

# 混合粒子群和差分进化的定位算法

郑建国<sup>1</sup>, 张学煜<sup>2</sup>

(1. 浙江邮电职业技术学院, 浙江 绍兴 312016;

2. 中国科学技术大学 软件学院, 江苏 苏州 215123)

**摘要:** 针对由测量误差造成的无线传感器网络定位精度不高的问题, 提出一种混合粒子群和差分进化的节点定位算法 (HPSO-DE); 首先, 对粒子群算法的惯性权重进行自适应更新, 使得每个个体随着迭代次数的增加而增大, 进而提高其全局探索能力, 然后改进差分进化算法的变异策略, 从而提高该算法的局部寻优能力, 之后将个体先经过改进的粒子群算法优化, 低于平均适应度值的个体继续通过改进的差分进化算法优化, 从而得到 HPSO-DE 算法; HPSO-DE 算法继承了二者的优点, 提高了该算法的最优解精度和收敛速度; 最后在无线传感器网络节点定位模型中应用 HPSO-DE 算法, 仿真结果表明, 所提 HPSO-DE 算法在测距误差为 30% 时, 定位误差比 PSO 和 DFOA 分别少 2.1 m 和 1.1 m, 具有更高的定位精度和更强的抗误差性能。

**关键词:** 无线传感器; 节点定位; 粒子群; 差分进化

## Hybrid Particle Swarm Optimization and Differential Evolution Based Localization Algorithm

Zheng Jianguo<sup>1</sup>, Zhang Xueyu<sup>2</sup>

(1. Zhejiang Post and Telecommunication College, Shaoxing 312016, China;

2. University of Science and Technology of China, Suzhou 215123, China)

**Abstract:** Aiming at the problem of low positioning accuracy caused by ranging error in Wireless Sensor Networks, a hybrid particle swarm optimization and differential evolution algorithm (HPSO-DE) for node localization is proposed. Firstly, the inertia weight of PSO is updated adaptively to improve its global exploring ability, so that each individual increases with the iterations, thereby improving its global exploration ability, and then improving the mutation strategy of the differential evolution algorithm to improve the locality of the algorithm. After the individual is optimized by the improved particle swarm optimization algorithm, and the individuals below the average fitness value continue to be optimized by the improved differential evolution algorithm to obtain the HPSO-DE algorithm. The HPSO-DE algorithm inherits the advantages of both, and improves the optimal solution precision and convergence speed of the algorithm. Finally, the HPSO-DE algorithm is applied to the wireless sensor network node location model. The simulation results show that the proposed HPSO-DE algorithm has a positioning error of 2.1 m and 1.1 m less than PSO and DFOA, respectively, when the ranging error is 30%, and has a high positioning accuracy and greater resistance to errors.

**Keywords:** wireless sensor network; node localization; particle swarm optimization; differential evolution

## 0 引言

无线传感网络协作地感知、采集和处理网络覆盖区域中被感知对象的信息, 并发送给观察者。由于其成本低、功能多、融合多门技术, 被誉为 21 世纪最具有影响力的技术之一。其应用包括视频监控、航空交通控制、机器人学、汽车、智能家居、健康检测和工业自动化等, 成本较低且实现简单, 因此在国内外得到了广泛的关注。

节点定位是无线传感网络 (wireless sensor network, WSN) 重要的支撑技术<sup>[1]</sup>, 其精确性是衡量无线传感网络

性能优劣的一个重要的标准。

根据是否需要测量距离, 目前无线传感器网络节点定位算法可以分为两种定位机制, 基于测距和无需测距<sup>[2]</sup>。基于测距的定位通过距离确定节点的位置<sup>[2]</sup>, 无需测距近似估计节点的位置而不用知道节点的距离和方向, 显然基于测距的定位性能高于无需测距的方法, 本文主要研究基于测距技术的定位。测距定位的基本方法包括接收信号强度指示 (received signal strength indication, RSSI)<sup>[3]</sup>、到达时间差 (time difference of arrival, TDOA)<sup>[4]</sup>、到达角度 (angel of arrival, AOA)<sup>[5]</sup>。其中 TDOA、AOA 等都需要其他硬件支持, 比方说: 红外线发射器、天线阵列、超宽带 (UWB) 以及脉冲器等, 虽然它们的精度高于 RSSI 的测距方法, 但同时也对硬件具有较高的要求。RSSI 通过利用无线通信芯片, 且不需要额外的设备, 使用起来十分方便,

收稿日期: 2019-03-27; 修回日期: 2019-05-06。

作者简介: 2018 年浙江省教育厅一般科研项目 (Y201840156)。

作者简介: 郑建国 (1982-), 男, 硕士, 讲师, 主要从事认知无线电、物联网技术、信息安全方向的研究。

因此其是无线传感器网络节点定位中经常应用的测距技术,但在实际的测距过程中存在着较大误差,通过将无线传感器的定位问题转换成求测距误差最小值的优化问题来降低误差成为研究热点,当前有许多学者利用智能优化算法来提高节点定位的精度。

于泉等人改进粒子速度、惯性权重等,增强算法跳出局部最优能力,提高迭代后期算法的搜索速度,提出利用粒子群算法 (particleswarmoptimization, PSO) 求解 WSN 定位问题<sup>[6]</sup>,仿真表明该方法不仅可以提高精度而且可以提高稳定性。张健等人<sup>[7]</sup>利用动态步长机制控制果蝇种群寻优范围 DFOA,然后通过质心定位得出最终结果,仿真表明该算法有较抗误差能力。

以上算法虽然在一定程度上提升了定位性能,但是在定位精度上仍然有提升空间,研究一种性能好、效率高的智能算法至关重要,PSO 和差分进化 (differentialsolution, DE) 是两种经典的智能优化算法,PSO 模拟鸟类觅食的过程,通过不断向种群中优秀个体靠拢,进而快速寻找到食物。DE 模拟生物界染色体通过交叉、变异和选择保留优秀基因的过程。然而这两种算法都存在一定的不足,因此本文首先改进二种算法,然后提出混合粒子群和差分进化的 HPSO-DE 算法,并和文献 [6] 的 PSO、文献 [7] 的 HBPGA 等方法进行比较,证明本文算法在定位精度和寻优速度上的优势。

## 1 节点定位问题建模

在 WSN 中,设锚节点  $P_1(x_1, y_1), P_2(x_2, y_2), \dots, P_n(x_n, y_n)$  与未知节点  $P(x, y)$  之间的实际真实距离分别为  $r_1, r_2, \dots, r_n$ , 实际测量距离分别为  $d_1, d_2, \dots, d_n$ , 测距误差分别为  $\epsilon_1, \epsilon_2, \dots, \epsilon_n$ , 则满足  $|r_i - d_i| < \epsilon_i$ , 其中  $i = 1, 2, \dots, n$ , 那么未知节点  $P(x, y)$  的位置可由式 (1) 约束条件表示为:

$$\begin{cases} d_1^2 - \epsilon_1^2 \leq (x - x_1)^2 + (y - y_1)^2 \leq d_1^2 + \epsilon_1^2 \\ d_2^2 - \epsilon_2^2 \leq (x - x_2)^2 + (y - y_2)^2 \leq d_2^2 + \epsilon_2^2 \\ \vdots \\ d_n^2 - \epsilon_n^2 \leq (x - x_n)^2 + (y - y_n)^2 \leq d_n^2 + \epsilon_n^2 \end{cases} \quad (1)$$

解  $(x, y)$ , 使得:

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

由于测距误差的存在,需要对第二步根据式 (2) 计算,其整体取得最小值的情况即坐标  $(x, y)$  为未知点最优解的情况。由此节点定位问题可以转化成求式 (2) 所示对适应度函数最小的多约束优化问题。由于智能算法具有较快的寻优速度和较高的寻优精度,因此本文拟用智能算法求解节点定位问题。

## 2 粒子群算法及差分进化算法

### 2.1 粒子群算法 (PSO)

粒子群优化算法<sup>[8]</sup>受鸟类群体活动启发,将寻找问题

最优解的过程看作是鸟类 (抽象成粒子) 寻找食物的过程。具有并行性、分布式和收敛速度快等特点<sup>[8]</sup>,且没有许多参数需要调整。目前,已经广泛应用于工程设计、分类、模糊聚类、预测和神经网络等领域。

它们根据式 (3) 和式 (4) 更新速度  $V_{id} = (v_{i1}, v_{i2}, \dots, v_{id})$  和位置  $X_i = (x_{i1}, x_{i2}, \dots, x_{id})$ ,  $D$  是搜索空间维度,  $v_{ij}$  和  $x_{ij}$  分别表示第  $i$  个粒子第  $j$  维的速度和位置。

$$v_{id}(t+1) = \omega \cdot v_{id}(t) + c_1 \cdot r_1 \cdot (p_{id}(t) - x_{id}(t)) + c_2 \cdot r_2 \cdot (g_d(t) - x_{id}(t)) \quad (3)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t) \quad (4)$$

其中:  $\omega$  是惯性因子,  $t$  表示第  $t$  次迭代;  $c_1$  和  $c_2$  是学习因子;  $r_1$  和  $r_2$  是 2 个在  $[0, 1]$  上服从均匀分布的随机变量;  $p_i(t) = (p_{i1}(t), p_{i2}(t), \dots, p_{id}(t))$  和  $g(t) = (g_1(t), g_2(t), \dots, g_D(t))$  分别表示截至  $t$  代时第  $i$  个粒子搜索的局部最优解和所有粒子搜索的全局最优解。

在粒子群算法中,由公式 (3) 可以看出,粒子会向全局最优个体和个人局部最优个体靠拢,虽然能够较快的获得较优秀的解同时也很容易陷入局部最优。

### 2.2 差分进化算法 (DE)

差分进化算法<sup>[9]</sup>在解决全局最优解的问题上有独特的优点,模拟了自然过程,有着广阔的发展前景,目前已经应用到工程应用和学习研究中。它利用两条染色体的向量差值产生新解,指导算法进化方向,主要由变异、交叉和选择操作构成。

变异:在第  $t$  次迭代中,随机选择两个染色体  $X_{r_2}(t)$  和  $X_{r_3}(t)$ , 将两者的差值加到第三个随机个体  $X_{r_1}$  上,产生第  $i$  个变异个体  $H_i(t)$ 。  $F$  为变异因子。

$$H_i(t) = X_{r_1}(t) + F \cdot (X_{r_2}(t) - X_{r_3}(t)) \quad (5)$$

交叉:将  $H_i(t) = [h_{i1}(t), h_{i2}(t), \dots, h_{id}(t)]$  按式 (6) 交叉,产生交叉个体  $V_i(t)$ 。其中  $cr$  为交叉概率。

$$v_{ij} = \begin{cases} h_{ij}(t) & \text{rand}(0, 1) \leq cr \\ x_{ij}(t) & \text{else} \end{cases} \quad (6)$$

选择:选择的目标是第  $t+1$  代的染色体不差于  $t$  代的个体,如式 (7) 所示:

$$X_i(t+1) = \begin{cases} V_i(t) & f(V_i(t)) \leq f(X_i(t)) \\ X_i(t) & \text{else} \end{cases} \quad (7)$$

差分进化算法中的变异、交叉和选择机制保证了该算法具有较强的全局寻优能力,但是这种机制是完全随机的,因此该算法经常需要进化很多代才能得到较优秀的解。

## 3 节点定位的 HPSO-DE 算法

在第二节中,对 PSO 算法和 DE 算法进行描述和分析,PSO 算法具有较强的局部寻优能力但是全局寻优能力差,DE 算法具有较强的全局寻优能力但是局部寻优能力差,本章将对 PSO 和 DE 算法分别改进,并结合两者的优势,提出了基于节点定位的 HPSO-DE 算法。

在 PSO 算法中,惯性权重  $w$  用于平衡全局和局部搜索

能力<sup>[6]</sup>, 式 (3) 所示的固定惯性权重难以获得较好效果, 因此本文提出一种随着迭代次数自适应变化的惯性因子, 更新公式如式 (8) 所示。其中  $a$ 、 $b$ 、 $c$  和  $d$  是常数。

$$\omega = a \cdot e^{bt} + c \cdot e^{dt} \quad (8)$$

这样设计的思路是: 在迭代初期和中期, 应该尽可能减小  $\omega$ , 获得局部最优解, 加快寻优速度, 在迭代后期, 为了防止陷入局部最优, 应增大  $\omega$  值, 跳出当前解空间, 以探索全局最优解。

在 DE 算法的变异过程中,  $H_i(t)$  受  $X_{r_1}(t)$  影响很大, 算法容易陷入搜索停滞, 为了解决这个问题, 本文利用式 (9) 对其变异。

$$H_i(t) = \frac{X_{r_1}(t) + X_{r_2}(t) + X_{r_3}(t)}{3} + (F_2 - F_1)(X_{r_1}(t) - X_{r_2}(t)) + (F_2 - F_3)(X_{r_3}(t) - X_{r_2}(t)) + (F_1 - F_3)(X_{r_3}(t) - X_{r_1}(t)) \quad (9)$$

其中,  $F = |f(X_{r_1}(t))| + |f(X_{r_2}(t))| + |f(X_{r_3}(t))|$ ,

$$F_1 = \frac{|f(X_{r_1}(t))|}{F}, F_2 = \frac{|f(X_{r_2}(t))|}{F}, F_3 = \frac{|f(X_{r_3}(t))|}{F}。这样新产生的变异个体  $H_i(t)$  受 3 个随机个体的影响近似相同。$$

由于粒子群算法具有较强的局部寻优能力, 寻优速度快, 因此先用粒子群进行优化, 这样可以更快速地寻找到较优秀的解, 将个体适应度值高于种群平均适应度阈值  $f_{avg}$  的个体 (说明该个体估计的节点位置 and 实际节点位置误差较大) 利用 DE 继续进行进化, 从而使得陷入局部最优的这些个体尽快跳出当前区域, 去更大的空间寻找优秀的解。由此得到本文节点定位的 HPSO-DE 算法。主要步骤如下:

1) 初始化: 设置种群 NP 的规模  $N$ , 迭代总次数  $I$ , 设置当前迭代次数  $t=1$ , 对种群中每个个体的位置  $X_i(1)$  和速度  $V_{e_i}(1)$  随机初始化。

2) 适应度值更新: 利用式 (2) 求每个粒子的适应度值  $f(X_i(t))$ 。

3) 种群更新: 利用式 (8) 计算  $\omega$ , 然后带入到式 (3) 更新粒子速度, 利用式 (4) 更新粒子位置。计算阈值  $f_{avg}$ 。

4) 种群分级: 若  $f(X_i(t)) \leq f_{avg}$ , 将  $X_i(t)$  加入高级群  $NP_{sup}$  中, 否则加入劣等群  $NP_{wor}$ 。

5) 劣解更新: 将  $NP_{wor}$  中的劣质个体利用公式 (9)、(6) 和 (7) 进行变异、交叉和选择。

6) 将经过 DE 更新后的劣解  $NP_{wor}$  和  $NP_{sup}$  合并为 NP, 并确定种群最优个体  $g(t)$ 。

7) 判断  $t$  是否满足终止条件, 如果是转 (8), 否则转 (2)。

8) 输出种群最优个体  $g(t)$ , 作为对未知节点  $P(x, y)$  的位置估计。

## 4 仿真实验与分析

本节分析提出的 HPSO-DE 算法的节点定位性能, 并和文献 [6] 的 PSO 算法、文献 [7] 的 DFOA 算法进行对比分析。

### 4.1 算法参数设置

在 PSO 算法中, 参考 [6] 设置学习因子  $c_1 = c_2 = 1.4945$ , 在 DFOA 算法中, 参考 [7], 设置搜索步长  $radiusX$  为 0.1, 本文 HPSO-DE 算法中, 设置常数  $a=0.445$ ,  $b=d=-8.5E-06$ ,  $c=0.13$ , 交叉概率  $cr=0.6$ 。3 种算法中设置种群规模大小为 30, 最大迭代次数设置为 80。

### 4.2 实验仿真分析

仿真环境参数设置参考文献 [10], 设置节点通信半径为 10 m, 在 30 m×30 m 的仿真环境中, 随机分布 30 个传感器。

WSN 节点定位性能评价标准<sup>[11]</sup> 主要有定位精度、规模、锚节点密度、节点密度、容错性和自适应性、功耗和代价等 7 种。定位精度即定位精确度, 细分为绝对精度和相对精度; 规模即定位的范围; 锚节点的成本较高, 且当其密度达到一定值后, 定位精度不再随之增加; 节点密度用网络的平均连通度来表示; 容错性和自适应性较强即故障处理能力较强, 能够减小各种误差带来的影响; 功耗即各个传感器节点上的电池能量消耗, 与其关系比较密切的有计算量、时间复杂性和通信开销等; 代价包括时间代价与空间代价。

本文参考文献 [12] 和 [13] 以平均定位误差 (averagelocationerror, AVE) 为评价标准。其公式如式 (10) 所示:

$$AVE = \frac{1}{M} \sum_{i=1}^M \sqrt{(x-x_i)^2 + (y-y_i)^2} \quad (10)$$

式中,  $M$  为已知节点的总个数,  $(x, y)$  为预测位置,  $(x_i, y_i)$  为实际位置。

图 1 给出了在锚节点为 10 个时, 3 种算法的平均定位误差与测距误差的关系, 图中每个数据都是 20 次仿真结果的平均。由图可知: (1) 随着测距误差的减小, 3 种算法的平均定位误差也在减小, 说明 3 种智能优化算法的有效性; (2) 在测距误差较小, 即 0~5% 时, BA、CBA 和 HM-BA 的平均定位误差几乎接近于 0, 3 种方法均能达到较高的定位精度, 但相比较而言, HM-BA 的定位精度更高。但当定位误差不断增大, 尤其是在 15%~30% 时, 3 种方法的差距明显变大, 体现出了 HM-BA 在定位精度上的优势; (3) 本文在改进粒子群和差分进化算法的同时, 又结合两者的优势, 使得 HPSO-DE 算法定位性能最好, 在测距误差为 30% 时, HPSO-DE 的定位误差比 PSO 和 DFOA 分别少 2.1 m 和 1.1 m; (4) 当定位误差不断增大, 尤其是在 15%~30% 时, 3 种方法的差距明显变大, 相对来说 HPSO-DE 的误差增长的较为缓慢, 体现出了 HPSO-DE

算法在定位精度上的优势。

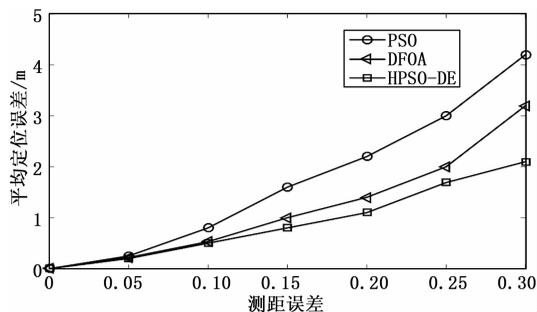


图 1 测距误差对定位性能的影响

图 2 给出了在定位误差为 10% 时, 3 种算法的平均定位误差与锚节点个数的关系。由图可知, 3 种算法的平均定位误差随着锚节点个数的增加而减小, 说明 3 种智能优化算法均能适应于节点定位中, 同时本文在达到相同的定位误差时需要最少的锚节点, 例如当定位误差为 1.5 m 时, HPSO-DE、PSO 和 DFOA 算法需要的锚节点分别为 3、5 和 7 个。这意味着本算法仅需要较小的硬件成本就能实现较高精度的定位。

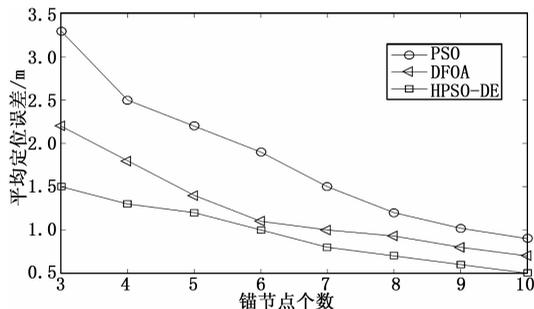


图 2 锚节点个数对定位性能的影响

图 3 给出了在定位误差为 10%, 锚节点个数为 10 个时, 3 种算法的平均定位误差与迭代次数的关系。由图可以看出, 随着迭代次数的增加, 更优的位置被发现, 因此 3 种算法的定位误差都在逐渐减小, HPSO-DE、PSO 和 DFOA 算法在达到稳定时需要的迭代次数依次为 20、20 和 47 次。PSO 算法虽然寻优速度快, 但是很快陷入局部最优, 因此平均定位误差较大, 而 HPSO-DE 算法结合了 PSO 的局部寻优能力强和 DE 的全局探索能力高的优势, 在保持较快寻优性能的同时具有最小的定位误差。

## 5 结语

节点定位是无线传感网络重要的支撑技术, 针对由测量误差造成的无线传感器网络节点定位精度不高的问题, 本文首先改进粒子群算法的固定惯性权重为自适应惯性权重, 增强了粒子群算法的全局搜索能力, 然后改进差分进化算法的变异策略, 增强 DE 算法的局部寻优能力, 然后将经过粒子群优化后的较差个体继续通过差分进化算法优化, 得到混合粒子群与差分进化的 HPSO-DE 算法, 仿真实验

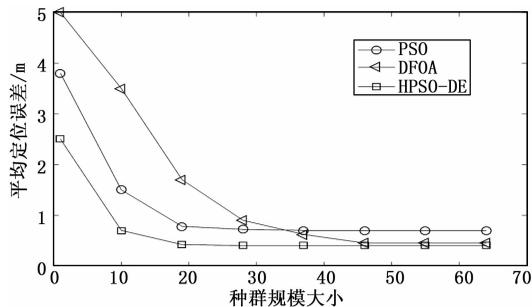


图 3 种群规模大小对定位性能的影响

表明, HPSO-DE 算法不仅提高了定位精度而且减少了定位需要消耗的时间。

## 参考文献:

- [1] 吕淑芳. 无线传感器网络节点定位研究综述 [J]. 传感器与微系统, 2016, 35 (05): 1-3.
- [2] 何涛, 包亮强, 赵长财. 关于无线传感器网络定位算法仿真 [J]. 传感器与微系统, 2017, 36 (11): 143-146.
- [3] Zheng J G, Wu C D, Chu H, et al. Localization algorithm based on RSSI and distance geometry constrain for wireless sensor network [A]. 2010 International Conference on Electrical and Control Engineering [C]. 2010: 2836-2839.
- [4] 闫雷兵, 陆音, 张业荣. 基于 TOA/TDOA 的一致性正交容积卡尔曼跟踪算法 [J]. 电子学报, 2018, 46 (08): 1989-1996.
- [5] 董文杰, 王旭东, 吴楠. 基于 RSS/AOA 混合的室内可见光定位算法 [J]. 激光与光电子学进展, 2018, 55 (05): 88-93.
- [6] 于泉, 孙顺远, 徐保国, 等. 基于改进粒子群算法的无线传感器网络节点定位 [J]. 计算机应用, 2015, 35 (06): 1519-1522.
- [7] 张健, 郭星, 李炜. 基于果蝇优化算法的 WSN 节点定位研究 [J]. 微电子学与计算机, 2018, 35 (04): 89-92.
- [8] Masdari M, Salehi F, Jalali M, et al. A survey of PSO-Based scheduling algorithms in cloud computing [J]. Journal of Network & Systems Management, 2017, 25 (1): 122-158.
- [9] Das S, Suganthan P N. Differential evolution: a survey of the state-of-the-art [J]. IEEE Transactions on Evolutionary Computation, 2011, 15 (1): 4-31.
- [10] 孟凯露, 岳克强, 尚俊娜. 基于元胞蝙蝠算法的无线传感器网络节点定位研究 [J]. 电信科学, 2017, 33 (11): 56-65.
- [11] 余义斌. 传感器网络定位算法及相关技术研究 [D]. 重庆: 重庆大学, 2006.
- [12] Peng L J, Li W W. The Improvement of 3D wireless sensor network nodes localization [A]. 26th IEEE Chinese Control and Decision Conference [C]. Changsha, 2014.
- [13] 范玉红. 无线传感器网络中节点定位算法研究 [D]. 成都: 西华大学, 2011.