



国防科技大学学报

Journal of National University of Defense Technology

ISSN 1001-2486,CN 43-1067/T

《国防科技大学学报》网络首发论文

题目： 针对 AOA-TDOA 联合定位的混合策略优化 HHO 算法
作者： 秦湖程，黄炎焱，耿泽，张寒
收稿日期： 2025-04-24
网络首发日期： 2025-12-17
引用格式： 秦湖程，黄炎焱，耿泽，张寒. 针对 AOA-TDOA 联合定位的混合策略优化 HHO 算法[J/OL]. 国防科技大学学报.
<https://link.cnki.net/urlid/43.1067.t.20251216.1637.002>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

doi: 10.11887/j.issn.1001-2486.25040042

针对 AOA-TDOA 联合定位的混合策略优化 HHO 算法

秦湖程¹, 黄炎焱^{1,*}, 耿泽¹, 张寒²

(南京理工大学 自动化学院, 江苏 南京 210094, 2.昆明物理研究所, 云南 昆明, 650223)

摘要: 针对现有到达角(angle of arrival, AOA)定位和到达时间差(time difference of arrival, TDOA)定位联合定位方法在复杂环境下局部搜索能力不足、易陷入局部最优解以及收敛速度较慢等问题, 提出了一种混合策略优化的哈里斯鹰优化(hybrid strategy-optimized Harris hawks optimization, HSHHO)算法。通过原始种群与准反射种群的双模协同机制, 利用双向精英迁移策略实现种群间优势互补和信息共享。同时, 在算法的开发与探索阶段分别融合了黄金正弦优化和柯西变异策略, 对种群更新机制进行了改进, 从而提升算法的全局搜索能力和局部开发能力。仿真实验结果表明, 与现有算法相比, HSHHO 算法在收敛速度、全局探索能力、局部开发能力和定位精度等方面均表现出更优异的性能。

关键词: 到达角-到达时间差联合定位; 哈里斯鹰优化算法; 双模协同优化模型; 黄金正弦优化; 柯西变异策略

中图分类号: TP18; TN911.7

Hybrid strategy optimized HHO algorithm for AOA-TDOA joint localization

QIN Hucheng¹, HUANG Yanyan^{1,*}, GENG Ze¹, ZHANG Han²(School of Automation, Nanjing University of Science and Technology, Nanjing 210094, China;
2.Kunming Institute of Physics, Kunming 650223, China)

Abstract: To address the issues of insufficient local search capability, susceptibility to local optima, and slow convergence in existing angle of arrival (AOA) and time difference of arrival (TDOA) joint positioning methods under complex environments, a hybrid strategy-optimized Harris hawks optimization (HSHHO) algorithm was proposed. A dual-mode cooperative framework consisting of the original and quasi-reflective populations was constructed. A bidirectional elite migration strategy was employed to facilitate information exchange and complementary advantages between the two populations. Additionally, during the algorithm's exploration and exploitation phases, the golden sine optimization and Cauchy mutation strategy were respectively integrated to refine the population update mechanism, thereby enhancing the algorithm's global exploration and local exploitation capabilities. Simulation results demonstrate that, compared with existing algorithms, the HSHHO algorithm exhibits superior performance in terms of convergence speed, global search capability, local refinement, and positioning accuracy.

Keywords: AOA-TDOA(angle of arrival-time difference of arrival) joint localization; Harris hawks optimization algorithm; dual-mode cooperative optimization model; golden sine optimization; Cauchy mutation strategy

收稿日期: 2025-04-24

基金项目: 国家自然科学基金资助项目(61874186)

第一作者: 秦湖程(1996—), 男, 广西桂林人, 博士研究生, E-mail: qhc1502@163.com

*** 通信作者:** 黄炎焱(1973—), 男, 广西桂林人, 教授, 博士, E-mail: E-mail:huangyy@njust.edu.cn

引用格式: 秦湖程, 黄炎焱, 耿泽, 等. 针对AOA-TDOA联合定位的混合策略优化HHO算法[J]. 国防科技大学学报,

Citation: QIN H C, HUANG Y Y, GENG Z, et al. Hybrid strategy optimized HHO algorithm for AOA-TDOA joint localization[J]. Journal of National University of Defense Technology,

在军事侦察与战场态势感知领域，随着战术自组网、军用物联网和无人作战系统的实战化部署，高精度定位技术已成为现代 C4ISR 系统的重要支撑^[1]。其中，基于角度到达(angle of arrival, AOA)和到达时间差(time difference of arrival, TDOA)的联合定位方法，凭借其抗干扰能力强、隐蔽性高等战术优势，已广泛应用于战场目标追踪和目标定位等领域^[2-5]。

然而，在建模与求解过程中，AOA-TDOA 联合定位问题仍然面临诸多挑战。首先，AOA 和 TDOA 分别基于接收信号的相位角和时间差构建距离测量模型，其中 TDOA 观测通常呈现双曲线定位形式，而 AOA 模型则依赖于方向余弦^[6]。在联合模型中，非线性三角函数与高阶差分项混合使用，导致整体目标函数具有高度非凸性^[7]，并存在大量局部极值。其次，AOA 和 TDOA 测量均极易受到环境噪声、硬件延迟和同步误差等因素的影响^[8-9]，造成复杂的误差模型，从而进一步加大了解的敏感性和不确定性。此外，联合定位问题通常涉及多维变量求解及约束条件，其输入数据涵盖多个传感器（或基站）的空间位置、TDOA 观测值和 AOA 观测角，输出则是目标节点的空间坐标估计。在此过程中，不仅需要高维参数进行有效优化，还必须满足任务区域内的边界约束和物理可行性条件。

由于 AOA-TDOA 联合定位问题具有建模复杂、解空间非凸、干扰因素多以及对鲁棒性要求高等显著特点^[1]，使得其难以通过传统解析方法直接求解^[10]。而启发式和元启发式算法因其卓越的全局搜索能力和抗干扰性，逐步被引入到 AOA-TDOA 联合定位问题的求解中。例如，文献[11]结合多元泰勒级数展开算法与人工鱼群算法，减少了鱼群数目和迭代次数对定位精度的影响，从而实现更高精度的定位。文献[12]提出了一种改进的哈里斯鹰优化定位算法(improved Harris hawks optimization, IHHO)，通过优化初始种群和适应度函数，提高了算法的收敛速度。文献[13]则采用樽海鞘优化算法(salp swarm algorithm, SSA)求解 TDOA 定位问题。此外，文献[14]在天牛须搜索算法 (beetle antennae search, BAS) 中引入步长因子优化，提高了定位精度和算法稳定性。除了上述优化方法，粒子群优化算法^[15-16] (particle swarm optimization algorithm, PSO)、遗传算法^[17-18] (genetic algorithm, GA)、灰狼优化算法^[19-20] (grey wolf optimization) 以及混合启发式算法^[21-22] 等智能优化算法也已成功应用于定位问题。同时，近年来涌现出的新型智能优化算法^[23-25] 已在高维约束优化场景中展现出卓越性能，为解决 AOA-TDOA 联合定位中的非凸优化难题提供了重要借鉴。

在上述研究的基础上，本文提出了一种混合策略优化的哈里斯鹰优化 (hybrid strategy-optimized Harris hawks optimization, HSHHO) 算法。该方法的核心思想是利用原始种群与准反射种群的双模协同优化机制，通过双向精英迁移策略实现种群间的优势互补和信息共享。并对算法的种群更新策略进行了改进，分别在算法的开发和探索阶段融合黄金正弦优化和柯西变异策略，以提升算法的全局搜索能力和局部开发能力。

1 问题建模

假设在三维空间中存在 m 个监测站，监测站坐标为 $\mathbf{c}_{b_i} = (x_i, y_i, z_i)^T \in \mathbb{R}^{3 \times 1}$ ，目标位置为 $\mathbf{c}_o = (x, y, z)^T \in \mathbb{R}^{3 \times 1}$ ，以监测站 b_1 为原点构建三维空间监测站与目标几何关系示意图，如图 1 所示。选择监测站为 b_i 参考节点计算 TDOA 值，通过测量目标 o 到监测站 b_i 和目标到其他监测站 $b_j (j \neq i)$ 的信号到达时间，可以得到各监测站与监测站 b_i 之间的信号到达时间差信息 $\tau_{(j,i)}$ ，通过测量目标到达各监测站的方位角和俯仰角可以得到角度信息 (α_i, β_i) 。由于受到噪声的影响，测量值存在误差，测量误差可以认为是 0 均值的高斯噪声^[14]。

根据图 1 监测站和目标间的几何关系，可以得到方位角、俯仰角与检测站和目标坐标间的关系：

$$\alpha_i = \arctan\left(\frac{y - y_i}{x - x_i}\right) \quad (1)$$

$$\beta_i = \arctan\left(\frac{z - z_i}{\sqrt{(x - x_i)^2 + (y - y_i)^2}}\right) \quad (2)$$

式中， α_i 和 β_i 分别为方位角和俯仰角的理论值，根据目标位置和监测站位置计算得到。




图 1 三维空间监测站与目标间几何关系示意图

Fig1 The schematic diagram of the geometric relationship between the three-dimensional space monitoring station and the target

由于存在测量噪声, 实际测量的方位角和俯仰角存在误差

$$\hat{\alpha}_i = \alpha_i + \varepsilon_{\alpha_i}, \hat{\beta}_i = \beta_i + \varepsilon_{\beta_i} \quad (3)$$

式中, $\hat{\alpha}_i$ 和 $\hat{\beta}_i$ 分别为监测站方位角和俯仰角的实际测量值, ε_{α_i} 和 ε_{β_i} 分别为方位角和俯仰角的测量误差, 假设为零均值、方差为 σ_{α}^2 和 σ_{β}^2 的高斯噪声。

在 AOA 定位中, 目标的位置通过估计信号的到达角度来推算。可以基于观测到的角度数据, 利用最大似然估计, 最大化目标位置的似然函数。

对于每个监测站 b_i , 测得的方位角 α_i 和俯仰角 β_i 都受到高斯噪声影响, 似然函数为:

$$M_{AOA} = \prod_{i=1}^{n_{AOA}} \frac{1}{\sqrt{2\pi\sigma_{\alpha}^2}} \cdot e^{-\frac{(\hat{\alpha}_i - \arctan(\frac{y-y_i}{x-x_i}))^2}{2\sigma_{\alpha}^2}} \cdot \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma_{\beta}^2}} \cdot e^{-\frac{(\hat{\beta}_i - \arctan(\frac{z-z_i}{\sqrt{(x-x_i)^2 + (y-y_i)^2}}))}{2\sigma_{\beta}^2}} \quad (4)$$

式中, n_{AOA} 为使用 AOA 定位某个目标时使用的监测站个数。

监测站 b_i 到目标的距离定义为

$$l_i = \sqrt{(x-x_i)^2 + (y-y_i)^2 + (z-z_i)^2} \quad (5)$$

选择监测站为 b_1 参考节点计算 TDOA 值, 通过测量目标 o 到监测站 b_1 和目标到其他监测站 b_i 的信号到达时间, 可以得到各监测站与监测站 b_1 之间的信号到达时间差信息 $\hat{\tau}_{(i,1)}$ 。

信号从目标到各监测站与参考监测站 b_1 的理论时间差为:

$$\tau_{(j,1)} = \frac{l_j - l_1}{c} \quad (6)$$

式中, c 为信号传播速度。

同样, 实际测量的时间差 $\hat{\tau}_{(i,1)}$ 受到噪声的影响, 假设测量误差为零均值、方差为 σ_{TDOA}^2 的高斯噪声:

$$\hat{\tau}_{(i,1)} = \tau_{(i,1)} + \varepsilon_{\tau_{(i,1)}} \quad (7)$$

式中, $\varepsilon_{\tau_{(i,1)}}$ 为时间测量误差。

由此, 可得基于测量数据得到的目标到监测站与目标到参考监测站的距离差

$$c \cdot \hat{\tau}_{(i,1)} = c \cdot \tau_{(i,1)} + c \cdot \varepsilon_{\tau_{(i,1)}} \quad (8)$$

即 $l_{i1} = l_i - l_1 + e_{j1}$, 其中 l_i 、 l_1 分别为监测站 b_i 和监测站 b_1 到目标的实际距离, e_{i1} 为测量误差。

$$e_{i1} = e_i - e_1 = c \cdot \varepsilon_{\tau_{(i,1)}} \quad (9)$$

综合上述内容, 可以建立 TDOA 定位双曲线方程, 用最大似然估计的方法来估计目标节点的位置坐标。

$$M_{TDOA} = \prod_{i=2}^{n_{TDOA}} \frac{1}{\sqrt{2\pi\sigma_{TDOA}^2}} \cdot e^{-\frac{(c \cdot \hat{\tau}_{(i,1)} - l_i + l_1)^2}{2\sigma_{TDOA}^2}} \quad (10)$$

式中, n_{TDOA} 为使用 TDOA 定位某个目标时使用的监测站个数。

将 TDOA 和 AOA 联合使用时, 似然函数需要同时考虑到 TDOA 和 AOA 的误差。联合似然函数可以表示为:

$$M_{joint} = M_{AOA} \cdot M_{TDOA} \quad (11)$$

对式(11)取对数, 构造对数似然函数进一步求解。求解目标坐标 (x, y, z) 的最大似然估计值, 相当于求解式(12):

$$(\hat{x}, \hat{y}, \hat{z}) = \arg \min \left[\sum_{i=2}^n (c \cdot \hat{\tau}_{(i,1)} - l_i + l_1)^2 + \sum_{i=1}^n (\hat{\alpha}_i - \arctan(\frac{y-y_i}{x-x_i}))^2 + \sum_{i=1}^n (\hat{\beta}_i - \arctan(\frac{z-z_i}{\sqrt{(x-x_i)^2 + (y-y_i)^2}}))^2 \right] \quad (12)$$

式(12)即为联合定位目标函数, 其目标是通过最小化定位误差平方和, 实现对目标位置的估计。该函数具有高度非线性, 存在多个局部最优解。同时, 由于 TDOA 与 AOA 两种异构测量方式之间存在复杂的耦合项, 使得优化过程难以分解, 且模型性能易受到测量噪声的干扰, 从而对算法的鲁棒性和稳定性提出了更高要求。这一联合定位问题因而难以通过解析方法获得精确解, 但其结构特征适合采用启发式算法进行全局搜索与优化。

为此, 本文采用改进的哈里斯鹰优化算法对式(12)所定义的目标函数进行求解。目标函数刻画了某一候选位置与多基站 TDOA-AOA 测量值之间的误差, 其数值越小, 表示候选位置越接近真实目标。

式(13)为约束条件, 定义了目标节点在任务区域内的空间边界, 确保算法仅在可行区域内进行定位估计。

$$\begin{cases} x_{\min} \leq x \leq x_{\max} \\ y_{\min} \leq y \leq y_{\max} \\ z_{\min} \leq z \leq z_{\max} \end{cases} \quad (13)$$

给定算法输入: 监测站三维坐标

$\{s_1, s_2, \dots, s_m\}$ 、目标与监测站 i 和监测站 j 之间的 TDOA 观测值 $\{\Delta t_{ij}\}$ 、和监测站 i 接收到目标信号的 AOA 观测值。在上述目标函数和约束条件的基础上, HHO 算法求解流程可总结为以下 5 个步骤:

1)种群初始化。设定种群规模, 在给定搜索空间内生成初始种群, 种群每个个体表示一个潜在的目标位置 $x_i = [x_i, y_i, z_i]^T$ 。

2)适应度评估。对于每个个体, 代入目标函数计算其适应度值。适应度越小表示估计误差越小, 定位精度越高。

3)种群迭代更新。基于 HHO 算法特有的动态捕猎机制, 结合种群个体间的信息交互, 迭代生成新一代候选解。

4)边界处理与收敛判定。在个体更新过程中对位置进行边界约束, 确保搜索始终在可行解空间内进行。设置最大迭代次数作为收敛判据, 达到指定迭代轮数或满足精度条件时停止算法执行。

5)输出最优解。迭代结束后, 输出使目标函数最小的个体所对应的位置向量作为目标的最终估计坐标。

2 基于混合策略改进的 HHO 算法

2.1 HHO 算法

HHO 算法设计灵感来源于哈里斯鹰在捕食猎物过程中的合作行为以及突然袭击的狩猎风格, 算法的寻优过程包括探索、探索与开发过渡和开发三个阶段。

1)探索阶段

在探索阶段哈里斯鹰通过两种策略搜索猎物位置:

①基于猎物位置的策略(概率 $p < 0.5$)

$$X(t+1) = X_{rand}(t) - r_1 \cdot |X_{rand}(t) - 2r_2 \cdot X(t)| \quad (14)$$

式中, t 为当前迭代次数, $X(t)$ 为当前个体位置, $X_{rand}(t)$ 为随机选择的个体位置, r_1 和 r_2 为 $[0,1]$ 之间的随机数。

②随机栖息策略($p \geq 0.5$)

$$X(t+1) = [X_{rabbit}(t) - X_{mean}(t)] - r_3 \cdot [l_b + r_4 \cdot (u_b - l_b)] \quad (15)$$

式中, $X_{rabbit}(t)$ 为当前最优个体位置, $X_{mean}(t)$ 为种群平均位置, r_3 和 r_4 为 $[0,1]$ 之间的随机数, u_b 和 l_b 分别为搜索空间的上界和下界。

2)探索与开发过渡阶段

猎物能量 E 随迭代次数递减, 控制算法阶段切换:

$$E = 2E_0 \cdot (1 - \frac{t}{T}) \quad (16)$$

式中, $E_0 \in [-1,1]$, 表示初始能量, T 表示最大迭代次数。

当 $|E| \geq 1$ 时继续探索阶段, 当 $|E| < 1$ 时进入开发阶段。

3)开发阶段

根据猎物逃逸能量 E 和随机跳跃强度 S_p , 采用四种捕猎策略:

①软包围($|E| \geq 0.5$ 且 $S_p \geq 0.5$)

$$X(t+1) = \Delta X(t) - E \cdot |J \cdot X_{rabbit}(t) - X(t)| \quad (17)$$

式中, $\Delta X(t) = X_{rabbit}(t) - X(t)$, J 为猎物跳跃强度且 $J = 2(1 - r_5)$, 其中 $r_5 \in [0,1]$ 。

②硬包围($|E| < 0.5$ 且 $S_p \geq 0.5$)

$$X(t+1) = X_{rabbit}(t) - E \cdot |\Delta X(t)| \quad (18)$$

③渐进式快速俯冲软包围($|E| \geq 0.5$ 且 $S_p < 0.5$)

首先进行 Levy 飞行扰动:

$$Y = X_{rabbit}(t) - E \cdot |JX_{rabbit}(t) - X(t)| \quad (19)$$

再判断是否改进:

$$X(t+1) = \begin{cases} Y & \text{if } Y_{fitness} < X(t)_{fitness} \\ Z & \text{otherwise} \end{cases} \quad (20)$$

式中, $Z = Y + S \cdot LF(D)$, 其中 $LF(*)$ 为 Levy 函数, D 为问题维度, S 为随机向量。

④渐进式快速俯冲硬包围($|E| < 0.5$ 且 $S_p < 0.5$)

$$Y = X_{rabbit}(t) - E \cdot |JX_{rabbit}(t) - X_{mean}(t)| \quad (21)$$

$$X(t+1) = \begin{cases} Y & \text{if } Y_{fitness} < X(t)_{fitness} \\ Z & \text{otherwise} \end{cases} \quad (22)$$

2.2 HSHHO 算法

AOA-TDOA 定位问题融合了两种不同的观测模型, 其目标函数常呈现出高度非凸和众多局部极值的特点。同时, 实际测量过程中常受环境噪声、硬件延迟和同步误差等因素影响, 增加了解的敏感性与不确定性。传统 HHO 算法在局部搜索时容易陷入局部最优并提前收敛, 而初期种群探索分布不均也会影响求解效果。因此, 有必要对 HHO 算法进行多方面改进, 以提高其在解决 AOA-TDOA 定位问题时搜索全局最优解的能力和鲁棒性。具体改进如下:

首先, 提出一种基于原始种群与准反射种群的双模协同优化机制。该机制通过生成准反射解以拓展搜索空间, 并通过两个种群间的信息共享与优势互补, 提升算法的收敛速度、稳定性和全局搜索能力。

基于对称解空间映射原理, 准反射种群 $M^{qr} = \{X_0^{qr}, X_1^{qr}, \dots, X_n^{qr}\}$ 通过准反射操作^[26]生

成:

$$\begin{cases} X_i^{qr} = X_0 + r \cdot (X_i - X_0), X_0 < X_i \\ X_i^{qr} = X_0 + r \cdot (X_0 - X_i), X_0 \geq X_i \end{cases} \quad (23)$$

式中, $r \in [0,1]$, $X_0 = \frac{l_b + u_b}{2}$ 。

在每次迭代中, 引入双向精英迁移策略。利用原始种群中的最优个体替换准反射种群中的最差个体, 同时将准反射种群中表现最优的个体替换原始种群中的最差个体, 以实现两种种群之间的优势互补和信息共享。

其次, 对种群更新策略进行改进, 以提升算法的全局搜索和局部探索能力。具体改进如下:

1) 融合黄金正弦优化的探索阶段种群搜索优化

黄金正弦优化是一种基于黄金分割比和正弦函数设计的全局优化方法, 通过模拟黄金分割在优化搜索中的作用, 并结合正弦扰动, 使算法在初期具有较强的全局搜索能力, 后期则更容易收敛到全局最优。

将黄金正弦优化机制引入标准算法探索阶段种群更新中, 将探索阶段原始算法种群更新公式(14)和(15)改为

$$\begin{cases} X(t+1) = X_{rand}(t) \cdot \sin(r_1) \\ \quad - (r_2 + e) \cdot \sin(r_1) \cdot (G_1 \cdot u_b - G_2 \cdot l_b), p < 0.5 \\ X(t+1) = [X_{rabbit}(t) - X_{mean}(t)] \cdot \sin(r_3) \\ \quad - (r_4 + e) \cdot \sin(r_3) \cdot (G_1 \cdot u_b - G_2 \cdot l_b), p \geq 0.5 \end{cases} \quad (24)$$

式中, G_1 为黄金分割比例, $G_1 = (1 - 0.5\sqrt{5}) \cdot \pi$; $G_2 = 1 - G_1$; r_1 、 r_2 、 r_3 、 r_4 为取值 0~1 之间的随机数。

2) 融合柯西变异策略的局部搜索优化

HHO 算法在开发阶段前期易因局部搜索倾向导致个体快速聚集至狭窄区域, 引发早熟收敛问题。通过嵌入柯西变异算子, 利用其宽峰厚尾特性增强算法局部搜索前期的全局扰动能力, 从而延缓局部最优陷阱的形成。具体实现如下:

①式(17)软包围过程策略改进:

$$X(t+1) = \Delta X(t) - E \cdot |J \cdot X_{rabbit}(t) - X(t)| + \gamma \cdot C(0, \sigma) \quad (25)$$

式中, γ 为缩放因子, 通常设置为一个较小的正数以控制变异幅度, 本文取 $\gamma = 0.1$; $C(0, \sigma)$ 为以 0 为均值, σ 为尺度参数的柯西分布, 其概率密度函数为:

$$f(x) = \frac{1}{\pi \cdot \sigma \cdot \left(1 + \left(\frac{x}{\sigma}\right)^2\right)} \quad (26)$$

本文取 $\sigma = 1$ 。

②式(19)渐进式快速俯冲软包围过程策略改进:

$$X(t+1) = X_{rabbit}(t) - E \cdot |\Delta X(t)| + \gamma \cdot C(0, \sigma) \quad (27)$$

结合 AOA-TDOA 定位问题的实际特点, 上述改进方案具有以下优势: (1)通过异构种群的协同探索扩展搜索空间, 并结合动态信息共享机制加速算法收敛, 能有效提升算法收敛速度。(2)通过融合黄金正弦更新和柯西变异策略, 兼顾全局探索与局部微调能力, 使算法能够更好地适应 AOA-TDOA 定位问题中目标函数复杂、多峰的特性。

SHSHO 算法流程如图 2 所示。SHSHO 算法在种群寻优过程遵循 HHO 的基础框架, 其整体流程主要包括下面 5 个步骤:

步骤 1: 算法参数设置—设定种群规模 n 、最大迭代次数 T 、问题维度 D 以及搜索空间上下界 $[l_b, u_b]$ 。

步骤 2: 种群初始化—在搜索空间内利用 Sobol 序列初始化, 生成均匀分布的原始种群 M , 并通过准反射学习机制构建与之同等规模的准反射种群 M_r 。

步骤 3: 双种群同步迭代更新—每次迭代基于融合黄金正弦与柯西变异的更新策略更新种群 M 和 M_r 。在每次迭代时, 动态更新猎物逃逸能量 E , 并生成随机概率 p 和随机跳跃概率 Sp 。根据这三个参数的取值情况, 在算法的不同阶段采用相应的策略更新种群:

1) 在探索阶段 ($E \geq 1$), 基于式(25)定义的黄金正弦优化机制更新种群;

2) 在软包围阶段 ($0.5 \leq E < 1$), 当随机跳跃概率 $Sp \geq 0.5$ 时, 采用式(26)定义的柯西变异软包围更新策略更新种群, 当 $Sp < 0.5$ 时, 采用式(27)定义的柯西变异渐进式快速软包围策略更新种群;

3) 在硬包围阶段 ($E < 0.5$), 采用原始 HHO 算法中的硬包围更新策略更新种群。

步骤 4: 双向精英个体迁移—在每次迭代中, 分别用原始种群 M 中的最佳个体替换准反射种群 M_r 中的最差个体, 同时用准反射种群 M_r 中的最佳个体替换原始种群 M 中的最差个体。

步骤 5: 终止条件判断与最优解输出—若当前迭代次数达到设定的最大值, 输出原始种群 M 中的最优个体 X_{Best} 作为最终解; 否则返回步骤 3 和步骤 4, 继续迭代优化。

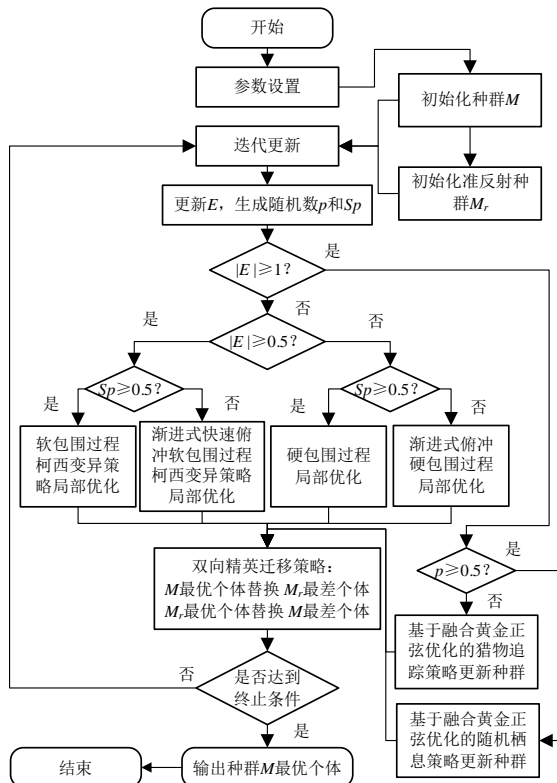


图2 HSHHO 算法流程
Fig2 HSHHO algorithm procedure

为检验 HSHHO 算法的性能, 本文共设计 3 组实验: 实验 1 通过对不同改进策略在基准测试函数上的性能进行对比分析; 实验 2 通过 HSHHO 算法与 5 种智能算法在基准测试函数上的性能进行对比分析; 实验 3 在具体的复杂定位场景下, 比较 HSHHO 算法与实验 2 中的 5 种智能算法及不同改进策略在定位精度和收敛速度的差异。

本文实验均基于 python3.9 进行。实验 1 和实验 2 种群规模 $n = 30$, 最大迭代次数 $T = 400$, 在 6 个基准测试函数上分别独立运行 50 次来检验本文算法的改进性能。这些基准测试函数包括 3 个单峰函数 Sphere 函数、Rosenbrock 函数和 Schwefel 1.2 函数, 分别记为 f_1 、 f_2 和 f_3 ; 2 个多峰函数 Ackley 函数和 Penalized1 函数, 分别记为 f_4 和 f_5 ; 1 个固定维度多峰函数 Kowalik 函数, 记为 f_6 。

3.1 改进策略有效性分析

为验证不同改进策略的有效性, 本文将结合黄金正弦优化的 HHO 算法(HHO-1)、融合柯西变异策略的局部搜索优化的 HHO 算法(HHO-2)以及基于原始种群与准反射种群的双模协同优化的 HHO 算法(HHO-3)分别与原始 HHO 算法和 HSHHO 算法在多个基准测试函数上的寻优性能进行对比。

3 实验与仿真分析

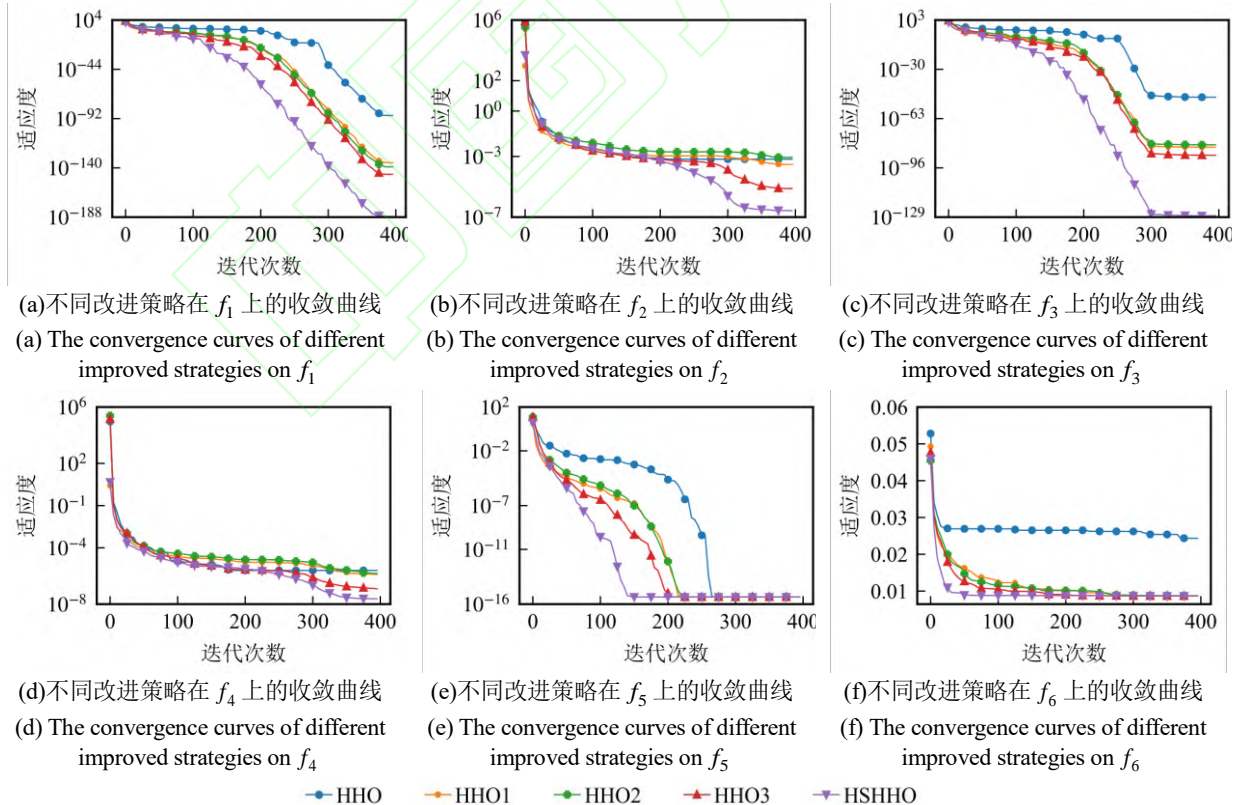


图3 不同改进策略在基准函数上的收敛曲线
Fig3 The convergence curves of different improved strategies on the benchmark function

在问题维度 $D=10$ 条件下, 各算法在不同基准测试函数中的适应度收敛特性如图 3 所示。结果表明, 3 种改进策略均在不同程度上提升了 HSHHO 算法的优化性能。这是由于黄金正弦机制与柯西变异分别增强了全局探索和局部开发能力, 有效规避了陷入局部最优的问题, 从而提升了在基准测试函数中的优化效果。此外, 采用异构种群协同优化机制能有效增强算法的全局搜索与局部开发能力。融合上述 3 种策略优势的 HSHHO 算法实现了全局探索与局部开发的有机协同, 最终展现出最优的性能。

3.2 不同算法在基准函数测试中的性能对比分析

为证明本文所提算法相较其他智能算法的优势, 将 HSHHO 算法与樽海鞘算法^[13](SSA)、鸽群优化算法^[27](PIO)、改进哈里斯鹰算法^[12](IHHO)、改进灰狼优化算法^[20](IGWO)、基于反向学习的混沌映射自适应粒子群算法^[28](OAPSO)在问题维度 $D=10$ 条件下进行对比分析。以平均值、标准差和最优值作为性能评价指标, 各算法在基准函数的仿真对比结果如表 1 所示。

表 1 不同算法对比结果
Tab1 Comparison results of different algorithms

函数	值类型	SSA	PIO	HSHHO	IHHO	IGWO	OAPSO
f_1	最优值	1.62E-05	7.21E-04	1.47E-247	0.00E+00	1.91E-05	7.24E-05
	平均值	4.35E-01	5.97E-03	4.11E-190	6.40E-23	9.00E-05	2.04E-04
	标准差	1.08E+00	7.08E-03	0.00E+00	4.48E-22	2.84E-05	7.30E-05
f_2	最优值	2.98E+00	2.43E+00	1.39E-11	2.76E-08	8.59E-01	1.01E-02
	平均值	7.48E+01	2.89E+01	1.36E-06	2.59E-04	2.27E+00	5.43E+03
	标准差	1.82E+02	3.78E+01	4.95E-06	4.69E-04	4.41E-01	2.14E+04
f_3	最优值	2.13E-02	1.30E-03	1.36E-180	1.37E-93	4.29E-05	1.08E-04
	平均值	9.57E-01	2.32E-02	9.52E-112	6.88E-54	1.32E-04	2.06E-04
	标准差	1.57E+00	1.62E-02	6.66E-111	4.27E-53	4.89E-05	7.36E-05
f_4	最优值	1.02E-04	4.21E-06	6.67E-11	4.37E-10	3.33E-06	6.89E-05
	平均值	1.60E+00	6.24E-02	3.10E-08	1.78E-06	8.72E-06	3.56E-04
	标准差	2.06E+00	2.06E-01	4.95E-08	3.43E-06	3.71E-06	1.35E-04
f_5	最优值	5.84E-03	5.83E-03	4.44E-16	4.44E-16	7.88E-03	3.38E-04
	平均值	2.64E+00	7.74E-02	4.44E-16	4.44E-16	1.25E-02	7.97E-04
	标准差	1.59E+00	2.21E-01	0.00E+00	0.00E+00	2.26E-03	1.77E-04
f_6	最优值	8.63E-03	8.63E-03	8.61E-03	8.62E-03	8.63E-03	8.63E-03
	平均值	1.05E-02	1.00E-02	8.67E-03	2.52E-02	8.63E-03	8.66E-03
	标准差	4.87E-03	5.38E-03	1.16E-04	1.09E-02	1.89E-06	3.64E-05

在基准测试函数中, SSA 整体表现不稳定, 尤其在单峰函数中最优值偏大, 表明其局部开发能力不足; 在多峰函数上尽管最优值尚可, 但平均值和标准差偏高, 易陷入局部最优, 主要原因在于其探索与开发不平衡。PIO 在所有测试函数上表现较弱, 尤其在单峰函数中平均值和标准差均高, 反映出其局部搜索和跳出局部最优能力不足, 这与其缺乏有效扰动机制有关。HSHHO 在各类测试函数中均表现出优异性能, 最优值接近理论最优值, 且平均值与标准差极小, 显示出良好的全局收敛性和局部开发能力, 其性能提升得益于异构种群协同机制以及黄金正弦与柯西变异策略的引入。IHHO 通过 Chan 算法改进初始种群

质量, 整体表现良好, 但由于缺乏更新机制优化, 其局部搜索性能仍弱于 HSHHO。IGWO 在各测试函数中整体表现良好, 通过引入差分扰动与邻域机制, 在一定程度上增强了原始 GWO 的局部开发能力。然而, 其未针对局部最优陷阱进行有效改进, 导致在陷入局部极值区域后易出现性能下降的问题, 导致其平均性能略逊于 HHO 类算法。OAPSO 虽在 PSO 框架中融合反向学习、动态惯性权重与混沌扰动, 但由于仍采用标准的 PSO 更新策略, 局部开发能力有限, 且混沌扰动的随机性可能影响搜索稳定性, 难以有效摆脱局部极值陷阱。

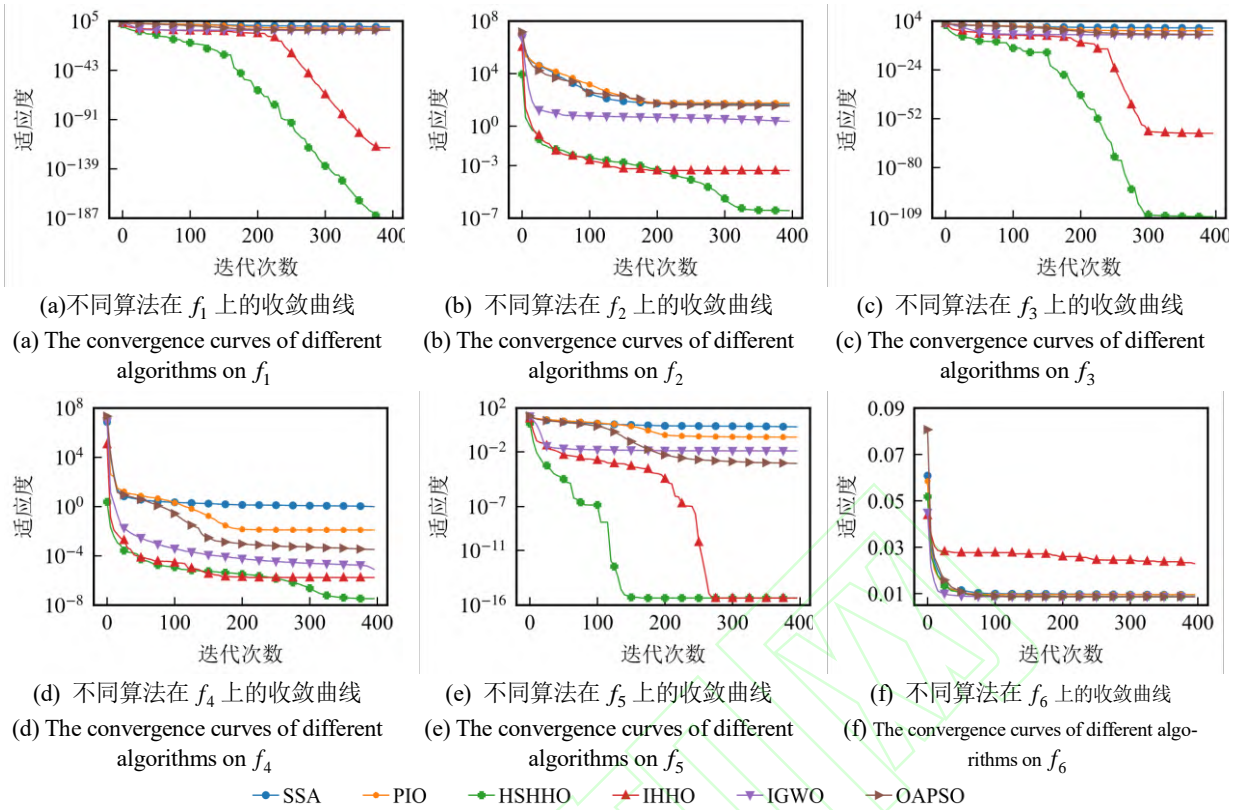


图4 不同算法适应度收敛曲线

Fig4 The fitness convergence curve of different algorithms

为更加直观地展示不同算法的性能差异，图4展示了6种算法基准测试函数独立运行30次的平均收敛曲线。在单峰函数 f_1 、 f_2 和 f_3 上，HSHHO 算法的适应度下降速度明显快于其他算法，且最终收敛值更接近理论最优值，表明其具备更强的局部开发能力和收敛速度。对于多峰函数 f_4 、 f_5 ，HSHHO 同样保持优异性能。表明其具有更强的全局探索能力和跳出局部最优的能力。

综合6个基准测试函数的收敛性能对比结果可知，HSHHO 在全局探索与局部开发能力之间取得了良好平衡，能够在较短时间内找到更优解，相比其他算法具有更高的优化效率。

3.3 定位模型仿真分析

定位场景设定为一个宽度40km、纵深40km、高度0.05km的三维空间，整个空间内部署4个蓝方测量节点，其坐标分别为(30.93, 1.86, 0.05)，(30.83, 25.81, 0.05)，(14.46, 21.13, 0.05)，(9.99, 0.79, 0.05)，红方未知通信节点坐标为(10, 15, 0)，各坐标值单位均为 km。搜索空间的上界和下界分别为 $u_b = [40, 40, 0.5]$ (单位: km) 和 $l_b = [0, 0, 0]$ (单位: km)。实验最大迭代次数设置为250次，TDOA 误差标准差、AOA 方位角误差标准差和俯仰角误差标准差分别设置为 100m、 0.1° 和 0.05° 。以均方根误差 (root mean square error, RMSE) 作为定位精度的评价指标。

在种群规模固定为30的情况下，通过观察不

同算法的适应度迭代曲线来分析各算法的收敛性能。图5展示了各优化算法在迭代过程中的适应度变化趋势。总体来看，HSHHO 算法在较少的迭代次数内即可获得优质解，并在后续迭代中持续优化，体现出良好的全局搜索与局部开发能力的平衡性。

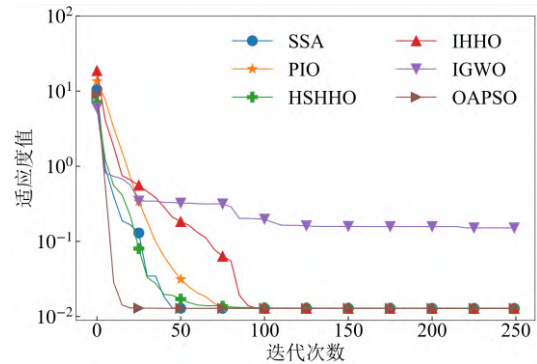


图5 不同算法适应度值随迭代次数的变化情况

Fig5 The variation of the fitness value of different algorithms with the number of iterations

图6展示了各算法在迭代过程中RMSE值的变化趋势。迭代结束后SSA、PIO、HSHHO、IHHO、IGWO和OAPSO的RMSE值分别为57.16m、61.41m、22.31m、66.00m、347.55m和54.17m。所有算法在迭代初期RMSE值均呈现显著的下降趋势，随后逐渐趋于稳定。其中，HSHHO 算法展现出最优的定位精度，表现出快速收敛特性与持续跳出局部最优的能力。SSA、PIO与OAPSO算法尽管在收敛趋势和最终误差方面表现相近，

且误差相对较低，但在后期缺乏摆脱局部极值的能力，限制了进一步优化空间。而 IGWO 算法在优化过程中频繁陷入局部最优，导致最终误差显著偏高。

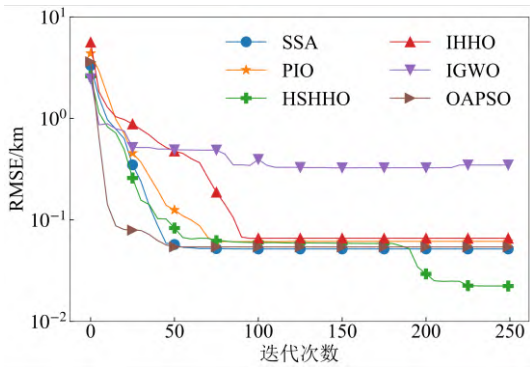


图 6 不同算法 RMSE 值与迭代次数的关系


Fig6 The relationship between RMSE value and iteration times of different algorithms

实验结果表明，HSHHO 算法通过混合策略设计有效平衡了全局探索与局部开发过程，在非凸多峰优化的 AOA-TDOA 联合定位问题中表现出更强的适应性和鲁棒性。该算法在噪声干扰环境下仍保持高精度稳定定位的特性，验证了其在复杂场景中的工程实用潜力。

值得注意的是，尽管 IGWO 算法在基准测试函数中表现良好，但在 AOA-TDOA 联合定位问题中却呈现出最差的性能。这一现象可能源于其邻域构建策略的局限性：IGWO 仅基于个体适应度的排序来选择邻域个体，而忽略了搜索空间中个体的几何分布和拓扑结构，导致所构建的邻域缺乏代表性。在应对 AOA-TDOA 目标函数时，这种结构容易引导搜索沿错误方向扰动，削弱算法的局部开发能力，进而增加陷入局部最优解的风险。


此外，SSA 算法、PIO 算法和 OAOAPSO 算法在 AOA-TDOA 联合定位问题中的表现显著优于其在基准测试函数中的性能。这一差异可能源于问题维度的不同。在基准测试中，较高的维度增加了搜索空间的复杂性与稀疏性，从而提升了收敛难度，导致算法难以找到最优解。而在 AOA-TDOA 联合定位问题中，由于问题维度较低，搜索空间更为集中，使得这些算法能更有效地执行局部搜索，从而在定位任务中获得更优的性能表现。

为进一步验证各改进策略的有效性，本文在最大迭代次数固定为 250 次的条件下，对不同策略在定位精度方面的表现进行了对比分析。



(a) 不同改进策略适应度变化情况

(a) The variation of the fitness of different improved strategies



(b) 不同改进策略 RMSE 值变化情况

(b) The change of RMSE value of different improved strategies

图 7 不同改进策略的动态收敛特性

Fig7 Dynamic convergence characteristics of different improved strategies

图 7 展示了各算法的 RMSE 动态收敛曲线。实验结果表明，所有改进算法在不同程度上均显著提升了原始 HHO 算法的定位性能，HHO-1 引入黄金正弦优化机制，其周期性振荡特性增强了算法的全局探索能力，有效避免陷入局部最优，提升了定位精度，降低了 RMSE 值；HHO-2 嵌入柯西变异算子，利用其宽峰厚尾分布特性，在局部搜索初期提供了更强的扰动能力，显著提升了对最优解的局部搜索精度；HHO-3 采用基于原始种群与准反射种群的双模协同优化机制，通过种群间的信息交互提升搜索多样性，缓解了单一群体易出现的早熟收敛问题。融合三种改进策略优势的 HSHHO 算法实现了全局搜索与局部开发的平衡。在 AOA-TDOA 定位任务中，HSHHO 展现出更快的收敛速度和更高的定位精度，在适应度与 RMSE 指标上均最优。

4 结论

本文针对传统 AOA-TDOA 联合定位方法在复杂环境中存在的局部搜索能力弱、易陷入局部最优解和收敛速度慢等问题，提出了一种融合多种改进策略的哈里斯鹰优化算法 HSHHO。

在多个基准测试函数和 AOA-TDOA 联合定位任务的仿真实验中验证了各项改进策略的有效性。与对比算法相比，HSHHO 在全局探索和局

部开发能力之间取得了良好的平衡,能够在较短时间内找到更优解,且在多个基准测试函数中展现了更高的求解性能。此外,在 AOA-TDOA 联合定位任务的仿真实验中, HSHHO 能在较少的迭代次数内获得较优解,并在后续阶段持续优化。与其他算法相比,其 RMSE 收敛曲线下下降速度更快,最终定位误差更低,表明其在实际复杂定位场景中具备更优的性能。

综上所述, HSHHO 算法通过多策略融合,实现了全局搜索能力、局部开发能力和种群协同机制的有机结合。它不仅在基准测试函数中优于现有优化算法,还在 AOA-TDOA 联合定位任务中展现了卓越的定位精度和工程实用价值,为后续在复杂优化与精确定位领域的研究提供了有效的参考方向。

参考文献

- [1] YASSIN M, RACHID E. A survey of positioning techniques and location based services in wireless networks[C]//Proceedings of the IEEE International Conference on Signal Processing, Informatics, Communication and Energy Systems (SPICES), 2015.
- [2] CHEN C, LU C, LIN J, et al. Hybrid TDOA/AOA geometrical positioning schemes for MS location estimation[J]. International Journal of Advancements in Computing Technology, 2013, 5(2): 723-730.
- [3] TERÇAS L, ALVES H, DE LIMA C H M, et al. Bayesian-based indoor factory positioning using AOA, TDOA, and hybrid measurements[J]. IEEE Internet of Things Journal, 2024, 11(12): 21620-21631.
- [4] ZAIDI M M, ASIRI A A, BOUAZZI I R. Simple digital design to optimize TDOA algorithm reducing energy consumption: WSN for forest fire localization[C]//Proceedings of the 5th International Conference on Mobile Computing and Sustainable Informatics (ICMCSI), 2024.
- [5] WEINZIERL D, HOFMANN C A, KNOPP A. Blind geolocation of RF-signals with LEO satellite formations[C]//Proceedings of the MILCOM 2023 - 2023 IEEE Military Communications Conference (MILCOM), 2023.
- [6] JIA T Y, WANG H Y, SHEN X H, et al. Target localization based on structured total least squares with hybrid TDOA-AOA measurements[J]. Signal Processing, 2018, 143: 211-221.
- [7] WANG G, SO A M, LI Y M. Robust convex approximation methods for TDOA-based localization under NLOS conditions[J]. IEEE Transactions on Signal Processing, 2016, 64(13): 3281-3296.
- [8] HU T, LI Y H, ZHANG W G. Compensated TDOA and AOA based fusion localization algorithm for wireless sensor networks[C]//Proceedings of the 4th International Conference on Computer Science and Blockchain (CCSB), 2024.
- [9] FU Y F, TIAN Z. Cramer-Rao bounds for hybrid TOA/DOA-based location estimation in sensor networks[J]. IEEE Signal Processing Letters, 2009, 16(8): 655-658.
- [10] SHEN Y, WIN M Z. Fundamental limits of wideband localization: part I: a general framework[J]. IEEE Transactions on Information Theory, 2010, 56(10): 4956-4980.
- [11] 刘倩, 夏斌, 谢楠, 等. 基于多元 Taylor 级数和 AFS 的混合定位算法[J]. 计算机仿真, 2020, 37(4): 290-293, 370.
LIU Q, XIA B, XIE N, et al. Hybrid localization algorithm based on multivariable Taylor series and artificial fish swarm[J]. Computer Simulation, 2020, 37(4): 290-293, 370. (in Chinese)
- [12] 马一鸣, 石志东, 赵康, 等. 基于改进哈里斯鹰优化算法的 TDOA 定位[J]. 计算机工程. 2020, 46(12): 179-184.
MA Y M, SHI Z D, ZHAO K, et al. TDOA Localization Based on Improved Harris Hawk Optimization Algorithm[J]. COMPUTER ENGINEERING. 2020, 46(12): 179-184. (in Chinese)
- [13] 陈涛, 王梦馨, 黄湘松. 基于樽海鞘群算法的无源时差定位[J]. 电子与信息学报, 2018, 40(7): 1591-1597.
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. (in Chinese)
- [14] 苟平章, 孙梦源, 刘学治, 等. 基于天牛须搜索优化的 TDOA 三维节点定位算法[J]. 传感器与微系统, 2022, 41(10): 141-144.
GOU P Z, SUN M Y, LIU X Z, et al. 3D node localization algorithm based on optimization of BAS[J]. Transducer and Microsystem Technologies, 2022, 41(10): 141-144. (in Chinese)
- [15] YAO J, LI J, WANG L, et al. Wireless sensor network localization based on improved particle swarm optimization [C]// Proceedings of the 2012 International Conference on Computing, Measurement, Control and Sensor Network. IEEE, 2012.
- [16] 刘艺, 秦伟, 李庚松, 等. 面向混合特征数据的粒子群填补方法[J]. 国防科技大学学报, 2024, 46(6): 107-112.
LIU Y, QIN W, LI G S, et al. Particle swarm optimization based data imputation method for mixed features[J]. Journal of National University of Defense Technology, 2024, 46(6): 107-112. (in Chinese)
- [17] REN Q Q, ZHANG Y, NIKOLAIDIS I, et al. RSSI quantization and genetic algorithm based localization in wireless sensor networks[J]. Ad Hoc Networks, 2020, 107: 102255.

- [18] 国强, 王亚妮, 袁鼎, 等. 基于改进整型遗传算法的稀疏矩形平面阵列优化[J]. 国防科技大学学报, 2023, 45(2): 105-111.
GUO Q, WANG Y N, YUAN D, et al. Optimization of sparse rectangular planar array using modified integer genetic algorithm[J]. Journal of National University of Defense Technology, 2023, 45(2): 105-111. (in Chinese)
- [19] XU Z Q. Wireless sensor network localization incorporating gray wolf optimization and DV-hop algorithm[J]. IEEE Access, 2024, 12: 168594-168606.
- [20] WR S J, T J, K V K, et al. Improved grey wolf optimization based node localization approach in underwater wireless sensor networks[J]. Measurement Science Review, 2024, 24(3): 95-99.
- [21] AROBA O J, NAICKER N, ADELIYI T T. Node localization in wireless sensor networks using a hyper-heuristic DEEC-Gaussian gradient distance algorithm[J]. Scientific African, 2023, 19: e01560.
- [22] ARUL S B, JEBASELVI G D A. Enhancing wireless sensor network localization using hybrid PSO and FF algorithms [C]// Proceedings of the 2023 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems (ICSSES). IEEE, 2023.
- [23] LI H F, CHEN B Y, HUANG J W, et al. Clustering-assisted gradient-based optimizer for scheduling parallel cloud workflows with budget constraints[J]. The Journal of Supercomputing, 2024, 80: 17097-17134.
- [24] LI H F, CHEN B, HUANG J W, et al. Mutation-driven and population grouping PRO algorithm for scheduling budget-constrained workflows in the cloud[J]. Cluster Computing, 2024, 27: 1137-1158.
- [25] LI H F, XU G H, CHEN B Y, et al. Dual-mutation mechanism-driven snake optimizer for scheduling multiple budget constrained workflows in the cloud[J]. Applied Soft Computing, 2023, 149: 110966.
- [26] FAN Q, CHEN Z J, XIA Z H. A novel quasi-reflected Harris Hawks optimization algorithm for global optimization problems[J]. Soft Computing, 2020, 24: 14825-14843.
- [27] PAN J S, TIAN A Q, CHU S C, et al. TDOA location based on pigeon-inspired optimization algorithm in WSNs[C]// Proceedings of International Conference on Genetic and Evolutionary Computing, 2021.
- [28] 刘陈伟, 孙鉴, 雷冰冰, 等. 基于改进粒子群算法的云数据中心能耗优化任务调度策略[J]. 计算机科学, 2023, 50(7): 246-253.
LIU C W, SUN J, LEI B B, et al. Task scheduling strategy for energy consumption optimization of cloud data center based on improved particle swarm algorithm[J]. Computer Science, 2023, 50(7): 246-253. (in Chinese)