

改进樽海鞘群算法的无人机三维路径规划

陈忠云¹, 徐航², 施志勇¹, 杨舒洵¹, 张敏³

(1. 通信士官学校 机动通信系, 重庆 400035;

2. 贵州交通职业大学 智慧交通学院, 贵阳 551400;

3. 通信士官学校 基础部, 重庆 400035)

摘要: 该研究针对标准樽海鞘群算法在无人机三维路径规划中求解精度不足的问题, 提出了一种融合混沌高斯折射学习机制的改进算法; 通过对初始种群生成方式、领导者更新策略以及最差个体优化机制进行改进, 采用了 Tent 混沌映射增强种群多样性, 引入高斯变异操作提升全局搜索能力, 并利用折射原理的学习策略强化局部搜索性能; 为验证算法效果, 对 6 种典型复杂函数、CEC2014 测试函数集以及无人机三维路径规划问题进行了仿真实验; 实验结果表明, 改进算法在函数优化中表现出更快的收敛速度和更高的求解精度; 在路径规划应用中, 该算法显著提升了路径精度与收敛效率, 能够有效满足实际三维路径规划的需求。

关键词: 混沌映射; 高斯变异; 折射学习; 樽海鞘群算法; 无人机; 路径规划

3D Path Planning for Drones Based on Improved SSA

CHEN Zhongyun¹, XU Hang², SHI Zhiyong¹, YANG Shuxun¹, ZHANG Min³

(1. Department of Mobile Communication, Communications NCO Academy of PLA, Chongqing 400035, China;

2. College of Intelligent Transportation, Guizhou Communications Polytechnic University, Guiyang 551400, China;

3. Department of Basic Course, Communications NCO Academy of PLA, Chongqing 400035, China)

Abstract: To address the issue of insufficient solution accuracy in standard Salp Swarm Algorithms (SSAs) for three-dimensional path planning of drones, an improved algorithm that incorporates a chaotic Gaussian mutation learning mechanism is proposed. By enhancing the initial population generation method, leader update strategy, and worst individual optimization mechanism, the Tent chaotic mapping is employed to enrich population diversities, The Gaussian mutation operation is introduced to enhance global search capability, and the learning strategy based on the refraction principle is utilized to strengthen local search performance. To verify the effectiveness of the algorithm, simulation experiments were conducted on six typical complex functions, the CEC2014 test function set, and three-dimensional path planning for drones. Experimental results demonstrate that the improved algorithm exhibits faster convergence speed and higher solution accuracy in function optimization. In path planning applications, the algorithm significantly improves path accuracy and convergence efficiency, effectively meeting the requirements of practical three-dimensional path planning.

Keywords: chaotic mapping; Gaussian mutation; refraction learning; SSA; drones; path planning

0 引言

近年来, 无人机在复杂三维空间的应用日益增多^[1], 这对路径规划技术提出了更高要求。在三维网格环境中, 传统图搜索方法往往面临计算量过大的困境^[2], 而随机采样技术又难以获得理想的路径质量^[3]。

为应对这些挑战, 研究者们开始关注群体智能优化方法^[4-5], 这类算法通过模拟自然界中的群体行为来寻找最优解。以遗传算法 GA^[6]、和粒子群算法 PSO^[7]为代表的群体智能方法, 凭借其出色的全局搜索能力和环境适应性, 在解决高维非线性路径规划问题时表现出明显优势。不过需要指出的是, 这些算法在收敛速度和求解

收稿日期:2025-07-30; 修回日期:2025-09-16。

基金项目:通信士官学校理论研究项目(KYCQJQL22XXA)。

作者简介:陈忠云(1989-),男,研究生,助教。

通讯作者:徐航(1995-),男,研究生,助教。

引用格式:陈忠云,徐航,施志勇,等.改进樽海鞘群算法的无人机三维路径规划[J].计算机测量与控制,2026,34(7):209

-218.

精度之间仍存在需要优化的空间^[8]。

近年来, 樽海鞘群算法^[9] (SSA) 因结构简单、参数数量少等特点, 在优化算法领域崭露头角。然而, 该算法在解决三维路径规划问题时仍存在若干不足: 初始种群多样性较低易导致算法过早收敛, 固定步长机制限制了搜索效率, 且对复杂约束条件的处理能力有待加强。针对这些问题, 学者们提出了多种改进方案。例如, 有研究将正弦余弦算法引入 SSA 中, 通过三角函数的周期性特征优化个体搜索行为^[10]; 另有学者采用固定惯性权重策略来提升收敛速度^[11]。在种群初始化方面, 基于混沌映射的方法被证明能有效增强种群多样性^[12]。此外, 通过引入高斯变异策略^[13]和光学折射原理^[14]改进的学习机制, 进一步提升了算法的搜索能力。在环境建模方面, 基于三维格栅的地图^[15-16]构建方法结合航路点优化技术, 为无人机提供了兼顾安全性和经济性的路径规划方案。

本文提出一种改进的樽海鞘群算法 (ISSA), 通过 3 种策略解决传统 SSA 早熟收敛与精度不足的问题。首先, 借助扰动型 Tent 混沌映射完成种群初始化, 在搜索空间内形成高散布度、低冗余的初代个体, 为后续寻优奠定多样性基础。其次, 在领导者阶段嵌入自适应高斯扰动, 既保持早期大范围勘探, 又能在后期精细微调, 抑制陷入局部极值的风险。最后, 对适应度最差的若干追随者执行“折射学习”机制: 模拟光线在介质界面的折射现象, 从而带动群体跳出停滞区域。在环境建模方面, 采用三维格栅化处理方法, 既保证了障碍物表达的准确性, 又兼顾了计算效率的需求。

为验证所提方法的可行性, 研究分别在经典基准函数与栅格三维场景下开展仿真。对比实验显示, 相较于原始樽海鞘算法, ISSA 在收敛效率和最终精度上均呈现明显提升。本文的核心贡献可概括为三点: 首先, 将混沌初始化与自适应变异相结合, 构建了更高效的种群优化机制; 其次, 基于光学原理设计的折射学习策略, 有效增强了算法局部搜索性能; 最后, 构建基于三维格栅环境验证体系。实验结果进一步表明, 该算法能够稳定生成满足实际需求的三维飞行路径。

1 三维环境建模

针对无人机在复杂障碍环境中的三维路径规划需求, 首要解决的是环境建模问题。本研究采用空间离散化方法, 将连续飞行空域转换为规则的三维网格模型, 为后续路径优化算法提供计算基础。具体实现过程如下。

空间基准建立: 选取规划区域内的特征点作为空间参考原点 $O(0, 0, 0)$, 以此建立空间坐标系。3 个坐标轴分别对应实际环境中的东西、南北和垂直方向, 构成完整的三维网格空间 (如图 1 所示)。




图 1 三维网格规划空间

网格化处理: 基于设定的空间, 将连续空域沿 3 个坐标轴进行等间距划分, 形成规则的立方体单元。每个网格单元存储相应环境信息, 包括障碍物分布、飞行限制等属性。这种离散化处理既保留了环境特征, 又显著降低了计算复杂度。

确定规划空间的边界尺寸如下。

沿 X 轴最大延伸长度: L_x 。

沿 Y 轴最大延伸长度: L_y 。

沿 Z 轴最大延伸高度: L_z 。

三维离散化 (栅格划分):

将 X 轴方向 (长度 L_x) 均匀划分为 n_x 段, 得到 $n_x + 1$ 个垂直于 X 轴的切片平面。

将 Y 轴方向 (宽度 L_y) 均匀划分为 m_y 段, 得到 $m_y + 1$ 个垂直于 Y 轴的切片平面。

将 Z 轴方向 (高度 L_z) 均匀划分为 h_z 段, 得到 $h_z + 1$ 个水平面 (或垂直于 Z 轴的平面)。这三组正交的切割平面相互交织, 并且求解出里面的交点。

通过以上格栅化处理, 整个规划空间就被离散化为 $(n+1) \times (m+1) \times (h+1)$ 个节点构成的三维点阵。该点阵中的每个节点均通过双重坐标系精确定位:

索引坐标定义为 $\alpha_1(i, j, k)$, 其中: $i \in [0, n]$, 节点沿 X 轴向的栅格序号; $j \in [0, m]$, 节点沿 Y 轴向的栅格序号; $k \in [0, h]$, 节点沿 Z 轴向的栅格序号。

位置坐标对应 $\alpha_2(x_i, y_j, z_k)$, 通过下式映射到实际空间位置:

$$\begin{cases} x_i = i \cdot \Delta x, \Delta x = L_x/n \\ y_j = j \cdot \Delta y, \Delta y = L_y/m \\ z_k = k \cdot \Delta z, \Delta z = L_z/h \end{cases} \quad (1)$$

式中, L_x, L_y, L_z 分别为空间在 3 个维度的总长度。

在满足避障约束的前提下, 通过群体智能搜索策略, 从所有可能的节点连接组合中, 遴选出连接起始点 S 与目标点 G 且使目标函数 (如路径长度) 最优的三维节点序列, 最终形成连续飞行轨迹。

为优化无人机三维路径规划效率, 本方法设定 X

轴为主行进方向, 并将运动抽象为 3 个约束分量: X 轴向固定步进距离 Lx_max 、 Y 轴向最大横向偏移 Ly_max 、 Z 轴向最大纵向位移 Lz_max 。当樽海鞘个体位于栅格点 $H(i, j, k)$ 时, 其下一位置的搜索范围被限定在 X 轴方向 $[i, i + Lx_max/\Delta x]$ 、 Y 轴方向 $[j - Ly_max/\Delta y, j + Ly_max/\Delta y]$ 和 Z 轴方向 $[k - Lz_max/\Delta z, k + Lz_max/\Delta z]$ 构成的三维邻域内。这种运动约束机制有效缩小了搜索空间, 在保证路径可行性的同时显著提升了群体智能算法的求解效率。

该栅格化模型的核心价值在于: 将连续、复杂的真实空域转化为计算机易于处理的离散数据结构。这种方法显著降低了路径搜索的复杂度, 有利于群体智能算法在解空间中快速探索可行路径。

2 樽海鞘群算法

樽海鞘群优化算法 (SSA) 是受海洋生物群体行为启发而发展的一种智能优化方法。该算法模拟了樽海鞘独特的运动方式: 通过周期性吸水排水实现位移, 并以浮游植物为食的生态特征。在算法实现中, 研究者将樽海鞘群体抽象为链式结构, 其中处于前端的个体担任领导者角色, 负责探索新的搜索区域, 而后续个体则作为追随者, 通过位置迭代更新实现协同优化。这种分工机制使算法兼具全局探索和局部开发能力, 在解决复杂优化问题时展现出独特优势。

SSA 算法中, 每个樽海鞘个体的位置使用一个 d 维向量 $\mathbf{X} = [x_1, x_2, \dots, x_d]$ 来表示, 其中 d 对应优化问题的决策变量个数。整个种群由 N 个这样的个体组成, 其空间分布可以用一个 N 行 d 列的矩阵完整描述:

$$\mathbf{X} = \begin{bmatrix} x_1^1 & x_2^1 & \cdots & x_d^1 \\ x_1^2 & x_2^2 & \cdots & x_d^2 \\ \vdots & \vdots & \vdots & \vdots \\ x_1^N & x_2^N & \cdots & x_d^N \end{bmatrix} \tag{2}$$

在樽海鞘群算法中, 群体把当前搜索到的最佳点视为“食物”, 所有个体均以该目标为导航。链首的“领航者”率先向该食物逼近, 其位置更新规则如下:

$$x_j^1 = \begin{cases} F_j + c_1((ub_j - lb_j)c_2 + lb_j) & c_3 \geq 0.5 \\ F_j - c_1((ub_j - lb_j)c_2 + lb_j) & c_3 < 0.5 \end{cases} \tag{3}$$

其中: x_j^1 表示第一个樽海鞘在第 j 维空间的位置, F_j 代表食物源在同一维度的位置。 ub_j 和 lb_j 分别表示搜索空间的上下界。参数 c_2 和 c_3 为区间 $[0, 1]$ 范围内的随机数。

由式 (3) 可知, 食物源位置 F 主导着领导者的搜索方向。调节系数 c_1 作为核心控制参数, 直接影响算法的探索—开发平衡特性。该参数采用动态递减策略, 其计算过程如下:

$$c_1 = 2e^{-(4t/T_{\max})^2} \tag{4}$$

其中: t 为当前代数, $T_{\max}$ 为总代数。这种非线性递减机制使得算法在早期迭代阶段 (t 较小时) c_1 值较大, 赋予领导者位置更新项较大的权重, 促使种群在搜索空间内进行大范围的、随机性的探索, 有助于广泛采样, 避免过早陷入局部最优; 随着迭代进行 (t 增大), c_1 逐渐减小, 领导者位置更新项的影响微乎其微, 算法的搜索行为从全局探索自然过渡到围绕当前最优解的局部精细开发, 确保算法能够收敛。采用指数平方形式的衰减 ($e^{-(4t/T_{\max})^2}$) 相较于线性衰减, 其优势在于迭代初期衰减缓慢, 维持较长时间的强探索能力; 迭代后期衰减迅速, 能快速切入开发阶段。

虽然在第 t 代时算法不知道未来, 但作为算法的使用者或设计者, 在运行算法之前就已经确定了整个搜索过程的“生命周期” $T_{\max}$ 。公式中的 $t/T_{\max}$ 是一个归一化的迭代进度。一旦 $T_{\max}$ 被设定, c_1 随归一化进度 ($t/T_{\max}$) 自适应变化的机制也就完全确定。

对于追随者的位置更新, 具体表达式如下:

$$x_j^i = \frac{1}{2}(x_j^i + x_j^{i-1}) \tag{5}$$

因此, 由式 (3) 和式 (5) 完整再现了樽海鞘群体的链式运动特征。

3 混沌高斯折射学习的樽海鞘群算法

3.1 改进 Tent 映射的种群初始化

在缺乏先验信息的前提下, SSA 通常以随机撒点的方式获得首代群体, 但这种“盲目”布点往往造成个体聚集在局部位置, 进而拖慢收敛并降低精度。研究指出, 若能令初始点在可行域内实现近似均匀覆盖, 可显著提升后续搜索效率^[17]。

混沌序列因其独特的随机遍历特性, 为种群初始化提供了思路。通过特定的映射关系, 可以首先在 $[0, 1]$ 区间生成混沌序列, 再将其映射到实际的搜索空间。在众多混沌模型中, Tent 映射因其生成的序列均匀性优于 Logistic 映射而受到关注^[18]。然而, 标准 Tent 映射存在周期性和不稳定等问题。针对这一缺陷, 研究者提出了一种改进方案: 在原有 Tent 映射中引入随机扰动项 r/N , 改进后的 Tent 映射表达式为:

$$y_{j+1}^i = \begin{cases} \mu y_j^i + r/N, & y_j^i < 0.5 \\ \mu(1 - y_j^i) + r/N, & y_j^i \geq 0.5 \end{cases} \tag{6}$$

其中: $\mu \in [0, 2]$ 是混沌参数, μ 越大, 混沌性越好, 本文取 $\mu=2$, $i = 1, 2, \dots, N$ 表示种群规模, $j = 1, 2, \dots, d$ 表示混沌变量序号, r 为 $[0, 1]$ 区间内的随机数, N 表示种群规模。

在 μ 的定义域 $[0, 2]$ 内, 当且仅当 $\mu=2$ 时, 李雅普诺夫指数取得最大值 $\lambda_{\max} = \ln(2) \approx 0.693$ 。此时混沌强度达到理论极限。生成的混沌序列具有最宽的遍历范围和最好的伪随机特性。将其用于初始化种群, 可

以确保个体在解空间内分布得尽可能均匀和广泛,为后续的优化搜索提供一个最好的起始状态。当 $\mu < 2$, 虽然仍处于混沌状态,但其混沌强度较弱。产生的序列其遍历范围可能不足,随机性也相对较差,可能导致初始种群分布不够均匀,从而削弱算法前期的全局探索效果。

Tent 混沌映射对初始值具有高度敏感性,利用这一特性,只需为式 (6) 设定 d 个仅有细微差别的初值,便可并行生成 d 条均匀且互不重叠的混沌序列,随后通过线性逆映射:

$$x_j^i = lb_i + (ub_i - lb_i) y_j^i \quad (7)$$

其中: $[lb_i, ub_i]$ 为 x_j^i 的搜索范围。

3.2 高斯变异的更新策略

原 SSA 在领导者位置更新依赖指数递减的“粗调”步长 c_1 , 虽能随迭代收缩,却难以兼顾“全局”与“局部”双重需求,且固定方向的扰动容易错过更优解。针对这一短板,本文把高斯变异嵌入更新公式 (3), 在每一次位置修正后,再叠加一个零均值、方差随迭代自适应的高斯扰动项,如下:

$$x_j^1 = \begin{cases} F_j + c_1((ub_j - lb_j)c_2 + lb_j) + N(0, \sigma^2) & c_3 \geq 0.5 \\ F_j - c_1((ub_j - lb_j)c_2 + lb_j) + N(0, \sigma^2) & c_3 < 0.5 \end{cases} \quad (8)$$

$$\sigma = \eta(ub_i - lb_i)e^{-\lambda(t/T_{\max})} \quad (9)$$

其中: N 为高斯变异步长; σ 为搜索空间动态比例; η 为扰动系数; λ 为衰减因子, 取为 1; 随着迭代次数 t 的增加, σ 逐渐减小, 后期偏向局部开发。

系数 η (通常取 $0 < \eta \leq 0.1$) 用于精细调控初始扰动强度与搜索范围之间的比例关系。若 η 过小 (如 < 0.01), 则初始扰动 σ 过小, 变异项微不足道, 难以在搜索初期产生有意义的探索, 无法有效跳出局部最优。若 η 过大 (如 > 0.2), 则初始扰动 σ 可能接近甚至超过整个搜索范围的宽度。这意味着变异后的新解可能被抛到离当前有希望区域非常遥远的地方, 严重破坏算法的收敛过程, 使其性能接近于随机搜索。

大量文献表明, η 取值在 $[0.05, 0.1]$ 区间内是一个广泛有效且鲁棒的选择。本文取 $\eta = 0.1$ 。该取值既能保证在迭代初期提供足够强的探索能力, 又能确保扰动是可控的、围绕当前解的局部搜索, 而非盲目地全局跳跃, 较好地平衡了探索的有效性和安全性。

λ 决定了算法搜索策略切换的速度。较大的 λ 意味着扰动快速衰减, 算法较早进入开发阶段; 较小的 λ 则使扰动缓慢衰减, 算法维持更长时间的探索。 $\lambda = 1$ 是一个在众多优化算法 (如模拟退火、进化策略) 中被广泛验证的普适值。它确保了算法在大部分问题上能表现出稳定且良好的性能。

在算法迭代初期 ($t \rightarrow 0$), $e^{\lambda(t/T_{\max})} \approx 1$, 此时方差 σ

$\approx \eta(ub_j - lb_j)$ 。确保了扰动幅度与各维变量的搜索范围 ($ub_j - lb_j$) 成正比, 有助于逃离局部最优区域。

随着迭代进行 ($t \rightarrow T_{\max}$), $e^{\lambda(t/T_{\max})} \rightarrow 0$, 逐渐衰减至接近零。此时, 一个趋于零的微小方差能够为最优解提供细微的随机微调, 既增强了局部的开发能力, 又保留了最终跳出局部极值的微小潜力。

为了避免过度扰动, 可对变异后的位置进行边界约束, 约束如下:

$$x_j^1 = \min[\max(x_j^1, lb_j), ub_j] \quad (10)$$

对于高斯变异的领导者位置更新策略有如下优势:

1) 增强逃离局部最优能力: 高斯扰动为领导者提供随机跳跃机会, 尤其在局部最优附近。2) 平衡探索与开发: 动态调整的 σ 确保早期强探索、后期弱扰动。3) 低计算开销: 高斯变异仅增加少量随机数生成操作, 不影响算法整体效率。

3.3 折射原理的学习策略

在标准 SSA 算法中, 追随者的位置更新机制存在明显的局限性。根据式 (5), 每个追随者个体的新位置完全取决于其自身和前一个体的当前位置, 这种强依赖性会导致两个关键问题: 位置更新仅考虑相邻个体信息; 追随者易陷入局部最优, 导致搜索提前停滞出现。

为解决尾部追随者易陷局部最优的问题, 本文借鉴光的折射现象, 设计了针对“最差个体”的折射学习机制。如图 2 所示, 将搜索区间 $[a, b]$ 的中点 O 视为空气—介质分界面, 个体 x 为个体的搜索空间。先在 x 正上方取一入射点 x' 与 O 的距离为 h , 依据斯涅尔定律计算折射路径, 得到折射点 x^* 及其在界面上的投影 x^* , 该投影即为 x 的折射解。该策略把最差个体“折射”到搜索空间另一侧, 从而打破链式路径依赖, 增强群体跳出停滞区域的能力。




图 2 折射学习的原理图

由图 2 可知:

$$\sin \alpha = [(a+b)/2 - x]/h \quad (11)$$

$$\sin \beta = (x^* - (a+b)/2)/h^* \quad (12)$$

由式 (11) 和 (12) 可得, 折射率 n 可由下式表示:

$$n = \frac{\sin \alpha}{\sin \beta} = \frac{[(a+b)/2 - x]/h}{[x^* - (a+b)/2]/h^*} \quad (13)$$

设 $h/h^* = f$, 则式 (13) 改写为:

$$x^* = (a + b)/2 + (a + b)/(2fn) - x/fn \quad (14)$$
$$n = n_{\max} - (n_{\max} - n_{\min})t/T_{\max} \quad (15)$$

其中: x 为某追随者坐标, x^* 为其折射映射点; a 、 b 界定搜索上下限; f 是入射光线与折射光线的长度比, 本文取值为 1 意味着将入射空间(当前解空间)与折射空间(新解空间)视为具有相同“光学密度”的对称介质; n 为光线的折射率, $n_{\max}$ 和 $n_{\min}$ 分别是折射率最大值、最小值, t 、 $T_{\max}$ 分别是当前迭代数和最大迭代数。在式(14)、式(15)中, n 会随着迭代次数 t 的增大而逐渐增大, 当 n 小于 1 时, 搜索代理向其他区域映射, 以此增大算法在全局探索阶段找到全局最优区域的可能性; n 值大于 1 时, 搜索代理会在局部区域获得反向解, 随着迭代次数的增加, 反向解向某个区域收敛的速度会增加, 以此帮助算法更快地收敛。

与文献 [14] 的反向折射相比, 本策略仅作用于当前最差个体, 借助折射跃迁迅速拉开种群间距, 提升多样性并强化探索。

3.4 ISSA 算法步骤

- 改进樽海鞘群算法的路径规划具体步骤如下:
- 1) 环境建模与参数设置。构建三维空间模型, 设定起止点坐标, 配置种群规模 N 和最大迭代次数 T 等参数。
 - 2) 种群初始化。采用改进 Tent 混沌映射生成初始种群, 将个体均匀分布在解空间
 - 3) 适应度评估。计算每个个体的路径适应度值, 路径长度指标。
 - 4) 食物源选择。根据适应度排序, 选取当前最优个体作为食物源引导搜索方向。
 - 5) 位置更新机制。前 $N/3$ 个体执行高斯变异领导者更新, 中间 $N/3$ 个体进行标准追随者更新, 后 $N/3$ 最差个体实施折射学习优化。
 - 6) 迭代优化。循环执行适应度计算、食物源更新和路径记录, 直至满足终止条件。
 - 7) 结果输出。返回最优路径解, 包含完整的三维航路点序列。

4 仿真实验与结果分析

4.1 仿真环境和参数设置

为检验 ISSA 的性能与稳定性, 选取 6 个典型基准函数, 与 SSA、PSO、GA 各独立运行 50 次, 并同步开展无人机三维航迹仿真。各算法参数见表 1。

4.2 标准测试函数实验

实验采用统一的测试框架: 设置最大迭代次数为 1 000 次, 各算法 (SSA、PSO、GA 及 ISSA) 的初始种群规模均固定为 30 个个体。为验证算法的维度适应性, 测试分别在 10 维、30 维和 100 维 3 种不同规模的问题

表 1 算法参数设置

算法	主要参数
ISSA	混沌参数 $\mu = 2, \eta = 0.1, \lambda = 1$
SSA	
PSO	惯性权重 $\omega = 1$, 学习因子 $c_1 = c_2 = 1.5$ 个体速度限制为 $[-0.5, 0.5]$
GA	交叉概率 $p_c = 0.6$, 变异概率 $p_m = 0.01$ 采用轮盘赌的选择操作, 交叉和变异操作位置为随机多点

空间展开, 确保评估结果的全面性和可比性。

实验一: 本研究选取 6 个典型基准测试函数进行算法验证, 这些函数可分为两类特征:

单峰函数测试: 定义域内仅含单一全局最优解, 评估算法收敛速度和精度。

多峰函数测试: 存在多个局部极值点, 检验算法全局搜索能力。

测试函数维度设置为 10 至 100 维, 如表 2 所示。通过不同规模的问题空间全面考察算法性能。需要指出的是, 算法在低维空间的优化效果不能直接推广到高维情况, 因此多维度的测试设计更能反映算法的实际性能。

表 2 基准函数

函数	维度	特征	定义域	最佳值
f_1 Schwefel 1.2	10/30/100	单峰	$[-100, 100]$	0
f_2 Schwefel 2.21	10/30/100	单峰	$[-100, 100]$	0
f_3 Quartic	10/30/100	单峰	$[-1.28, 1.28]$	0
f_4 Ackley	10/30/100	多峰	$[-32, 32]$	0
f_5 Griewank	10/30/100	多峰	$[-600, 600]$	0
f_6 Penalized	10/30/100	多峰	$[-50, 50]$	0

实验数据统计结果如表 3 至表 5 所示, 通过 50 次独立运行对比了各算法的综合性能。评价指标包含 4 个方面: 在求解精度方面, 记录最优解 (Best) 反映算法的最佳表现, 平均解 (Mean) 体现整体优化水平; 算法稳定性通过标准差 (Std) 衡量结果的波动程度; 计算效率以平均耗时 (Time/s) 表征; 成功率 (SR%), 成功率定义为达标次数与总次数之比, 其中单次的成功判定标准如下:

$$\begin{cases} |F_A - F_T| / F_T < 1e^{-3}, & F_T \neq 0 \\ |F_A - F_T| < 1e^{-3}, & F_T = 0 \end{cases} \quad (16)$$

其中: F_A 为求解最佳值, F_T 为测试函数理论最佳值。

实验数据分析显示, ISSA 算法在各项测试中均表现出色。通过对比最优解和平均解两个关键指标, 可以观察到该算法具有优异的收敛特性和搜索能力。在单峰函数测试集 ($f_1 - f_3$) 上, ISSA 的求解精度达到 $1 \times$

表 3 各算法求解 10 维测试函数的结果

测试函数		ISSA	SSA	PSO	GA
f_1	Best	9.69×10^{-12}	2.70×10^{-10}	3.11×10^{-4}	1.52×10^3
	Mean	5.62×10^{-11}	1.79×10^{-9}	3.39×10^{-3}	4.54×10^3
	Std	2.20×10^{-11}	1.04×10^{-9}	2.04×10^{-3}	2.23×10^3
	SR $\%$	100	100	4	0
	Time/s	1.32	0.78	0.71	1.33
f_2	Best	1.47×10^{-6}	1.04×10^{-5}	4.75×10^{-3}	7.80×10^0
	Mean	5.96×10^{-6}	1.63×10^{-5}	1.38×10^{-2}	2.06×10^1
	Std	2.03×10^{-6}	4.73×10^{-6}	5.80×10^{-3}	7.48×10^0
	SR $\%$	100	100	0	0
	Time/s	0.56	0.41	0.34	0.98
f_3	Best	4.13×10^{-6}	1.27×10^{-3}	1.29×10^{-3}	2.66×10^{-3}
	Mean	2.53×10^{-4}	6.06×10^{-3}	5.76×10^{-3}	5.68×10^{-2}
	Std	2.17×10^{-4}	4.75×10^{-3}	3.48×10^{-3}	4.87×10^{-2}
	SR $\%$	100	0	0	0
	Time/s	0.61	0.43	0.34	1.01
f_4	Best	1.39×10^{-6}	1.15×10^0	2.01×10^0	2.00×10^0
	Mean	3.71×10^{-6}	1.64×10^0	2.69×10^0	2.87×10^0
	Std	1.76×10^{-6}	4.74×10^{-1}	5.95×10^{-1}	7.54×10^{-1}
	SR $\%$	100	0	0	0
	Time/s	0.70	0.48	0.40	1.05
f_5	Best	3.27×10^{-11}	6.39×10^{-2}	1.39×10^0	1.35×10^{-1}
	Mean	7.53×10^{-10}	2.24×10^{-1}	4.18×10^0	6.88×10^{-1}
	Std	5.56×10^{-10}	1.17×10^{-1}	1.84×10^0	5.02×10^{-1}
	SR $\%$	100	0	0	0
	Time/s	0.60	0.43	0.36	1.02
f_6	Best	2.90×10^{-12}	1.46×10^{-5}	3.80×10^{-4}	7.43×10^{-4}
	Mean	1.06×10^{-11}	6.03×10^{-1}	1.40×10^{-2}	5.68×10^{-1}
	Std	4.47×10^{-12}	9.92×10^{-1}	6.22×10^{-2}	8.04×10^{-1}
	SR $\%$	100	40	34	2
	Time/s	1.26	0.73	0.66	1.28

表 4 各算法求解 30 维测试函数的结果

测试函数		ISSA	SSA	PSO	GA
f_1	Best	2.09×10^{-9}	4.13×10^1	1.49×10^0	2.46×10^1
	Mean	9.82×10^{-8}	2.84×10^2	4.22×10^0	4.71×10^1
	Std	1.47×10^{-7}	227×10^2	1.51×10^0	1.23×10^1
	SR $\%$	100	0	0	0
	Time/s	3.19	1.76	1.66	2.28
f_2	Best	7.79×10^{-6}	3.31×10^0	2.10×10^{-1}	5.48×10^1
	Mean	1.53×10^{-5}	8.66×10^0	1.73×10^0	6.93×10^1
	Std	4.65×10^{-6}	4.15×10^0	1.25×10^0	8.44×10^0
	SR $\%$	100	0	0	0
	Time/s	0.633	0.46	0.36	1.01
f_3	Best	3.26×10^{-5}	2.63×10^{-2}	3.28×10^{-2}	6.61×10^{-1}
	Mean	3.54×10^{-4}	9.81×10^{-2}	9.51×10^{-2}	7.55×10^0
	Std	2.21×10^{-4}	4.08×10^{-2}	3.11×10^{-2}	7.56×10^0
	SR $\%$	100	0	0	0
	Time/s	0.876	0.58	0.47	1.13

续表

测试函数		ISSA	SSA	PSO	GA
f_4	Best	5.12×10^{-6}	1.30×10^{-1}	3.51×10^0	6.72×10^0
	Mean	1.12×10^{-5}	2.33×10^0	5.68×10^0	1.35×10^1
	Std	3.35×10^{-6}	8.12×10^{-1}	1.08×10^0	2.20×10^0
	SR $\%$	100	0	0	0
	Time/s	0.788	0.54	0.44	1.07
f_5	Best	4.34×10^{-9}	7.39×10^{-3}	1.57×10^1	1.88×10^1
	Mean	1.76×10^{-8}	1.68×10^{-2}	2.62×10^1	$6.8.6 \times 10^1$
	Std	9.20×10^{-9}	1.35×10^{-2}	6.14×10^0	3.37×10^1
	SR $\%$	100	0	0	0
	Time/s	0.695	0.49	0.43	1.05
f_6	Best	8.93×10^{-3}	3.76×10^{-1}	3.16×10^{-1}	3.54×10^4
	Mean	2.09×10^{-2}	4.81×10^0	2.59×10^0	1.27×10^7
	Std	5.76×10^{-3}	2.56×10^0	8.90×10^{-1}	162×10^7
	SR $\%$	0	0	0	0
	Time/s	1.78	1.03	0.92	1.58

表 5 各算法求解 100 维测试函数的结果

测试函数		ISSA	SSA	PSO	GA
f_1	Best	4.48×10^{-3}	1.24×10^4	3.30×10^3	2.94×10^5
	Mean	2.15×10^0	4.17×10^4	6.53×10^3	5.41×10^5
	Std	1.54×10^0	1.83×10^4	3.63×10^3	1.28×10^5
	SR $\%$	0	0	0	0
	Time/s	10.463	5.578	5.225	5.794
f_2	Best	1.49×10^{-5}	2.01×10^1	7.43×10^0	8.75×10^1
	Mean	2.48×10^{-5}	2.66×10^1	9.55×10^0	9.34×10^1
	Std	7.37×10^{-6}	3.00×10^0	1.18×10^0	2.21×10^0
	SR $\%$	100	0	0	0
	Time/s	0.950	0.765	0.450	1.038
f_3	Best	2.06×10^{-4}	7.17×10^{-1}	1.70×10^0	4.17×10^2
	Mean	2.74×10^{-3}	1.42×10^0	5.98×10^0	7.68×10^2
	Std	2.58×10^{-3}	3.65×10^{-1}	1.21×10^1	1.82×10^2
	SR $\%$	26	0	0	0
	Time/s	1.942	1.258	0.906	1.538
f_4	Best	2.28×10^{-5}	3.95×10^0	6.58×10^0	1.92×10^1
	Mean	5.77×10^{-1}	7.20×10^0	8.05×10^0	1.98×10^1
	Std	3.22×10^{-1}	1.27×10^0	6.77×10^{-1}	2.30×10^{-1}
	SR $\%$	10	0	0	0
	Time/s	1.233	0.923	0.593	1.178
f_5	Best	2.77×10^{-8}	2.82×10^{-1}	9.19×10^1	8.37×10^2
	Mean	1.35×10^{-3}	7.12×10^{-1}	1.18×10^2	1.35×10^3
	Std	2.04×10^{-3}	2.27×10^{-1}	1.67×10^1	1.42×10^2
	SR $\%$	66	0	0	0
	Time/s	1.154	0.871	0.656	1.159
f_6	Best	1.13×10^{-1}	8.01×10^0	2.96×10^0	5.94×10^8
	Mean	1.76×10^{-1}	1.78×10^1	4.32×10^0	1.01×10^9
	Std	4.22×10^{-2}	4.65×10^0	8.28×10^{-1}	2.07×10^8
	SR $\%$	0	0	0	0
	Time/s	3.846	2.201	1.849	2.486

10^{-12} 级别, 显著优于其他对比算法。随着问题维度从 10 维增加到 100 维, 所有算法的性能均有所下降, 但 ISSA 展现出更好的维度适应性。特别是在处理 100 维 Schwefel 1.2 函数时, 标准 SSA 算法出现 1×10^4 级别的较大误差, 而 ISSA 仍能保持稳定的优化精度, 验证了其在高维问题中的优势。

针对多峰基准函数 f_4-f_6 的测试结果显示, 尽管整体精度较单峰情形有所下滑, ISSA 依旧保持显著领先。即便在 100 维 Penalized (f_6) 场景下, 其误差仅落在 1×10^{-1} 量级, 仍明显优于 SSA、PSO 与 GA。综合来看, ISSA 无论面对单峰或多峰、低维或高维问题, 均展现出稳定的搜索能力与可靠的鲁棒表现。

在成功率测试中, ISSA 展现出卓越的稳定性, 除 100 维问题外均实现 100% 的成功率。与之形成鲜明对比的是, 标准 SSA 仅在 f_1 和 f_2 两个单峰函数上取得完全成功, 其他测试案例的成功率均为零。特别值得注意的是, 随着问题维度的增加, 标准 SSA 的优化性能急剧下降, 其标准差和成功率指标均显著下降。这种差异主要源于 ISSA 创新的高斯变异机制, 该设计使算法在迭代过程中保持更强的全局探索能力。

在计算效率方面, 实验结果显示 ISSA 的运行时间略长于标准 SSA, 主要原因在于高斯变异与折射学习策略引入了额外的计算环节; 而 PSO 与 SSA 在耗时方面互有胜负, 均低于 ISSA 与 GA。尽管 ISSA 的耗时有所增加, 但增量处于可接受范围, 用有限的额外时间换取了寻优精度和鲁棒性的提升, 工程应用中的性价比仍然良好。

为客观评估算法性能差异, 本研究采用严格的统计分析方法。参考 Derrac 等人^[19]的研究成果, 针对 50 次独立实验数据, 在显著性水平 $\alpha=0.05$ 条件下进行非参数检验。具体而言, 通过 Wilcoxon 秩和检验对 ISSA 与 SSA、PSO、GA 等基准算法的优化结果进行两两比较, 以验证改进策略的有效性。这种检验方法避免了传统均值比较的局限性, 能够更可靠地判定算法间的性能差异。

表 6 为各基准函数下算法两两比较的 p-value 结果。检验方案如下: 若 ISSA 被判为当前函数最优算法, 则依次进行 ISSA vs SSA、ISSA vs PSO 与 ISSA vs GA 三组成对检验; 对于表中已标注为 N/A 的最优算法, 则跳过与自身的比较。依照 Derrac 等人提出的评判准则, 当所得 p-value 低于 0.05 时, 即可拒绝零假设, 认定算法间的性能差异具有统计学显著性。这一统计验证过程为确认改进策略的有效性提供了可靠的依据。

表 6 的统计检验结果证实了 ISSA 算法的显著优势。在所有基准测试中, ISSA 与对比算法的 Wilcoxon 检验 p 值均小于 0.05, 这一结果表明: 1) 算法改进策

表 6 Wilcoxon 秩和检验的 p-value

F	D	ISSA	SSA	PSO	GA
f_1	10	N/A	7.06×10^{-18}	7.06×10^{-18}	7.06×10^{-18}
	30	N/A	7.07×10^{-18}	7.07×10^{-18}	7.07×10^{-18}
	100	N/A	7.06×10^{-18}	7.06×10^{-18}	7.06×10^{-18}
f_2	10	N/A	7.06×10^{-18}	7.06×10^{-18}	7.06×10^{-18}
	30	N/A	7.07×10^{-18}	7.07×10^{-18}	7.07×10^{-18}
	100	N/A	7.07×10^{-18}	7.07×10^{-18}	7.07×10^{-18}
f_3	10	N/A	7.06×10^{-18}	7.06×10^{-18}	7.06×10^{-18}
	30	N/A	7.07×10^{-18}	7.07×10^{-18}	7.07×10^{-18}
	100	N/A	7.07×10^{-18}	7.07×10^{-18}	7.07×10^{-18}
f_4	10	N/A	7.01×10^{-18}	7.01×10^{-18}	7.01×10^{-18}
	30	N/A	7.07×10^{-18}	7.07×10^{-18}	7.07×10^{-18}
	100	N/A	7.05×10^{-18}	7.05×10^{-18}	7.05×10^{-18}
f_5	10	N/A	7.06×10^{-18}	7.06×10^{-18}	7.06×10^{-18}
	30	N/A	7.06×10^{-18}	7.06×10^{-18}	7.06×10^{-18}
	100	N/A	7.07×10^{-18}	7.07×10^{-18}	7.07×10^{-18}
f_6	10	N/A	7.06×10^{-18}	7.06×10^{-18}	7.06×10^{-18}
	30	N/A	7.07×10^{-18}	7.07×10^{-18}	7.07×10^{-18}
	100	N/A	7.07×10^{-18}	7.07×10^{-18}	7.07×10^{-18}

略有有效提升了收敛精度; 2) 性能优势具有统计显著性; 3) 实验结果可重复性强。这些发现从统计学角度验证了 ISSA 在优化问题求解中的可靠性和稳定性。

本研究引入平均绝对误差 (MAE) 作为补充评价指标, 该方法的有效性已在文献 [20] 中得到验证。MAE 计算公式如下:

$$MAE = \frac{\sum_{i=1}^{N_f} |m_i - o_i|}{N_f}$$

(17)

其中: m_i 算法求解结果的平均值, o_i 理论最优解, N_f 测试函数数量。通过 MAE 值可以直观比较各算法的整体性能差异。这一指标能够有效反映算法在多个测试函数上的综合表现, 为性能评估提供量化依据。计算出的 MAE 如表 7 所示。

表 7 MAE 算法排名

算法	$D=10$ MAE/Rank	$D=30$ MAE/Rank	$D=100$ MAE/Rank
ISSA	$1.16 \times 10^{-6}/1$	$1.50 \times 10^{-3}/1$	$1.96 \times 10^{-2}/1$
SSA	$2.00 \times 10^{-1}/2$	$7.53 \times 10^0/3$	$2.07 \times 10^3/3$
PSO	$5.60 \times 10^{-1}/3$	$3.56 \times 10^0/2$	$5.68 \times 10^2/2$
GA	$2.55 \times 10^2/4$	$1.00 \times 10^4/4$	$9.91 \times 10^7/4$

表 7 给出的 MAE 结果显示, ISSA 在所有测试函数上的 MAE 为最小, 综合排名锁定第一。该量化评估进一步表明, 相较于 SSA、PSO 与 GA 等传统方法, ISSA 在求解精度与稳定性方面均占据优势, 从而再次验证了本文改进策略的切实有效性。

图 3 给出 6 个函数在 30 维的平均收敛曲线。由于

不同算法收敛精度存在较大差异，便于观察收敛情况，本文对寻优适应度值（纵坐标）取 10 为底的对数。在单峰函数优化方面（图 3a—c），ISSA 展现出显著的收敛优势：1）收敛速率最快；2）持续优化能力突出，未出现早熟收敛现象。相比之下，PSO 和 SSA 在迭代后期均表现出不同程度的停滞，且最终收敛精度较低。




图 3 基准函数平均收敛曲线（30 维）

在多峰函数的收敛特性分析中（图 3d—f），ISSA 表现出独特的收敛特性。具体而言，该算法在 f_4 和 f_5 函数优化过程中呈现出先缓后急的收敛特征，在 f_6 函数上则展现出持续稳定的优化能力。相比之下，传统优化算法在多峰问题求解中普遍存在明显的早熟收敛现象，表现为优化过程提前停滞或解质量波动较大。实验结果表明，ISSA 算法在不同特征的测试函数上均能保持稳定的收敛性能，克服了传统算法在多峰优化中的局限性。这些收敛曲线直观地展示了改进策略在增强算法搜索能力方面的有效性。

实验二：为进一步检验 ISSA 的可靠性与稳健性，本文从 CEC2014 测试集中抽取部分单峰、多峰、混合（Hybrid）及复合（Composition）函数进行验证。实验参数设定为种群 30，迭代上限 500，维度固定 30，详情见表 8。

表 9 汇总了 30 次独立运行的统计结果。面对 CEC2014 的高复杂度函数，ISSA 在所有算例中均优于 SSA、PSO 与 GA；其均值更接近理论极值，标准差亦

更小。该结果再次表明了 ISSA 算法在处理复杂优化问题时的有效性和鲁棒性。

表 8 CEC2014 基准函数

函数	维度	特征	定义域	最佳值
CEC01	30	UN	$[-100,100]$	100
CEC02	30	UN	$[-100,100]$	200
CEC04	30	MN	$[-100,100]$	400
CEC05	30	MN	$[-100,100]$	500
CEC17	30	HF	$[-100,100]$	1700
CEC26	30	CF	$[-100,100]$	2600

表 9 CEC2014 优化结果对比

CEC	指标	ISSA	SSA	PSO	GA
01	Mean	$1.469\ 4\times10^7$	$3.676\ 6\times10^7$	$2.387\ 9\times10^7$	$1.218\ 6\times10^9$
	Std	$3.981\ 8\times10^8$	$1.629\ 7\times10^7$	$1.137\ 9\times10^7$	$3.673\ 9\times10^8$
02	Mean	$4.111\ 6\times10^2$	$1.135\ 9\times10^4$	$5.184\ 6\times10^7$	$6.102\ 3\times10^{10}$
	Std	$1.480\ 5\times10^2$	$1.097\ 3\times10^4$	$2.007\ 9\times10^8$	$8.138\ 1\times10^9$
04	Mean	$4.797\ 3\times10^2$	$5.467\ 5\times10^2$	$5.586\ 1\times10^2$	$1.587\ 9\times10^4$
	Std	$1.186\ 7\times10^4$	$4.076\ 1\times10^1$	$2.652\ 3\times10^1$	$1.921\ 1\times10^3$
05	Mean	$5.200\ 0\times10^2$	$5.200\ 8\times10^2$	$5.210\ 5\times10^2$	$5.210\ 7\times10^2$
	Std	$2.635\ 0\times10^4$	$1.078\ 6\times10^1$	$6.309\ 5\times10^2$	$5.058\ 4\times10^{-2}$
17	Mean	$3.571\ 3\times10^5$	$2.276\ 3\times10^6$	$1.093\ 9\times10^6$	$1.054\ 9\times10^8$
	Std	$2.727\ 8\times10^5$	$1.168\ 9\times10^6$	$1.526\ 9\times10^6$	$5.529\ 9\times10^7$
26	Mean	$2.700\ 2\times10^3$	$2.700\ 6\times10^3$	$2.783\ 9\times10^3$	$2.783\ 8\times10^3$
	Std	$2.323\ 2\times10^{-2}$	$1.124\ 5\times10^{-1}$	$7.558\ 7\times10^1$	$3.189\ 6\times10^1$

综合上述全部实验结果，混沌-高斯-折射樽海鞘群算法（ISSA）在单峰、多峰、混合及复合函数上均求解到较好结果。首先，无论维度从 10 维升至 100 维，ISSA 的误差曲线始终保持最快的初期下降与最小的后期波动，显示其“早-中期广域勘探”与“后期精细微调”衔接得当；其次，Wilcoxon 秩和检验与 MAE 排序一致证实，ISSA 的改进并非偶然，而是具有统计学显著性的系统性优势。此外，CEC2014 复杂测试集上的结果进一步表明，ISSA 的均值与标准差均优于 SSA、PSO 与 GA，验证了其对于高维非线性问题的适应能力。值得注意的是，算法耗时虽略高于传统 SSA，但增量稳定且可控。综上，ISSA 通过混沌初始化提升种群多样性、高斯扰动增强全局搜索能力、折射学习加速最差个体迁移，三策略协同作用，使算法在收敛速度、精度与鲁棒性之间取得有效平衡，为高维复杂优化提供了一种可靠的新选择。

4.3 改进樽海鞘群算法的无人机三维路径规划仿真

本文提出的路径规划方法主要针对静态环境下的离线任务规划需求，特别适用于无人机在已知环境中的各类作业场景，包括但不限于基础设施巡检、灾害搜救等应用领域。通过仿真实验验证，该方法在离线规划场景

下展现出良好的计算效率, 能够满足实际应用的实时性要求。

在实验验证环节, 本研究构建了一个规模为 21 公里(长)×21 公里(宽)×2 公里(高)的三维栅格化环境模型, 用于模拟无人机的典型作业空间。采用栅格法对规划空间进行离散化处理, 其中 X 轴(东西向)和 Y 轴(南北向)均以 1 km 为间隔划分, Z 轴(高度向)以 200 m 为间隔分层, 共形成 21×21×10 的栅格化空间。起点设置为位置坐标 (1, 10, 0.8), 对应栅格索引 [1, 10, 4]; 终点坐标为 (21, 4, 1), 对应栅格索引 [21, 4, 5]。地形障碍, 将海拔高度 ≥800 m 的区域标记为禁飞区。

为全面评估所提方法的性能优势, 验证提出的改进樽海鞘群算法 (ISSA) 性能, 与标准樽海鞘群算法 (SSA)、粒子群优化算法 (PSO) 以及遗传算法 (GA) 进行仿真对比。从路径质量、收敛速度和稳定性等多个维度验证了所提方法的优越性。设置种群规模 30、最大迭代次数 200 次, 分别进行 30 次实验。

- 主要参数配置如下:
- 1) 空间维度: 21 km×21 km×2 km;
 - 2) 栅格划分: X/Y 轴 1 km 间隔, Z 轴 200 m 间隔;
 - 3) 起止点: 起点 [1, 10, 4], 终点 [21, 4, 5];
 - 4) 障碍设置: 地形障碍 ≥800 m;
 - 5) 算法参数: 种群 30, 迭代 200 次。

图 4 给出了改进樽海鞘群算法 (ISSA)、樽海鞘群算法 (SSA)、粒子群优化算法 (PSO) 以及遗传算法 (GA) 这 4 种算法的无人机三维路径空间规划图, 从图中可以看出, 每种算法都能有效地避开障碍物, 且不出超空域范围。其中 ISSA 算法的路径规划更短, 证明改进后的算法能够寻找到更优的路径。




图 4 不同算法无人机三维路径规划图

图 5 给出了 4 种不同智能算法在无人机三维路径规划下的收敛曲线, 从图中可以看出所提方法在初期搜索方向性更明确, 路径搜索能力显著优于其它几种算法。将 4 种算法下最优路径长度和迭代次数进行统计, 统计结果如表 10 所示。从表中可以看出, 与 SSA、PSO、

GA 这 3 种算法相比, 最优路径长度 ISSA 算法的最小为 102.67 m, 表明 ISSA 在寻优精度上更好。而且, 最优路径长度中的最差值也为 103.81 m, 均要比其他 3 种算法的较好。4 种算法的最优路径长度均值也是 ISSA 的最好。ISSA 算法独立 30 次计算的标准差基本比其它 3 种算法都要小。这说明 ISSA 算法对于无人机路径寻优求解有着很好的稳定性。此外, 本文所提的算法能够获得最短的路径, 迭代次数最少, 说明收敛速度也最好。




图 5 不同算法收敛曲线变化趋势

表 10 不同算法路径规划结果对比

指标	ISSA	SSA	PSO	GA
最优值/m	102.67	105.08	109.46	112.62
最差值/m	103.81	111.33	116.56	118.94
均值/m	103.43	107.20	113.48	116.25
标准差	0.44	1.55	2.18	1.93
最小迭代数	13.00	20.00	55.00	36.00

4.4 动态环境适应性的探讨

改进樽海鞘群算法的无人机三维路径规划在性能评估主要聚焦于路径长度和算法收敛速度等核心优化指标, 以验证 ISSA 在寻优能力上的优势。在三维栅格环境中直接生成的路径通常由一系列连续的栅格中心点连接而成, 其平滑性确实存在不足, 可能包含尖锐的拐角。

然而, 需要指出的是, 路径规划与路径平滑在实际工程中通常是两个解耦的步骤。本文的研究重点在于前者, 即解决“能否在复杂约束下找到一条安全、可通的较优路径”这一更基础且关键的问题。ISSA 算法在此方面的卓越表现, 为后续的平滑处理提供了高质量的基础路径, 这本身就是一个重要的贡献。

5 未来研究工作展望

5.1 动态环境适应性的探讨

虽然本文未对动态环境进行仿真验证, 但基于 ISSA 算法的特性, 现对其扩展至动态环境的可行性与初

步思路探讨如下:

算法基础的适应性: 群体智能优化算法 (如 SSA 及其改进算法) 的本质是通过种群迭代寻找最优解。这种在线优化特性使其天然适合于动态环境。一旦环境发生变化 (如感知到新的障碍物), 只需将变化信息更新到代价地图中, 并将当前种群作为先验知识重新启动优化过程, 即可实现路径的快速重规划。ISSA 算法优秀的收敛速度保证了其重规划的实时性潜力。

5.2 路径平滑性的优化方向

路径的平滑性对于无人机的飞行控制、能耗和安全性至关重要。后续研究方案可采用连续化环境表示: 当前的三维栅格地图是离散的。未来可探索与连续化环境表示方法 (如欧氏距离场、八叉树) 相结合, 从而在连续空间中直接生成光滑路径。

6 结束语

本文针对传统樽海鞘群算法存在的种群多样性不足、全局搜索能力弱等问题, 提出了一种融合混沌高斯折射学习机制的改进算法 (ISSA)。通过 Tent 混沌序列生成初始种群, 有效克服了随机初始化带来的种群分布不均匀问题, 显著增强了种群多样性; 在领导者位置更新阶段引入的高斯变异操作, 通过扰动机制拓展了算法的搜索空间, 使全局搜索能力得到明显提升; 基于折射原理的学习策略优化了最劣个体的更新方式, 有效强化了算法的局部搜索性能。在 6 个典型复杂函数和 CEC2014 测试函数集上的对比实验表明, 与 SSA、PSO、GA 等算法相比, 本文提出的 ISSA 算法在收敛速度和寻优精度方面均表现出显著优势, 验证了改进策略的有效性; 无人机三维路径规划仿真结果进一步表明, ISSA 算法在路径长度优化、收敛速度等方面具有一定优势。

参考文献:

- [1] 闫刚, 夏孝程, 李佳明. 基于改进粒子群算法的无人机复杂三维路径规划 [J]. 自动化应用, 2025, 66 (12): 38-42.
- [2] 张琪, 任宇辰, 顾腾达, 等. 无人机航迹规划算法研究进展 [J]. 现代信息科技, 2024, 8 (17): 49-55.
- [3] 池吕庭, 鲁宇明, 黎政秀. 改进 RRT* 算法移动机器人路径规划 [J/OL]. 机械科学与技术, 1-10 [2025-07-21]. <https://doi.org/10.13433/j.cnki.1003-8728.20240032>.
- [4] 焦健, 纪元法, 孙希延, 等. 基于改进 GWO 的多无人机三维协同航迹规划 [J]. 计算机与现代化, 2024 (10): 1-6.
- [5] 刘晓芬, 吴传淑, 张紫瑞, 等. 基于粒子群和蜂群算法的无人机路径规划 [J]. 兵工自动化, 2025, 44 (4): 107

-112.

- [6] HOLLAND J H. Adaptation in natural and artificial systems [M]. Ann Arbor: University of Michigan Press, 1975.
- [7] KENNEDY J, EBERHART R C. Particle swarm optimization [C] // Proc. of the IEEE International Conference on Neural Networks, Perth: IEEE, 1995: 1942-1948.
- [8] NGUYEN P, KIM J M. Adaptive ECG denoising using genetic algorithm-based thresholding and ensemble empirical mode decomposition [J]. Information Sciences, 2016, 373 (10): 499-511.
- [9] MIRJALILI S, GANDOMI A H, MIRJALILI S Z, et al. Salp swarm algorithm: a bio-inspired optimizer for engineering design problems [J]. Advances in Engineering Software, 2017, 114 (6): 163-191.
- [10] 陈忠云, 张达敏, 辛梓芸. 正弦余弦算法的樽海鞘群算法 [J]. 计算机应用与软件, 2020, 37 (9): 209-214.
- [11] HEGAZY A E, MAKHLOUF M A, ELTAWEL G S, et al. Improved salp swarm algorithm for feature selection [J]. Journal of King Saud University Computer and Information Sciences, 2018, 6 (3): 1-10.
- [12] 滕志军, 吕金玲, 郭力文, 等. 一种基于 Tent 映射的混合灰狼优化的改进算法 [J]. 哈尔滨工业大学学报, 2018, 50 (11): 46-55.
- [13] 陈忠云, 张达敏, 辛梓芸. 多子群的共生非均匀高斯变异樽海鞘群算法 [J]. 自动化学报, 2022, 48 (5): 1307-1317.
- [14] 邵鹏, 吴志健, 周炫余, 等. 基于折射原理反向学习模型的改进粒子群算法 [J]. 电子学报, 2015, 43 (11): 2137-2144.
- [15] 刘正锋, 张隆辉, 魏纳新, 等. 环境地图的格栅化及路径规划研究 [J]. 舰船科学技术, 2021, 43 (7): 141-145.
- [16] 唐俊超, 胡春鹤. 三维地形风场环境下无人机全覆盖路径规划 [J/OL]. 系统工程与电子技术, 1-10 [2025-07-17]. <http://kns.cnki.net/kcms/detail/11.2422.TN.20250102.1236.012.html>.
- [17] HAUPT R, HAUPT S. Practical genetic algorithm [M]. New York: John Wiley and Sons, 2004: 38-39.
- [18] 单梁, 强浩, 李军, 等. 基于 Tent 映射的混沌优化算法 [J]. 控制与决策, 2005, 20 (2): 179-182.
- [19] DERRAC, JOAQUIN, GARCIA, et al. A practical tutorial on the use of nonparametric statistical tests as a methodology for comparing evolutionary and swarm intelligence algorithms [J]. Swarm & Evolutionary Computation, 2011, 1 (1): 3-18.
- [20] EMAD N. A modified flower pollination algorithm for global optimization [J]. Expert Systems with Applications, 2016, 57 (15): 192-203.