:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{worst}^t - X_{i,j}^t}{i^2}\right), & i < \frac{N}{2} \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \cdot A \cdot L, & \text{其他} \end{cases} \quad (4)$$

其中, X_{worst} 和 $X_{i,j}$ 分别表示最优位置和最劣位置; A 为 $1 \times d$ 的矩阵,元素为随机 1 或者 -1。

在觅食过程中,会选取 10%~20% 的麻雀来侦测预警,确保种群的安全性。当面临捕食者的威胁或者意识到危险时,会立刻进行反捕食行为。侦察者的位置更新公式如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{best}^t + \beta \cdot |X_{i,j}^t - X_{best}^t|, & f_i > f_k \\ X_{i,j}^t + k \cdot \frac{|X_{i,j}^t - X_{worst}^t|}{(f_i - f_w) + \epsilon}, & f_i = f_g \end{cases} \quad (5)$$

其中, β 是步长调整参数,服从 $(0, 1)$ 正态分布, k 是 $[-1, 1]$ 范围的随机数, ϵ 是一个极小的常数,用于避免分母为 0 的情况。 f_i 是第 i 只麻雀的适应度, f_k 和 f_w 分别是当前种群中的最佳适应度和最差适应度。

2) Sobol 序列初始化种群

混沌映射序列可以有效保证种群的多样性,利于算法跳出局部最优,因此被很多学者运用于优化搜索问题。研究证明, Sobol 序列有分布均匀、计算周期短、收敛速度快的优点^[13]。为保持麻雀种群多样性,使种群个体初始化尽可能保持均匀分布,采用 Sobol 序列对种群进行初始映射。公式表示如下:

$$X_n = X_{ub} + C_n (X_{lb} - X_{ub}) \quad (6)$$

式中: X_{lb} 和 X_{ub} 分别表示位置取值范围的上限和下限, C_n 表示为 Sobol 序列产生的 $[0, 1]$ 之间的随机数。

3) 柯西变异和加权中心反向学习策略

柯西算子能够产生较大步长使算法跳出局部最优,亦可产生较小步长加快对最优解的搜索速度。对于传统 SSA 算法易陷入局部最优的问题,通过结合柯西分布引入柯西变异策略,发挥柯西算子的扰动能力。当个体陷入局部最优时,对当前最优个体进行柯西扰动,提高算法的全局寻优能力^[14]。并采用式(8)对当前最优个体进行位置更新。

柯西标准公式如下:

$$f(x) = \frac{1}{\pi \times (x^2 + 1)}, x \in (-\infty, +\infty) \quad (7)$$

位置更新公式:

$$X'_{new}(i) = X'_{best}(i) \times (1 + cauchy(0, 1)) \quad (8)$$

式中: X'_{new} 为当前最优解, $cauchy(0, 1)$ 为柯西扰动算子。

反向学习实现过程是在当前解的基础上, 构造反向种群。通过反向学习机制寻找到对应反向解, 经过比较评估, 选取当前种群和反向种群中更优个体作为初始解^[15]。定义点 $S(s_1^d, s_2^d, \dots, s_L^d)$ 为 d 维空间的一点, $s \in [u_i^d, l_i^d], i = 1, 2, \dots, L$, 其中 u 和 l 分别为点 S 在维度 d 的最小值和最大值, 则点 S 在维度 d 上的精英个体反向解为:

$$s' = u_i^d + l_i^d - s_i^d \quad (9)$$

在搜索过程中为了加快收敛速度, 通过对种群适应度值给定权重来确定加权中心, 进而引导种群进化。这个中心点为反向学习的对称中心。个体适应度值 $f(F_i)$ 为目标函数值, 加权中心个体的权重值为 $A_i = f(F_i)/f(F_i)$, 则得到个体加权中心在维度 d 上的值为 $J^d = \sum_{i=1}^m A_i \cdot F_i$ 。由此可以计算出点 S 在维度 d 上以加权中心为对称点的反向点位置:

$$s'_{central} = \delta(J^d - s^d) + J^d \quad (10)$$

式中: δ 为服从 $[0, 1]$ 均匀分布的动态因子。

如图 1 所示, S 为搜索个体位置, 点 O 为加权中心。动态因子 k 越小, 反向学习点越靠近点 O , 反之则以点 S 为对称方向远离点 O 。搜索范围会随着 k 值的增大而增大, 当 k 值较小时, 搜索范围大多集中在点 O 附近。




图 1 加权反向学习模型

本文借鉴贪婪选择思想, 实行动态选择策略, 以一定概率 p 对当前最优解交替执行柯西变异操作和加权中心对称反向学习, 动态更新位置, 增强全局寻优能力, 改善基础麻雀算法容易陷入局部最优的缺陷。若 $rand$ 随机概率小于转换概率 p , 则对当前最优解使用柯西变异扰动策略改进; 若 $rand$ 大于等于 p 则应用加权中心对称反向学习更新适应度。

ISSA 算法流程如图 2 所示。

2.2 跳数优化

在 DV-Hop 定位算法的距离矢量交换阶段, 信标节点利用协议广播包含自身信息的数据包 $\{ID, (x, y), h\}$, 其中 ID 为节点编号, (x, y) 为坐标信息, h 为跳数信息。以通信半径 R 进行全网泛洪时, 信标节点把与其通信的邻居节点的跳数记为 1, 这样会导致在半径 R 内的节点实际跳距增大。因此提出了动态调整通信半径的想法, 根据节点

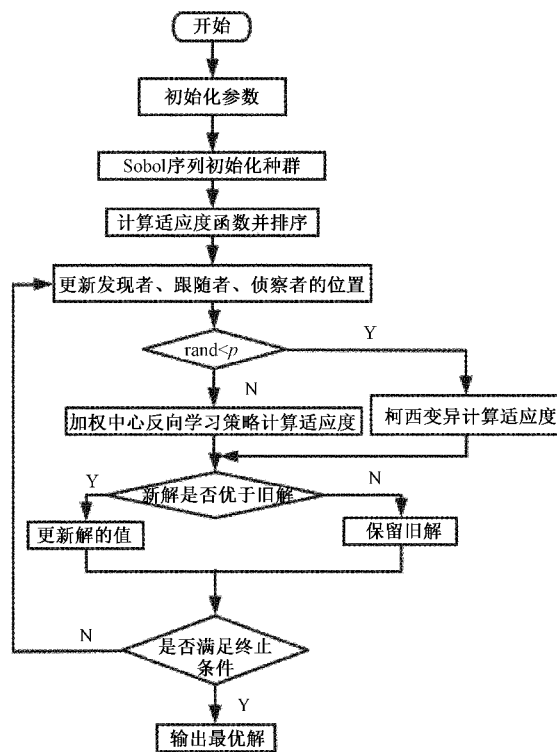


图 2 ISSA 算法流程

实际分布状况, 细化跳数, 从而减少距离误差。节点间跳数归纳公式如下:

$$h_{ij} = \begin{cases} \frac{1}{n}, & 0 < d \leq \frac{R}{n} \\ \frac{i}{n}, & \frac{(i-1)R}{n} < d \leq \frac{iR}{n}, i = 2, \dots, n-1 \\ 1, & \frac{(n-1)R}{n} < d \leq R \end{cases} \quad (11)$$

本文引入的是双通信半径来细化锚节点和未知节点的跳数, 即 $n=2$, 则跳数公式如下:

$$h_{ij} = \begin{cases} 10.5, & R < d_{ij} \leq R \\ 0.5, & 0 < d_{ij} \leq 0.5R \end{cases} \quad (12)$$

2.3 跳距修正

由于网络中传感器节点分布不均匀, 跳数计数不合理等因素都会造成节点平均跳距误差较大。如果使用靠近未知节点最近的锚节点的平均跳距作为整个网络的平均跳距去估算网络中节点之间的距离, 计算出的节点坐标将存在误差。为了提高定位精度, 提出了利用加权动态因子来调整跳距。

锚节点的平均跳距表示如下:

$$HopSize'_i = \frac{d_{i1}}{\sum_{i \neq j} d_{ij}} \times \frac{d_{j1}}{h_{i1}} + \frac{d_{i2}}{\sum_{i \neq j} d_{ij}} \times \frac{d_{j2}}{h_{i2}} + \dots + \frac{d_{im}}{\sum_{i \neq j} d_{ij}} \times \frac{d_{jm}}{h_{im}} = \lambda_{i1} \times \frac{d_{i1}}{h_{i1}} + \lambda_{i2} \times \frac{d_{i2}}{h_{i2}} + \dots + \lambda_{im} \times \frac{d_{im}}{h_{im}} \quad (13)$$

随着任意两个锚节点之间距离 d_{ij} 的增加, λ_{ij} 相应增加, 即随着距离增加, 其对平均跳距的影响也随之增加。锚节点的距离是特定的物理值, 因此引入 λ_{ij} 作为距离权重因子更合理且有利于提高定位精度。

将距离权重因子修正后的平均跳距与跳数相乘, 得到锚节点和未知节点的估计距离。如果使用节点估计距离作为真实距离来计算待测节点和信标节点的距离, 必定会造成很大误差。因此可根据锚节点 i 到锚节点 j 的估计距离 d_{true} 和实际距离 d_{est} 的偏差值及跳数进一步对跳距修正。跳距校正系数如下:

$$W_i = \frac{\sum_{i/j} [(d_{true} - d_{est})/h_{ij}]}{m} \quad (14)$$

将式(14)所得的跳距校正系数累加求和后, 根据信标节点数求平均值, 进一步对平均跳距进行修正, 最终得到平均跳距表示如下:

$$HopSize_{final} = HopSize'_i + \sum_{i=1}^m W_i/m \quad (15)$$

2.4 ISSA-DH 算法流程

步骤 1: 网络初始化。初始区域为 $M \times M$, 通信半径为 R , 信标节点数量为 m , 未知节点数量为 n , 这些节点随机散布在指定区域中。

步骤 2: 采用双通信半径计算未知节点和锚节点之间的最小跳数以及锚节点间的平均跳距。

步骤 3: 利用加权修正因子对跳距修正后, 进一步利用估计距离和实际距离的偏差加权系数提高锚节点和未知节点的距离精度。

步骤 4: 生成适应度函数 $f(x, y)$ 并初始化麻雀种群。

步骤 5: 计算目标函数值, 并根据改进后的 ISSA 算法对种群进行扰动, 防止陷入局部最优解, 更新适应度值, 并保留较好的值。

步骤 6: 判断是否满足终止条件, 满足则输出全局最优解, 目标函数所求解即为定位节点坐标; 否则继续寻优。

3 仿真结果与分析

3.1 仿真参数设置

仿真基于 MATLAB2016b 仿真软件。为了验证提出的算法的定位性能, 将 DV-Hop 算法、文献[16]中改进的 DCAI DV-Hop 算法及本文所提出的 ISSA-DH 算法进行分析比较。同时为了避免实验结果的偶然性, 将实验分为 3 组, 每组循环仿真 50 次。图 3 所示为网络节点分布图, 区域中随机抛撒 30 个信标节点, 70 个未知节点。仿真环境以及参数设置如表 1 所示。采用式(16)计算归一化定位误差评估定位精度。其中 N 表示节点总数, M 表示锚节点数, R 是节点通信半径, (x_i, y_i) 是节点的真实位置, (x'_i, y'_i) 是节点的估计位置。

$$ALE = \frac{\sum_{i=1}^{N-M} \sqrt{(x_i - x'_i)^2 + (y_i - y'_i)^2}}{(N - M) \cdot R} \quad (16)$$




图 3 网络节点分布

表 1 实验模拟环境及参数设置

参数名称	取值
面积	100 m × 100 m
节点总数	100
锚节点比例	0.3
半径/m	30
种群数量	100
迭代次数(T)	100
安全值(ST)	0.6

3.2 仿真结果分析

图 4 为通信半径对定位误差影响的关系图。设置节点总数为 100, 锚节点比例为 0.3。实验结果表明, 随着通信半径的增加, 误差不断降低。其中半径从 15 m 增到 25 m 的过程定位误差下降速度最快, 随后递减速度下降并趋于平缓。在通信半径改变的过程中, 算法的平均 ALE 值如表 2 所示。其中本文所提出的算法的平均 ALE 为 0.195, 而 DV-Hop 与 DCAI DV-Hop 的平均 ALE 分别为 0.382 和 0.301。通过对比可知, 本文算法的定位精度与其他两种算法相比分别提高了 48.9% 和 35.2%。




图 4 通信半径对定位误差的影响

图 5 为锚节点数量对定位误差影响的关系图。设置节点总数为 100, 通信半径为 30 m。通过实验仿真发现, 随着锚节点的增加, 定位误差逐渐降低。锚节点数量从 10 增加

表 2 通信半径为变量下的算法平均 ALE

算法	平均 ALE
DV-Hop	0.382
DCAI DV-Hop	0.301
ISSA-DH	0.195

到 40 过程中,算法的平均 ALE 值如表 3 所示。本文所提出的算法的平均 ALE 为 0.164,而 DV-Hop 与 DCAI DV-Hop 的平均 ALE 分别为 0.317 和 0.222。对比可知,本文提出的算法在定位精度上相比于 DV-Hop 经典算法与 DCAI DV-Hop 算法分别提高了 48.2%和 26.1%。这是因为 ISSA 算法具有更强的寻优能力,即使在锚节点数量稀少,有效信息缺乏情况下仍可以通过柯西变异和反向中心学习来扩大节点的搜寻范围。

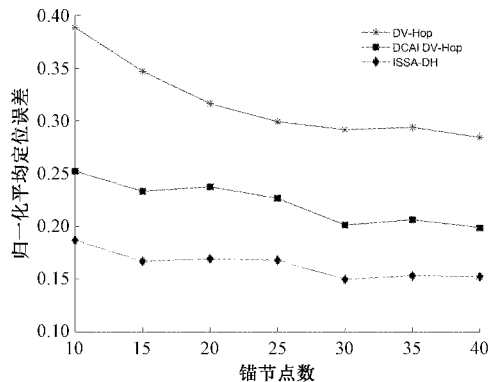


图 5 锚节点数量对定位误差的影响

表 3 锚节点数为变量下的算法平均 ALE

算法	平均 ALE
DV-Hop	0.317
DCAI DV-Hop	0.222
ISSA-DH	0.164

图 6 为节点数量对定位误差影响的关系图。设置锚节点占节点总数的比例为 0.3,通信半径为 30 m。随着节点总数的增加,定位误差逐渐降低。这是因为随着节点数量




图 6 节点总数对定位误差的影响

增添,网络联通性变强,节点收集到的定位信息越多,定位上的偏差也就越低。总节点数从 50 增加到 110 的过程中,算法的平均 ALE 值如表 4 所示。本文所提出的算法的平均 ALE 为 0.156,而 DV-Hop 与 DCAI DV-Hop 的平均 ALE 分别为 0.337 和 0.221。对比可知,本文提出的算法在定位精度上要优于其他算法,定位精度相比于经典 DV-Hop 算法和 DCAI DV-Hop 算法分别提高了 53.7%和 41.7%。

表 4 节点总数为变量下的算法平均 ALE

算法	平均 ALE
DV-Hop	0.337
DCAI DV-Hop	0.221
ISSA-DH	0.156

4 结 论

本文分析了 DV-Hop 算法产生误差原因,提出采用双通信半径计算最小跳数,融入加权思想,通过节点间距离构造距离权重因子;利用信标节点间距离产生的误差,建立跳距校正系数得到最终的平均跳距;最后在改进的跳距基础上,使用优化的麻雀搜索算法求解节点坐标。寻优过程通过 Sobol 序列初始化种群,后期运用柯西变异和反向中心学习策略扩大解的搜索范围,最终获得更加精确的节点位置。仿真实验证明,本文提出的算法具有更高的定位精度。本文仅考虑了静态传感器网络中节点的定位问题,未来可以推广并改进现有算法到动态网络中。

参考文献

- [1] 彭宇,王丹. 无线传感器网络定位技术综述[J]. 电子测量与仪器学报, 2011, 25(5):389-399.
- [2] 孟东阳,何秀凤,桑文刚. 基于无线网络传感器的定位技术研究[J]. 电子测量技术, 2012, 35(9):4-9.
- [3] 郭志鹏,李娟,赵友刚,等. 物联网中的无线传感器网络技术综述[J]. 计算机与应用化学, 2019, 36(1): 74-85.
- [4] LIU Y, GAO L. Optimized DV-Hop localization algorithm based on improved artificial bee colony[J]. Laser & Optoelectronics Progress, 2020, 57(19):192303.
- [5] 徐慧娟. 基于 DV-Hop 测距修正的遗传模拟退火定位算法[J]. 传感技术学报, 2018(1):147-151.
- [6] MESSOUS S, LIQUANE H, LIQUANE N. Improvement of DV-Hop localization algorithm for randomly deployed wireless sensor networks[J]. Telecommunication Systems: Modelling, Analysis, Design and Management, 2020, 73:75-86.
- [7] BING X, XU B. Improved DV-Hop algorithm with weighting based on multiple communication radius [J]. Computer Applications and Software, 2016, 33(7):

- 125-129.
- [8] 褚银菲,吕惠芳.基于测距修正的差分进化的 DV-Hop 定位算法[J].国外电子测量技术,2021,40(6):33-37.
- [9] 方旺盛,吴伟伟,胡中栋.跳距加权和跳数优化的粒子群 DV-Hop 算法[J].传感器与微系统,2020,39(3):137-140.
- [10] 石琴琴,王冬雨,徐强,等.路径相似度因子在 DV-Hop 改进中的应用[J].电子测量与仪器学报,2019,33(1):113-119.
- [11] XUE J K. A novel swarm intelligence optimization approach: a parrot search algorithm [J]. Systems Science & Control Engineering,2020,8(1):22-34.
- [12] 吕鑫,慕晓冬,张钧,等.混沌麻雀搜索优化算法[J].北京航空航天大学学报,2020,9(11):1-10.
- [13] 李志军.基于 Sobol 序列和间歇 Levy 跳跃的改进蝙蝠算法[J].数学的实践与认识,2021,51(8):313-320.
- [14] 王永骥,苏婷婷,刘磊.基于柯西变异的多策略协同进化粒子群算法[J].系统仿真学报,2018,30(8):64-72.
- [15] 汤文亮,张平,汤树芳.基于精英反向学习的萤火虫 k-means 改进算法[J].计算机工程与设计,2019,40(11):3164-3169.
- [16] 李天琦.基于 DV-Hop 的无线传感器网络定位算法的研究与改进[D].长春:吉林大学,2018.

作者简介

颜慧超,硕士研究生,主要研究方向为无线传感器网络。

E-mail:1348364534@qq.com

曾子维,教授,硕士生导师,主要研究方向为移动计算。

E-mail:zzwustl@163.com

王刚(通信作者),副教授,主要研究方向为智能计算。

E-mail:purgwg@163.com