

DOI: 10.20189/j.cnki.CN/61-1527/E.202601011

适于射频识别网络规划的改进型海星优化算法

王云峰¹, 王晓龙², 杨自强¹

(1. 陆军防化学院, 北京 102205;

2. 陆军兵种大学长春士官学校, 长春 130117)

摘要: 为提升射频识别网络规划在标签覆盖率、阅读器干扰抑制、系统功率与负载均衡等方面的综合性能, 提出一种改进型海星优化算法 (improved Starfish optimization algorithm, ISFOA)。利用拉丁超立方体的均匀分布特性增强种群多样性; 在平衡算法的探索与开发阶段, 引入自适应概率阈值, 动态调整搜索过程的探索与开发; 在探索阶段引入 Lévy 飞行策略, 解决海星算法易陷入局部最优问题; 在开发阶段引入高斯扰动策略, 概率性添加扰动项, 增强算法局部开发能力, 避免算法早熟。基于 CEC2017 函数集对算法性能进行对比, 并开展了 RFID 网络规划仿真实验, 针对 100 个随机和集群分布标签场景, 对比分析各算法在覆盖率、干扰率、系统功率和负载均衡方面的性能。结果表明: ISFOA 在多数测试函数上收敛速度快、寻优精度高, Friedman 检验排名第 1, 验证了算法的有效性。随机分布场景下, ISFOA 标签覆盖率为 0.98, 干扰率低至 0.01, 最优适应度为 0.176; 集群分布场景下, 使用 6 个阅读器实现标签覆盖率 0.94, 适应度低至 0.122, 明显优于对比算法, 验证了其在 RFID 网络规划中的适用性与优越性。

关键词: RFID 网络规划; 拉丁超立方体初始化; 自适应概率阈值; Lévy 飞行; 高斯扰动

中图分类号: TP311.1

文献标志码: A

开放科学标识码(OSID):

文章编号: 2097-2741(2026)01-0120-12



听语音
与作者互动
聊科研

射频识别技术 (radio frequency identification, RFID) 是通过无线射频方式对目标进行自动识别的非接触双向数据通信技术。其特有的非接触式自动识别性能, 使其被广泛应用于交通、物流机场、图书馆和零售行业等领域^[1]。

RFID 系统由标签、阅读器和后台数据库组成^[2], 标签布局和阅读器部署统称为 RFID 网络规划。由于阅读器识别范围有限, 如果盲目追求安装更多的阅读器确保覆盖所有标签, 只会增加 RFID 网络成本。配置适当数量的阅读器, 提高对标签的覆盖率同时兼顾负载均衡, 减少阅读器间识别干扰, 实现低功率信息传输的目标, 是 RFID 网络规划的研究热点。

目前, 大量基于改进的群智能算法研究已应用在 RFID 网络规划领域。全艺璇等^[3]提出一种改

进型灰狼算法, 利用高斯变异算子和惯性常量策略, 提高了种群的多样性, 在保证识别覆盖率的基础上, 充分考虑了负载均衡, 避免了阅读器间的干扰, 但在 RFID 网络规划实验中, 算法对标签的覆盖率较低、适应度值欠优。张馨予等^[4]提出一种基于 NSGA-II 算法, 采用精英保留策略的锦标赛选择方法, 确保选择出的个体具有较优性能, 引入高斯变异算子, 增加种群多样性, 避免算法陷入局部最优, 但随着识别标签的数量增加, 识别 50 个标签时算法对标签的平均覆盖率降至 70%~80%, 覆盖率欠优。罗文聪等^[5]提出一种改进型樽海鞘群算法, 引入分离算子优化搜索能力, 并通过迭代不断寻找满足条件的非支配解, 标签覆盖率达 95%, 且减少了阅读器间的干扰, 但其在追求高覆盖率的同时, 牺牲了系统成本, 增加

收稿日期: 2025-08-29

修回日期: 2025-09-23

录用日期: 2025-10-09

第一作者: 王云峰 (1990—), 男, 工程师, 主要从事智能算法及应用研究。E-mail: wangyunfengie@126.com

引用格式: 王云峰, 王晓龙, 杨自强. 适于射频识别网络规划的改进型海星优化算法[J]. 火箭军工程大学学报, 2026, 40 (1): 120-131. WANG Yunfeng, WANG Xiaolong, YANG Ziqiang. Improved Starfish optimization algorithm for radio frequency identification network planning[J]. Journal of Rocket Force University of Engineering, 2026, 40 (1): 120-131.

了阅读器使用数量。学者们在研究中发现, 相较于传统元启发算法, 鱼鹰优化算法^[6]、黑猩猩搜索算法^[7]、改进的蜣螂优化算法^[8]、精英金豺优化算法^[9]、金鹰优化算法^[10]等在函数寻优方面表现优异, 但仍存在收敛速度较慢和易陷入局部最优等不足^[11], 导致算法应用在RFID网络规划中, 无法同时兼顾阅读器数量和干扰、识别覆盖率、系统功率和负载平衡等关键性能。

海星优化算法^[12] (Starfish optimization algorithm, SFOA) 是一种新型启发式优化方法, 其灵感来源于海星的搜索食物、捕食、断臂再生行为。通过模拟海星搜索食物行为实现算法的探索功能, 模拟捕食和遇到危险断臂再生行为完成算法的开发功能, 使算法搜索空间得到有效探索和开发。海星优化算法设计结构简单, 能够灵活实现快速寻优。

基于海星算法思想, 提出一种改进型海星优化算法 (Improved Starfish optimization algorithm, ISFOA), 利用拉丁超立方的均匀分布特性, 增强种群多样性; 引入自适应概率阈值, 动态调整搜索过程的探索与开发; 引入Lévy飞行策略, 解决海星算法探索阶段易陷入局部最优的问题; 利用高斯扰动策略添加扰动项, 增强算法局部开发能力, 避免算法早熟, 从而提高最终解的质量。

1 RFID网络优化目标

RFID网络规划 (RFID network planning, RNP) 是一个多目标的组合优化问题, 常见优化目标有覆盖率、干扰率、系统功率和负载均衡^[13]。

1.1 覆盖率

覆盖率指阅读器识别范围内覆盖的标签数量和标签总数的比例, 是RFID网络规划中重要的指标。覆盖率 f_c 可表示为

$$f_c = \sum_{i=1}^{N_t} L_i / N_t \quad (1)$$

$$L_i = \begin{cases} 1, & d \leq R \\ 0, & d > R \end{cases} \quad (2)$$

式中: N_t 为系统中标签总数量; L_i 表示第 i 个标签是否被阅读器工作范围覆盖; d 为每个标签距离阅读器中心位置的距离; R 为阅读器识别半径。

1.2 干扰率

RFID系统中的干扰指同一个标签被多个阅读器同时识别产生的信息碰撞。碰撞率 f_c 可表示为

$$f_c = \sum_{i=1}^{N_r} I_i / N_r \quad (3)$$

$$I_i = \begin{cases} C_i - 1, & C_i > 1 \\ 0, & 0 \leq C_i \leq 1 \end{cases} \quad (4)$$

式中: N_r 为系统中阅读器总数量; I_i 为被视为干扰源的阅读器数量; C_i 为标签被识别范围覆盖的阅读器个数。

1.3 系统功率

系统功率受阅读器数量及工作范围影响, 考虑经济效益, 阅读器数量越少, 工作范围越小, 系统功率越低。系统功率 f_p 可表示为

$$f_p = \sum_{i=1}^{N_r} P_i \quad (5)$$

式中: P_i 为第 i 个阅读器产生的功率大小。

1.4 负载均衡

在RFID系统中, 阅读器间读取标签的数量相近是负载均衡的体现, 负载均衡值低意味着系统更稳定可靠。负载均衡 f_j 可表示为

$$f_j = \prod_{i=1}^{N_r} 1/K_i \quad (6)$$

式中: K_i 表示第 i 个阅读器读取的标签数量。

1.5 线性加权法

RNP问题的本质是多目标优化问题, 许多研究选用线性加权法求解多目标问题。为实现RFID网络优化部署, 覆盖率 f_c 越大越好, 干扰率 f_c 、系统功率 f_p 、负载均衡 f_j 则越小越好, 将4个目标进行归一化处理后, 得到 F_c 、 F_G 、 F_P 、 F_J 的值都约束在 $[0, 1]$ 区间内, 将整体优化目标用上述4个优化目标线性组合可表示为

$$\min \text{Fitness} = \omega_1 F_c + \omega_2 F_G + \omega_3 F_P + \omega_4 F_J \quad (7)$$

$$\omega_1 + \omega_2 + \omega_3 + \omega_4 = 1$$

$$F_c = 1 - f_c, F_P = \frac{f_p - N_r P_{i \min}}{N_r (P_{i \max} - P_{i \min})} \quad (8)$$

$$F_G = \frac{f_c}{N_r - 1}, F_J = \frac{f_j}{N_r^2 N_t^2 (N_r - 1)}$$

式中: Fitness为系统优化部署适应度函数; ω_1 、 ω_2 、 ω_3 、 ω_4 分别为覆盖率、干扰率、系统功率、负载均衡的权重系数; $P_{i \max}$ 、 $P_{i \min}$ 分别为单个阅读器输出功率的最大值和最小值。

2 海星优化算法

海星优化算法在探索阶段模拟海星搜索食物行为, 提出五维和一维搜索模式。开发阶段模拟海星捕食和再生行为, 采用并行双向搜索策略,

确保开发阶段的收敛性,有效平衡了算法的探索 and 开发。

2.1 种群初始化

算法以常见的反向学习策略 (opposition-based learning, OBL)^[14]初始化种群,初始位置公式为

$$X_{i,j} = (U_j - L_j) \times \text{rand}(\cdot) + L_j, i = 1, 2, \dots, N, j = 1, 2, \dots, D \quad (9)$$

式中: $X_{i,j}$ 为第 i 个海星在第 j 维的初始位置; L_j 、 U_j 分别为搜索空间的下限与上限; D 为算法维度; $\text{rand}(\cdot)$ 表示生成 D 维 0 到 1 的随机向量; N 为海星种群数量。

2.2 探索阶段

探索阶段模拟海星 5 条手臂的搜索能力,分为 $D > 5$ 的五维搜索模式和 $D \leq 5$ 的一维搜索模式。

若优化问题维度 $D > 5$, 则搜索空间相对广阔,需要海星移动 5 条手臂来探索周围环境,可建立数学模型为

$$\begin{cases} Y_{i,p} = X_{i,p} + a_1 \cdot (X_{ibest,p} - X_{i,p}) \cos \theta, r \leq 0.5 \\ Y_{i,p} = X_{i,p} + a_1 \cdot (X_{ibest,p} - X_{i,p}) \sin \theta, r > 0.5 \end{cases} \quad (10)$$

$$a_1 = (2r - 1) \pi \quad (11)$$

$$\theta = \frac{\pi}{2} \cdot \frac{T}{T_{\max}} \quad (12)$$

式中: p 为从 D 维中随机选择的维度数量; $X_{i,p}$ 、 $X_{ibest,p}$ 、 $Y_{i,p}$ 分别为第 i 个海星第 p 维的当前位置、当前最佳位置和计算获得的下一位置; T 为当前迭代次数; $T_{\max}$ 为最大迭代次数; $\theta \in [0, \pi/2]$; r 为 $[0, 1]$ 区间的随机数; 正弦和余弦项表示海星手臂向左或向右以 50% 的概率扭曲移动。 a_1 、 θ 参数随迭代不断产生扰动,使海星个体位置逐渐向最佳位置移动。

若优化问题维度 $D \leq 5$, 使用一维搜索模式来更新位置。海星结合其他海星位置信息,使用一只手臂移动搜索食物,个体位置更新公式为

$$Y_{i,p} = E_i X_{i,p} + A_1 \cdot (X_{k_1,p} - X_{i,p}) + A_2 \cdot (X_{k_2,p} - X_{i,p}) \quad (13)$$

$$E_i = \frac{T_{\max} - T}{T_{\max}} \cos \theta \quad (14)$$

式中: $X_{k_1,p}$ 、 $X_{k_2,p}$ 分别为 2 个随机选择的海星第 P 维所对应位置; A_1 和 A_2 为 $(-1, 1)$ 区间的随机数; E_i 为海星的能量。

2.3 开发阶段

开发阶段考虑捕食和再生 2 个行为以搜索全局解,设计了 2 种更新策略。为模拟海星的捕食阶段,采用并行双向搜索策略,计算种群当前最佳

位置与其他 5 个海星间距离,并随机选择 2 个距离作为认可信息,更新当前海星位置公式为

$$d_m = X_{\text{best}} - X_m, m = 1, 2, \dots, 5 \quad (15)$$

$$Y_i = X_i + r_1 d_{m_1} + r_2 d_{m_2} \quad (16)$$

式中: X_i 和 Y_i 分别为第 i 个海星的当前位置和下一位置; X_{best} 和 X_m 分别为种群当前最佳位置和随机选择的 5 个海星的当前位置; d_m 为当前全局最优位置与 5 个海星间距离; d_{m_1} 和 d_{m_2} 为 d_m 中随机选取的 2 个距离; r_1 和 r_2 为 $[0, 1]$ 区间的随机数。

由于海星移动缓慢,易遭到捕食者攻击。若捕食者抓到海星,海星可能会断掉一只手臂来逃脱。算法的再生阶段只在种群中的最后一只海星 ($i = N$) 中实施,其位置更新公式为

$$Y_i = X_i e^{-\frac{T \cdot N}{T_{\max}}} \quad (17)$$

尽管再生行为在开发阶段每次迭代中只进行一次,但这个阶段可有效避免算法陷入局部最优并增强全局收敛。

3 改进型海星优化算法

改进型海星优化算法保留了原算法的生物启发性和结构简洁性,重点增强种群多样性、动态平衡全局探索和局部开发,并引入 Lévy 飞行和高斯扰动策略,避免算法早熟收敛。

3.1 拉丁超立方体初始化

拉丁超立方体初始化是一种高效的多维分层抽样技术^[15],将种群的分布区间均匀划分为多个不重叠的子区间,并在每个子区间内独立进行等概率抽样,从而确保每个维度上的样本点在每个区间内仅出现一次,使样本点均匀覆盖整个分布空间,主要步骤如下。

Step1 区间划分。对于每个维度 j ,将取值范围 $[a, b]$ 划分为 N 个等概率子区间,每个子区间长度为 $\Delta_j = \frac{b-a}{N}$ 。

Step2 随机排列。在每个维度 j 上生成一个随机排列 ω_j ,表示子区间的编号顺序。例如, $\omega_j(i)$ 表示第 i 个样本在第 j 维的子区间编号。

Step3 采样点计算。第 i 个样本在第 j 维的采样点位置计算公式为

$$X_{i,j} = a + \frac{\omega_j - u_{i,j}}{N} \times \Delta_j \quad (18)$$

式中: $u_{i,j} \sim U(0, 1)$ 为均匀分布随机数。

Step4 多维组合。各维度的采样点随机组

合, 形成最终的多维样本矩阵, 满足每个子区间仅含一个样本点的拉丁方阵结构, 如图1所示。




图1 初始化方式对比

Fig. 1 Comparison of initialization methods

传统随机初始化易出现种群样本点聚集或某些区域无样本点的情况, 尤其是随着维度增加, 随机初始化的样本点容易出现“空洞”区域^[16]。拉丁超立方体初始化有助于算法探索更广泛的空间, 从而在早期发现潜在的全局最优解区域, 对高维问题极为重要, 其均匀分布特性可为后续种群多样性保持、局部搜索提供良好支撑。

3.2 自适应概率阈值

SFOA中, 通过与概率值0.5作比较来选择探索或开发阶段。随着迭代次数增加, 算法将逐步陷入局部最优且收敛速度变慢。因此, 采用一种自适应概率阈值来替代SFOA中的简单概率选择, 计算公式为

$$P = 1 - \log_2(1 + T/T_{\max}) \quad (19)$$

迭代初期, 概率阈值 P 较大, 算法以探索模式更新个体位置; 迭代后期, 随着 P 线性减小至0, 算法将以开发模式更新个体位置, 使其不断靠近最优解。

3.3 Lévy飞行策略

为增强算法全局搜索能力, 探索阶段引入大步长Lévy飞行策略^[17]。Lévy飞行策略是一种随机行走模式, 具有在长距离和短距离间随机切换的特点, 能够有效增强优化算法的全局搜索能力, 其位置更新公式为

$$X(t+1)_{n+1} = r \cdot (X_{\text{best}}(t) - s \cdot X(t)) \quad (20)$$

$$s = u/v^{1/\beta} \quad (21)$$

$$u \sim N(0, \sigma_u^2) \quad (22)$$

$$v \sim N(0, \sigma_v^2) \quad (23)$$

$$\sigma_u = \left(\frac{\Gamma(1+\beta) \cdot \sin(\frac{\pi\beta}{2})}{\beta \cdot \Gamma(\frac{1+\beta}{2}) \cdot 2^{\frac{\beta-1}{2}}} \right)^{\frac{1}{\beta}} \quad (24)$$

$$\sigma_v = 1$$

式中: 参数 r 是控制探索和开发的向量; X_{best} 是当前种群最佳位置; s 为Lévy飞行路径; β 为特征指数, 一般取1.5; u 、 v 为正态分布随机数; σ_u 和 σ_v 为正态分布标准差。图2为 $\beta = 1.5$, 步长为100时的1次Lévy策略的随机飞行轨迹。




图2 Lévy策略飞行轨迹

Fig. 2 Flight trajectory of Lévy strategy

式(10)、(13)可更新为

$$\begin{cases} Y_{i,p} = X_{i,p} + \text{Levy}(\beta, D) \cdot a_1 \cdot (X_{\text{best},p} - X_{i,p}) \cdot \cos \theta, & r \leq 0.5 \\ Y_{i,p} = X_{i,p} + \text{Levy}(\beta, D) \cdot a_1 \cdot (X_{\text{best},p} - X_{i,p}) \cdot \sin \theta, & r > 0.5 \end{cases} \quad (25)$$

$$Y_{i,p} = E_1 X_{i,p} + \text{Levy}(\beta, D) \cdot [A_1 \cdot (X_{k_1,p} - X_{i,p}) + A_2 \cdot (X_{k_2,p} - X_{i,p})] \quad (26)$$

引入Lévy飞行策略, 算法探索新领域时, 既可以进行局部精细搜索, 又能偶尔进行大跨度跳跃, 从而提高算法搜索效率。当算法陷入局部搜索时, 大步长的扰动能够帮助算法跳出局部最优, 避免算法早熟收敛。

3.4 高斯扰动策略

原始海星算法开发阶段仅依赖2个臂进行线性方向的组合以实现位置更新, 缺乏细粒度搜索能力, 缺少跳出微小局部陷阱的随机性, 可能导致算法在接近最优解时出现停滞现象。对此, 引入扰动来增强局部搜索。但是, 添加扰动概率过低, 扰动太少, 效果不明显; 添加扰动概率太高, 位置更新过度随机化, 可能导致收敛不稳定。因此, 选用30%概率, 保证添加扰动的同时维持算法的稳定性, 如式(27)所示。

$$\sigma = (U_j - L_j) \times e^{-\frac{T}{T_{\max}}}, \quad r < 0.3 \quad (27)$$

式(16)、(17)可更新为

$$Y_i = X_i + r_1 d_{m_1} + r_2 d_{m_2} + \text{randn}(1, D) \cdot \sigma \quad (28)$$

$$Y_i = X_{ie}^{-\frac{T \cdot N}{T_{\max}}} + \text{randn}(1, D) \cdot \sigma \quad (29)$$

式中： $\text{randn}(1, D) \cdot \sigma$ 为服从 $N \sim (0, \sigma^2)$ 的正态分布， σ 随着迭代增加递减。迭代后期种群多样性降低，在算法接近收敛时，对当前最优解施加小幅随机扰动，使算法跳出局部最优，以提高算法寻优精度。

ISFOA 算法流程如图 3 所示。




图 3 ISFOA 算法流程

Fig. 3 Flowchart of ISFOA

3.5 ISFOA 算法性能

使用 CEC2017 基准函数对比 ISFOA 算法与鲸鱼迁徙算法^[18] (whale migration algorithm, WMA)、不实野燕麦算法^[19] (animated oat optimization, AOO)、云漂移算法^[20] (cloud drift optimization, CDO)、指数三角算法^[21] (exponential-trigonometric optimization, ETO)、SFOA 的性能。该测试函数套件包括 2 个单峰函数 (F_1 、 F_3)、6 个简

单多峰函数 ($F_4 \sim F_9$)、10 个混合函数 ($F_{10} \sim F_{19}$) 以及 11 个组合函数 ($F_{20} \sim F_{30}$)^[22]。各算法参数设置见表 1，每个算法运行 30 次取平均值，最大迭代次数设置为 500 次，种群设置为 50，维度大小为 30。

表 1 算法参数设置

Table 1 Algorithm parameter settings

符号	描述
WMA	领导者数量占种群 50%, $N_L = N/2$
AOO	全局搜索、局部搜索温度阈值设置为 0.25 和 0.6; 步长系数 $C_1 = 0.5$; 扰动系数 $C_2 = 0.05$; 温度变化系数 $C_3 = 2$
CDO	初始条件: $z = 0.005$, 适应度初始阈值为 e^{-300}
ETO	约束探索: $a = 4.6, b = 1.55$
SFOA	探索、开发切换概率阈值 $GP = 0.5$
ISFOA	Lévy 飞行: $\beta = 1.5$; 高斯扰动概率阈值 30%

部分函数测试结果如表 2、图 4 所示，从测试结果可以看出，ISFOA 算法在单峰函数、简单多峰函数以及混合函数测试时，其最优适应度、平均适应度、标准差均表现良好，其 Friedman 秩平均值最低，体现了 ISFOA 算法在多测试函数下的稳定性，算法整体泛化能力更强，且 ISFOA 算法基本在 20 次迭代内即可快速寻找到最优适应度，且收敛曲线平稳、无较大波动。综合来看，ISFOA 算法较其他算法具有更好的平稳性与快速收敛性。

基准测试箱型图如图 5 所示，可以直观看出，相较于其他 5 种算法，虽然 ISFOA 算法在测试 F_5 、

表 2 6 种算法适应度值的比较结果

Table 2 Comparison results of fitness values of six algorithms

函数	指标	WMA	AOO	CDO	ETO	SFOA	ISFOA
F_1	最优适应度	1.53×10^{10}	7.67×10^{10}	8.37×10^8	7.99×10^9	2.16×10^{10}	1.76×10^8
	标准差	5.59×10^9	1.65×10^{10}	1.08×10^9	7.62×10^9	7.35×10^9	2.74×10^8
	平均适应度	2.54×10^{10}	1.12×10^{11}	2.31×10^9	1.82×10^{10}	3.82×10^{10}	6.65×10^8
F_5	最优适应度	8.25×10^2	1.06×10^3	6.36×10^2	6.97×10^2	8.30×10^2	7.30×10^2
	标准差	5.13×10	5.30×10	4.82×10	5.68×10	3.78×10	3.68×10
	平均适应度	9.08×10^2	1.15×10^3	7.48×10^2	7.98×10^2	8.96×10^2	7.84×10^2
F_8	最优适应度	1.02×10^3	1.27×10^3	9.46×10^2	9.95×10^2	1.06×10^3	9.69×10^2
	标准差	4.22×10	3.77×10	2.11×10	3.94×10	3.03×10	4.49×10
	平均适应度	1.13×10^3	1.37×10^3	9.94×10^2	1.08×10^3	1.13×10^3	1.03×10^3
F_{12}	最优适应度	6.41×10^8	1.30×10^{10}	3.00×10^7	3.67×10^7	2.35×10^9	1.64×10^7
	标准差	9.06×10^8	6.42×10^9	2.34×10^8	6.22×10^8	3.11×10^9	5.03×10^7
	平均适应度	2.40×10^9	2.47×10^{10}	2.57×10^8	5.54×10^8	6.25×10^9	8.23×10^7

续表

函数	指标	WMA	AOO	CDO	ETO	SFOA	ISFOA
F_{21}	最优适应度	2.60×10^3	2.81×10^3	2.45×10^3	2.49×10^3	2.56×10^3	2.47×10^3
	标准差	5.90×10	5.04×10	4.62×10	4.99×10	5.86×10	5.74×10
	平均适应度	2.68×10^3	2.90×10^3	2.54×10^3	2.57×10^3	2.68×10^3	2.57×10^3
F_{29}	最优适应度	4.56×10^3	7.87×10^3	4.29×10^3	3.99×10^3	4.60×10^3	3.80×10^3
	标准差	7.67×10^2	1.59×10^4	2.66×10^2	3.34×10^2	8.51×10^2	2.84×10^2
	平均适应度	6.05×10^3	1.94×10^4	4.68×10^3	4.59×10^3	6.08×10^3	4.44×10^3
Friedman 秩平均值		4.35	6.00	2.00	2.62	4.48	1.55
Friedman 秩排名		4	6	2	3	5	1

注：表中黑体为最优数据。




图 4 ISFOA 与其他算法 CEC2017 基准测试对比结果

Fig. 4 Comparison results of CEC2017 benchmark testing among ISFOA and other algorithms




图 5 ISFOA 与其他算法 CEC2017 基准测试箱型图对比结果

Fig. 5 Comparison results of CEC2017 benchmark testing box plots among ISFOA and other algorithms

F_8 、 F_9 、 F_{21} 函数时, 箱体高度略高于 CDO 算法, 表明其寻优精度逊于 CDO 算法, 但测试其他函数时, ISFOA 算法箱体高度更低, 说明具有更优的适应度值, 算法收敛至更优解的能力强, 且所有适应度值均优于 SFOA 算法; ISFOA 算法箱体更扁平, 数据波动小、适应度值集中, 反映算法收敛性强且优化效果稳定, 同时适应度值差异小, 受初始条件或随机性影响小, 算法鲁棒性强。

为深入分析算法, 选取 F_{10} 、 F_{20} 测试函数对改进策略的有效性进行分析。将 ISFOA 算法与 ISFOA₁ (不采用拉丁超立方体初始化)、ISFOA₂ (不采用自适应概率阈值)、ISFOA₃ (不采用 Lévy 飞行策略) 和 ISFOA₄ (不采用高斯扰动策略) 进行比较, 算法策略有效性比较结果如图 6 所示。可以直观看出, 在不同的基准函数中, ISFOA 收敛速度最快, 适应度值最佳, 相较于 ISFOA₁、ISFOA₂、ISFOA₃、ISFOA₄ 性能更优越。说明 ISFOA 算法中的每一种改进策略都是有效的, 这些策略有效地增强了种群初始化, 算法跳出局部最优, 加快了算法收敛, 提高了解的质量。

为进一步分析组合策略对算法性能的影响, 选取 F_{17} 、 F_{20} 测试函数进行分析, A、B、C、D 分别代表拉丁超立方体初始化、自适应概率阈值策略、Lévy 飞行策略、高斯扰动策略, 例如 ISFOA_{BCD} 为采用自适应概率阈值、Lévy 飞行、高




图 6 ISFOA 算法策略有效性对比结果

Fig. 6 Comparison results of the effectiveness of

ISFOA strategies


斯扰动策略的 SFOA 算法, 对比结果如图 7 所示。从适应度值来看, ISFOA 算法优于采用其他组合策略的 SFOA 算法, 采用组合策略的 SFOA 算法=优于 SFOA 算法, 证明了引入策略的有效性。从收敛性看, 在迭代初期, 由于引入 4 种策略导致算法复杂度增加, ISFOA 的收敛性劣于采用其他组合策略的 SFOA 算法, 但在中后期, ISFOA 算法收敛较快, 能够使算法快速跳出局部最优。

综合来看, ISFOA 能够高效搜索空间, 拉丁超立方体初始化、Lévy 飞行、高斯扰动等策略均有效, 多策略相辅相成, 使算法具有较快的收敛速度和较高的寻优精度。

4 实验分析

4.1 仿真实验

将 RFID 识别系统区域设置为边长 30 m 的正方形区域, 在阅读器的实际使用过程中, 所发射的功率会随着阅读器的覆盖半径改变而变化, 通常将阅读器的覆盖半径设置为 3~7 m^[23]。选取 10 组权重系数进行实验, 其他参数设置参照表 1, 对集群分布的 100 个标签识别 30 次并取平均值, 结



果如表 3 所示。权重参数 ω_1 、 ω_2 、 ω_3 、 ω_4 分别为 0.5、0.05、0.05、0.4 时, 适应度值相对最优, 以此开展后续实验。




图 7 ISFOA 算法采用单一策略和组合策略对比结果
Fig. 7 Comparison results of the ISFOA using single and combined strategies

表 3 不同权重系数识别集群分布 100 个标签的 30 次实验平均值

Table 3 Average values of thirty experiments for identifying cluster distribution of one hundred labels using different weight coefficients

序号	ω_1	ω_2	ω_3	ω_4	适应度值	覆盖率 f_c	干扰率 f_g	功率 f_p	负载均衡 f_l
1	0.2	0.1	0.1	0.6	0.134	0.94	0.18	32.92	33.62
2	0.3	0.1	0.1	0.5	0.161	0.90	0.12	38.58	36.67
3	0.4	0.1	0.1	0.4	0.145	0.92	0.23	36.35	49.61
4	0.5	0.1	0.1	0.3	0.127	0.99	0.25	36.81	42.84
5	0.6	0.1	0.1	0.2	0.129	0.99	0.21	32.68	48.67
6	0.6	0.05	0.05	0.3	0.125	0.97	0.24	45.11	44.93
7	0.5	0.05	0.05	0.4	0.122	0.98	0.01	38.92	32.20
8	0.4	0.05	0.05	0.5	0.163	0.91	0.17	32.69	37.18
9	0.3	0.05	0.05	0.6	0.173	0.92	0.01	37.34	36.58
10	0.2	0.05	0.05	0.7	0.179	0.92	0.01	38.92	35.26

采用固定 6 个阅读器识别 100 个随机标签分布和可变阅读器个数识别 100 个集群标签分布 2 种情形, 进行 30 次重复实验取平均值, 测试 PSO^[24]、GWO^[25]、DBO^[26]、BWO^[27]、SFOA、ISFOA 算法在覆盖率、干扰率、系统功率和负载均衡方面的性能, 仿真结果如图 8、9 所示, 30 次实验中各算法优化目标数值最优的一次结果如表 4、5 所示。

4.2 结果分析

针对 100 个随机标签分布, 从覆盖率来看, ISFOA 算法覆盖了 100 个标签中的 98 个, 标签覆盖率最高, 最优适应度值最低为 0.176, 干扰率最低为 0.01。在获得高标签覆盖率、低干扰率和最优适应度的同时, 扩大了阅读器识别范围, 但牺牲了系统负载功率和负载均衡性能。面对随机分布的标签, ISFOA 算法能够表现出良好的位置寻优效果, 使得更多标签被覆盖并获得最优适应度值, 表现优于其他对比算法。因此, 识别随机分布标签, 不考虑系统功率和负载均衡前提下, 可以优先选择 ISFOA 算法。

针对 100 个集群标签分布, 从阅读器个数来看, ISFOA 算法仅用 6 个阅读器即可基本识别 100 个标签, 所需数量最少。从覆盖率来看, BWO 算法最优覆盖率为 1, ISFOA 由于使用阅读器个数少, 导致标签覆盖率稍低为 0.94, 但仍与 SFOA 算法基本持平。从干扰率来看, BWO 算法寻优效果更好, 待识别标签全覆盖的同时, 干扰率最低为 0.01; ISFOA 算法干扰率为 0.03, 仅次于 BWO




图 8 随机分布 100 个标签各算法规划结果

Fig. 8 Planning results of random distribution of one hundred labels of different algorithms




图 9 集群分布 100 个标签各算法规划结果

Fig. 9 Planning results of cluster distributions of one hundred labels obtained using different algorithms

表 4 识别随机分布 100 个标签各算法性能对比

Table 4 Comparison of the performances of different algorithms for identifying one hundred randomly distributed labels

算法	最优适应度值	平均适应度值	最优覆盖	平均覆盖	最优干扰	平均干扰	最优功率	平均功率	最优负载均衡	平均负载均衡
PSO	0.483	0.438	0.82	0.774	0.10	0.036	14.556	27.553	31.611	33.293
GWO	0.178	0.210	0.95	0.834	0.02	0.037	21.139	28.581	30.520	33.574
DBO	0.213	0.252	0.89	0.754	0.03	0.057	6.556	21.244	30.748	34.376
BWO	0.224	0.257	0.80	0.737	0.11	0.055	16.139	26.081	30.254	30.505
SFOA	0.454	0.212	0.87	0.819	0.07	0.492	26.222	37.360	37.091	82.049
ISFOA	0.176	0.213	0.98	0.864	0.01	0.047	38.917	40.183	32.200	34.635

注:黑体为各指标最优数据。

表 5 识别集群分布 100 个标签各算法性能对比

算法	阅读器 个数	最优适 应度值	平均适 应度值	最优 覆盖	平均 覆盖	最优 干扰	平均 干扰	最优 功率	平均 功率	最优负载 均衡	平均负载 均衡
PSO	7	0.160	0.183	0.90	0.853	0.06	0.089	10.860	24.088	40.583	40.654
GWO	8	0.131	0.143	1.00	0.947	0.11	0.133	10.688	25.809	41.128	41.961
DBO	8	0.153	0.171	0.93	0.859	0.05	0.073	17.860	23.791	39.262	40.999
BWO	9	0.129	0.156	1.00	0.996	0.01	0.037	6.099	14.933	33.758	35.934
SFOA	8	0.198	0.214	0.95	0.834	0.09	0.126	17.633	18.710	36.146	38.518
ISFOA	6	0.122	0.140	0.94	0.845	0.03	0.054	20.472	28.425	32.223	34.000

注：黑体为各指标最优数据。

算法，优于 SFOA 算法。从功率来看，ISFOA 算法使用阅读器数量最少，保持标签高覆盖率的同时，需要阅读器识别范围更广，导致功率损耗更大；BWO 算法使用阅读器数量最多，所以每个阅读器识别范围较小，平均功率损耗较低。负载均衡方面，由于 ISFOA 算法使用阅读器数量最少，由式（6）计算出 ISFOA 算法的最优负载均衡为 32.223，明显优于其他算法。ISFOA 算法的最优适应度为 0.122，说明其能够兼顾覆盖率、干扰率、功率和负载均衡 4 项指标，灵活调整少量阅读器的部署位置，达到精确寻优效果；BWO、GWO 适应度值稍逊，主要原因是使用阅读器个数多，导致系统总功率大、负载均衡差。因此，识别集群分布标签，当系统对阅读器要求个数少且考虑功率成本情况下，ISFOA 算法更适用。

综上所述，ISFOA 算法在遍历寻最优值方面表现更出色，较其他算法更适合处理 RFID 网络规划问题。

5 结论

针对 RFID 网络规划中存在的标签覆盖率不足、阅读器间干扰、功率成本高与负载不均衡等问题，提出一种改进型海星优化算法，旨在实现对阅读器部署的高效优化，主要结论如下。

1) 提出改进型海星优化算法 ISFOA，仿真实验表明，ISFOA 在 CEC2017 测试函数上收敛速度快、寻优精度高，Friedman 秩平均排名优于其他对比算法。

2) 通过对 ISFOA 及单一策略和组合策略算法的对比分析，改进策略对算法性能有积极影响，多种策略协同，使 ISFOA 算法收敛性、全局寻优能力更强。

3) ISFOA 算法在解决 RFID 网络规划问题方

面表现出较强的综合性能。随机和集群分布 100 个标签场景，ISFOA 能够实现高标签覆盖率、低干扰率，兼顾阅读器数量、功率与负载均衡，使适应度值最优。

综上所述，ISFOA 算法在 RFID 网络规划中表现良好，能够在保证高覆盖率和低干扰的同时，减少阅读器使用数量，优化负载分配，从而实现低成本、高效率、高稳定性的 RFID 网络部署。

参考文献

[1] 许燕，王维兰．基于 RFID 技术的动态手势指令识别方法仿真[J]．计算机仿真，2025，42(2)：248-251，487.
XU Y, WANG W L. Simulation of dynamic gesture instruction recognition method based on RFID technology[J]．Computer Simulation, 2025, 42(2)：248-251, 487.

[2] 毛刚，熊心宁，汪文勇，等．RFID 系统物理层防碰撞算法研究综述[J]．电子科技大学学报，2025，54(4)：532-545.
MAO G, XIONG X N, WANG W Y, et al. Anti-collision algorithms at the physical layer for RFID systems: a review[J]．Journal of University of Electronic Science and Technology of China, 2025, 54(4)：532-545.

[3] 全艺璇，郑嘉利，罗文聪，等．基于改进型灰狼算法的 RFID 网络规划[J]．计算机科学，2021，48(1)：253-257.
QUAN Y X, ZHENG J L, LUO W C, et al. Improved grey wolf optimizer for RFID network planning[J]．Computer Science, 2021, 48(1)：253-257.

[4] 张馨予，张颖超，薛伟莲．基于 G_NSGA-II 算法的 RFID 网络规划[J]．软件导刊，2024，23(2)：55-65.
ZHANG X Y, ZHANG Y C, XUE W L. RFID network planning based on G_NSGA-II algorithm

- [J]. Software Guide, 2024, 23(2): 55-65.
- [5] 罗文聪, 郑嘉利, 全艺璇, 等. 基于改进型多目标樽海鞘群算法的RFID阅读器天线优化部署[J]. 计算机科学, 2021, 48(9): 292-297.
- LUO W C, ZHENG J L, QUAN Y X, et al. Optimization deployment of RFID reader antenna based on improved multi-objective salp swarm algorithm[J]. Computer Science, 2021, 48(9): 292-297.
- [6] 李奕轩, 田云娜. 多策略改进的鱼鹰优化算法及其应用[J]. 延安大学学报(自然科学版), 2024, 43(4): 99-108.
- LI Y X, TIAN Y N. Improved osprey optimization algorithm based on multiple strategies and its application[J]. Journal of Yan'an University (Natural Science Edition), 2024, 43(4): 99-108.
- [7] 张福兴, 高腾, 吴泓达. 多策略融合的改进黑猩猩优化算法[J]. 北京航空航天大学学报, 2025, 51(1): 235-247.
- ZHANG F X, GAO T, WU H D. Improved chimpanzee search algorithm based on multi-strategy fusion and its application[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(1): 235-247.
- [8] 娄革伟, 郑永煌, 陈均, 等. 混合多策略改进的蜣螂优化算法[J]. 计算机工程与应用, 2024, 60(24): 97-109.
- LOU G W, ZHENG Y H, CHEN J, et al. Improved Dung Beetle optimization algorithm by hybrid multi-strategy[J]. Computer Engineering and Applications, 2024, 60(24): 97-109.
- [9] 吴智祥, 刘杰, 覃涛, 等. 多策略改进的精英金豺优化算法[J/OL]. 计算机工程与科学, (2024-06-28) [2025-08-05]. <https://link.cnki.net/urlid/43.1258.TP.20240627.1446.004>.
- WU Z X, LIU J, QIN T, et al. Elite Golden Jackal optimization based on multi-strategy improvement and its application in engineering problems[J/OL]. Computer Engineering & Science, (2024-06-28) [2025-08-05]. <https://link.cnki.net/urlid/43.1258.TP.20240627.1446.004>.
- [10] 杨洋, 李国成, 贾朝川. 基于交叉熵金鹰优化算法的室内可见光定位[J]. 安徽工业大学学报(自然科学版), 2024, 41(5): 525-534.
- YANG Y, LI G C, JIA C C. Indoor visible light positioning based on cross-entropy Golden Eagle optimization algorithm[J]. Journal of Anhui University of Technology (Natural Science), 2024, 41(5): 525-534.
- [11] 潘博阳. 多策略徒步旅行优化算法[J]. 信息工程大学学报, 2025(3): 275-281.
- PAN B Y. Multi-strategy Hiking optimization algorithm[J]. Journal of Information Engineering University, 2025(3): 275-281.
- [12] ZHONG C T, LI G, MENG Z, et al. Starfish optimization algorithm (SFOA): a bio-inspired metaheuristic algorithm for global optimization compared with 100 optimizers[J]. Neural Computing and Applications, 2025, 37(5): 3641-3683.
- [13] GHASEMI M, DERICHE M, TROJOVSKÝ P, et al. An efficient bio-inspired algorithm based on humpback whale migration for constrained engineering optimization[J]. Results in Engineering, 2025, 25: 104215.
- [14] WANG R B, HU R B, GENG F D, et al. The animated oat optimization algorithm: a nature-inspired metaheuristic for engineering optimization and a case study on wireless sensor networks[J]. Knowledge-Based Systems, 2025, 318: 113589.
- [15] ALIBABAEI S M. Cloud drift optimization algorithm as a nature-inspired metaheuristic[J]. Discoverer Computing, 2025, 28(1): 173.
- [16] LUAN T M, KHATIR S, TRAN M T, et al. Exponential-trigonometric optimization algorithm for solving complicated engineering problems[J]. Computer Methods in Applied Mechanics and Engineering, 2024, 432: 117411.
- [17] ZHANG J B, ZHENG J L, XIE X D, et al. Mayfly sparrow search hybrid algorithm for RFID network planning[J]. IEEE Sensors Journal, 2022, 22(16): 16673-16686.
- [18] RAHNAMAYAN S, TIZHOOSH H R, SALAMA M M A. Quasi-oppositional differential evolution[C]//2007 IEEE Congress on Evolutionary Computation. Piscataway, NJ, USA: IEEE, 2007: 2229-2236.
- [19] 何星月, 张靖, 覃涛, 等. 基于拉丁超立方的改进白骨顶鸡算法[J]. 计算机工程与设计, 2024, 45(4): 1069-1078.
- HE X Y, ZHANG J, QIN T, et al. Improved COOT algorithm based on Latin hypercube[J]. Computer Engineering and Design, 2024, 45(4): 1069-1078.
- [20] MCKAY M D, BECKMAN R J, CONOVER W J. A comparison of three methods for selecting values of input variables in the analysis of output from a computer code[J]. Technometrics, 2000, 42(1): 55-61.
- [21] 孙孝东, 刘海宁, 张勇. 一种自适应 t 分布和Lévy飞行机制的沙猫群优化算法[J]. 辽宁科技大学学报, 2023, 46(4): 308-314.

- SUN X D, LIU H N, ZHANG Y. A Sand Cat Swarm optimization algorithm with adaptive t -distribution and Lévy flight mechanism[J]. Journal of University of Science and Technology Liaoning, 2023, 46(4): 308-314.
- [22] KOMMADATH R, KOTTECHA P. Evaluation of teaching learning based optimization with focused learning on expensive optimization problems (CEC 2017) [C]//Smart Innovations in Communication and Computational Sciences. Singapore: Springer Singapore, 2019: 435-445.
- [23] 李芷芊, 郑嘉利, 陈奕君, 等. 基于改进型蛇算法的 RFID 网络规划部署[J]. 计算机科学, 2024, 51(6): 375-383.
- LI Z Q, ZHENG J L, CHEN Y J, et al. Enhanced Snake optimizer based RFID network planning[J]. Computer Science, 2024, 51(6): 375-383.
- [24] KENNEDY J, EBERHART R. Particle swarm optimization[C]//Proceedings of ICNN'95-International Conference on Neural Networks. Piscataway, NJ, USA: IEEE, 1995: 1942-1948.
- [25] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [26] XUE J K, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization [J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.
- [27] ZHONG C T, LI G, MENG Z. Beluga whale optimization: a novel nature-inspired metaheuristic algorithm[J]. Knowledge-Based Systems, 2022, 251: 109215.

Improved Starfish Optimization Algorithm for Radio Frequency Identification Network Planning

WANG Yunfeng¹, WANG Xiaolong², YANG Ziqiang¹

(1. Army Chemical Defense College, Beijing 102205, China;

2. Changchun Noncommissioned Office School of PLA Army Services University, Changchun 130117, China)

ABSTRACT: An improved Starfish optimization algorithm (ISFOA) was proposed to improve the comprehensive performance of radio frequency identification (RFID) network planning in terms of tag coverage, reader interference suppression, system power and load balancing. The algorithm used the uniform distribution characteristics of the Latin hypercube to enhance population diversity. To balance the exploration and exploitation phases of the algorithm, an adaptive probability threshold was introduced to dynamically adjust the exploration and exploitation of the search process. During the exploration phase, a Lévy flight strategy was introduced to solve the problem of the starfish algorithm falling easily into local optimization. In the exploitation phase, a Gaussian perturbation strategy was implemented, and perturbation terms were added probabilistically to enhance the local exploitation capability and avoid premature of the algorithm. The algorithm's performance was evaluated using the CEC2017 function set, and RFID network planning simulations were conducted. For 100 random and clustered tag distribution scenarios, comparative analyses were performed across coverage, interference rate, system power, and load balancing. The results show that the ISFOA exhibits fast convergence speed and high optimization accuracy in most test functions, and ranks first in the Friedman test, verifying the effectiveness of the algorithm. In random distribution scenarios, the ISFOA achieves a tag coverage of 0.98, with an interference rate as low as 0.01 and an optimal fitness of 0.176. In the clustered distribution scenarios, it achieves a tag coverage of 0.94 using six readers, with a fitness as low as 0.122. The ISFOA outperforms comparative algorithms, confirming its applicability and superiority in RFID network planning.

KEYWORDS: RFID network planning; Latin hypercube initialization; adaptive probability threshold; Lévy flight; Gaussian perturbation

(编辑: 于福兴)