

基于改进哈里斯鹰优化算法的 无人机路径规划

闫俊辰¹, 刘蓉², 刘嘉君¹

(1. 南京航空航天大学 自动化学院, 南京 210016;
2. 南京航空航天大学 无人机研究院, 南京 210016)

摘要: 智能算法是解决三维环境中无人机路径规划问题的重要工具, 在求解时容易出现陷入局部最优、路径最优性有限的问题; 为解决此问题, 提出了一种基于分工的增强型哈里斯鹰优化算法进行路径规划; 设计了势能波动学习策略增强探索效率, 提高算法对空间的搜索性能; 对算法在开发阶段选择迭代策略时的盲目性问题进行了分析, 提出了分工机制根据种群质量调整猎物逃逸机会, 避免策略的盲目选择; 设计了一种精英时变莱维飞行, 平衡算法对于前期跳出局部最优、后期提高收敛精度的不同需求; 使用仿真实验与其他算法进行对比, 评估改进算法的性能。仿真结果表明, 改进算法在收敛精度和稳定性等方面均得到明显提升, 能有效解决无人机路径规划问题。

关键词: 无人机; 路径规划; 哈里斯鹰优化算法; 势能波动学习; 分工机制; 精英时变莱维飞行

UAV Path Planning Based on Improved Harris Hawk Optimization Algorithm

YAN Junchen¹, LIU Rong², LIU Jiajun¹

(1. College of Automation Engineering, Nanjing University of Aeronautics and Astronautics,
Nanjing 210016, China;
2. Research Institute of UAVs, Nanjing University of Aeronautics and Astronautics,
Nanjing 210016, China)

Abstract: It is an important tool for an intelligent algorithm to solve the path planning of unmanned aerial vehicles (UAVs) in three-dimensional environments, which easily falls into a local optimum and limited optimal path. To solve this problem, an enhanced Harris Eagle optimization algorithm based on division of labor is proposed. Design a potential energy fluctuation learning strategy to enhance the efficiency of exploration, improve the search performance of the algorithm, analyze the blindness of iterative strategy selection in the development stage of the algorithm, present a division of labor mechanism to adjust the escape opportunity of prey according to the population quality to avoid blind strategy selection, and design an elite time-varying levy flight to balance the different requirements of the algorithm, which jumps out of local optimum in the early stage while improving convergence accuracy in the later stage. The performance of the improved algorithm is evaluated by comparing the simulation experiment with other algorithms. Simulation results show that the improved algorithm can obviously improve the convergence accuracy and stability, and can effectively solve the path planning of UAVs.

Keywords: UAV; path planning; Harris Eagle optimization algorithm; potential energy wave learning; division mechanism; elite time-varying Levy flight

收稿日期:2024-11-04; 修回日期:2025-03-31。

基金项目:LZ“十四五”预研项目(LZY202303052)。

作者简介:闫俊辰(2000-),男,硕士研究生。

引用格式:闫俊辰,刘蓉,刘嘉君. 基于改进哈里斯鹰优化算法的无人机路径规划[J]. 计算机测量与控制, 2026, 34(3): 258-265.

0 引言

近年来无人机技术发展迅猛,以其使用成本低、响应速度快等优点,因其可以代替飞行员执行复杂的飞行任务,在军事领域、民用领域均有着广泛应用。路径规划是无人机技术中一个重要的研究领域,是无人机自主完成航行任务的关键基础,其目的是规划一条飞行路径,保证无人机在满足自身约束条件的前提下,能够躲避威胁区域,以尽可能小的能耗,顺利到达目的地^[1]。

当前对于路径规划问题的研究方案主要分为传统算法和智能优化算法两大类。其中传统算法包括 A* 算法^[2]、RRT 算法^[3]、人工势场法^[4]等,这一类算法规划出的路径平滑度一般,容易存在较大转角,需要进一步圆滑处理才能作为全局路径使用,且随着地图范围的扩大,需要消耗大量的时间和计算资源,规划效率会受到影响。相比之下,仿照自然行为的智能优化算法以其寻优速度快、灵活性强等、逻辑易于理解等优点,被广泛地应用于无人机路径规划问题的求解。典型智能优化算法包括粒子群算法^[5]、遗传算法^[6]、鲸鱼优化算法^[7]等。智能优化算法可以在代价函数中综合考虑转弯约束和路径代价等因素,通过优化求解的方式规划出可行路径,相较于传统算法,对日趋复杂的无人机规划问题有更好的适应性^[8]。文献 [9] 将 Logistic 混沌映射和自适应线性变化系数引入粒子群算法,仿真证明这种方法能提高算法收敛速度和收敛精度。文献 [10] 将角度导向因子引入蚁群算法的状态转移规则以改进搜索效率,同时设计自适应调整因子平衡算法的收敛性和全局搜索能力,保证生成路径的平滑性和最优性。文献 [11] 在灰狼算法的基础上使用莱维飞行拓展种群搜索能力,结合共生生物搜索算法的交互性,提高了避免陷入局部最优的能力。

随着智能算法的深入研究,文献 [12] 于 2019 年受 Harris 鹰捕食行为的启发,提出 Harris 鹰优化算法 (HHO),其具有原理简单、参数少和易实现等优点,但缺点是收敛精度低、收敛速度慢和易陷入局部最优^[13]。针对这些缺点,文献 [14] 设计基于个体位置极值的搜索机制提高收敛精度,用自适应扰动因子提高跳出局部最优的能力。文献 [15] 将线性路径策略和非线性控制策略引入 HHO 算法,以提高路径平滑性和收敛精度,但规划时间几乎翻倍。文献 [16] 将 HHO 与基于对立的自学习、混沌局部搜索和自适应技术相结合,以解决局部极值和收敛慢的问题。文献 [17] 引入正弦一余弦算法,用于提高 HHO 算法的全局搜索能力。

上述研究一定程度优化了 HHO 的性能,但缺乏对原算法缺陷的有效分析,在收敛速度、收敛精度上仍存在改进空间。本文针对算法中的不足,设计势能波动学

习策略、分工算子、精英时变莱维飞行策略对 HHO 算法进行改进,最后通过路径规划对比实验,验证改进的有效性。

1 无人机路径规划

1.1 威胁地形建模

在无人机路径规划问题当中,机体所位于的区域环境、当前位置、代价函数的表示方法均需要依赖对环境的模拟构建。对真实飞行环境进行合理的数学抽象是建立环境模型的关键,也是保证路径规划有效实施的重要基础。

无人机路径规划目的是在真实三维环境中高效搜索可行路径,威胁地形模型主要用于表征环境的基本地形约束,为路径规划算法提供不同位置的高度数据,故为了便于地形数据的表达,采用威胁等效地形模拟方法^[18],构建无人机路径规划的飞行环境。威胁等效地形数学模型为:

$$z(x, y) = \sum_{i=1}^p h(i) \cdot \exp \left[- \left(\frac{x - x_{ci}}{x_{ki}} \right)^2 - \left(\frac{y - y_{ci}}{y_{ki}} \right)^2 \right] \quad (1)$$

式中, $z(x, y)$ 表示水平面上 (x, y) 点对应的地形高度; p 表示山峰数量; $h(i)$ 表示第 i 个山峰的顶点高度; x_{ci} , y_{ci} 分别表示第 i 个山峰顶点的横坐标以及纵坐标; x_{ki} , y_{ki} 表示山峰衰减系数,与坡度呈反比。如图 1 所示为威胁等效地形地形示意图,模型的起伏能够保留环境的真实性,并且便于后续路径规划研究的展开。




图 1 威胁等效地形效果图

1.2 障碍物建模

无人机进行路径规划时,还需要考虑环境中会存在碰撞风险的各种障碍物威胁,比如高耸树木、小型建筑、高压电杆、信号塔等。这些静态障碍物的模型差异性较大,且实际情况下可能是不规则的,如果在飞行途中实时计算突发威胁的体积、轮廓等信息,会对机载任务计算机带来较大处理负担。考虑到这些障碍物对无人机造成的威胁主要来源于其俯视横截面的最大轮廓半径,针对最大轮廓半径进行避障能够提高避障成功率并

降低算法计算难度,故本文采用外接圆柱体模型进行一致性表示,如图 2 所示。




图 2 已知障碍物模型效果图

等效圆柱体的半径为障碍物俯视横截面最大轮廓半径,高度为障碍物的高度,这种建模方式能够有效包围障碍物影响范围,并有助于算法实现高效避障。对于实际环境中的多种障碍物,各障碍物生成的外接圆柱体具备不同的高度、横截面积,圆柱体模型具备表征障碍物之间尺寸差异的能力,能够适用于复杂环境多障碍物场景。已知障碍物的威胁区域满足如下条件:

$$\begin{cases} (x - O_x)^2 + (y - O_y)^2 \leq O_r^2 \\ z \leq O_h \end{cases} \quad (2)$$

式中, (x, y, z) 表示空间中某点的坐标; (O_x, O_y) 表示圆柱体模型的底面圆心坐标; O_r 表示圆柱体模型的底面圆半径,数值等于障碍物俯视横截面的最大轮廓半径; O_h 表示圆柱体模型的高度。

1.3 飞行代价建模

针对无人机最优路径的生成问题,需要根据规划目标建立起符合实际需求的代价函数,以代价函数的值作为每次迭代的适应度值,引导算法向适应度值最优的方向求解。代价函数是智能算法和传统算法的主要区别之一,智能优化算法可以将规划目标引入代价函数。本文采用的评价指标主要包括路径长度、路径安全程度、路径平滑度三方面,通过尽可能地缩小代价,直接得到符合预期的有效路径,从而避免对路径的进一步处理操作影响原有路径规划效果。

1) 路径长度代价:

路径规划的重要目标之一,是使规划的路线能够保证无人机高效地从起始点飞往目标点,因此需要将路径总长度作为评价指标,通过优化求解尽可能缩短路径长度。令 $p_i(x_i, y_i, z_i)$ 表示一个路径点,路径 $Path = \{p_0, p_1, p_2, \dots, p_{n-1}, p_n\}$ 表示某条路径的所有路径点集合, p_0 为起始点, p_n 为目标点,路径长度代价函数使用路径点间的欧式距离表示:

$$C_1 = \sum_{i=0}^{n-1} |p_i, p_{i+1}| =$$

$$\sum_{i=0}^{n-1} \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2 + (z_{i+1} - z_i)^2} \quad (3)$$

2) 威胁代价:

路径规划的首要目标是保证飞行安全,因而规划出的路径应当避开环境威胁,本文重点考虑地形因素产生的威胁代价。为平衡计算复杂度和路径安全性,在相邻两个路径点之间等距离选取 5 个分段点,通过这些分段点与环境威胁的距离差确定该路径段的威胁大小,在本文的威胁环境中以高度差代替距离差。威胁代价函数为:

$$C_2 = \frac{1}{5} \sum_{i=1}^n \sum_{j=1}^5 T_j$$

$$T_j = \begin{cases} 0, h_j \geq z_j + h_{\text{safe}} \\ T, h_j < z_j + h_{\text{safe}} \end{cases} \quad (4)$$

式中, T_j 表示每段路径中第 j 个分段点的高度威胁; h_j 表示第 j 个分段点的高度; z_j 表示第 j 个分段点对应的地形高度; h_{safe} 表示安全高度; T 应尽可能大,表示不可以穿越地形。通过这种方式使穿过危险区的路径具有更高适应度,在迭代过程中倾向于向优质解靠近。

3) 平滑度代价:

无人机飞行会受自身机动性能约束,其转弯角和爬升/下滑角都被限制在一定范围内,相邻路径点的转角会影响无人机对路径的跟随效率,角度过大容易引发安全事故。将转弯角和爬升/下滑角的约束统一在路径平滑度代价中,代价函数为:

$$C_3 = \sum_{i=1}^{n-1} S_i$$

$$S_i = \begin{cases} 0, |\varphi_i| \leq \varphi_{\text{max}} \mid \theta_i \leq \theta_{\text{max}} \\ T, \text{else} \end{cases} \quad (5)$$

式中, S_i 表示第 i 个路径点处的平滑代价; φ_i, θ_i 表示第 i 个路径点处的转弯角和爬升/下滑角; $\varphi_{\text{max}}, \theta_{\text{max}}$ 表示最大转弯角和最大爬升/下滑角。这种方式可以令解集中超过无人机飞行约束的路径解具有更高适应度,保证其在优化过程中向着路径平滑的方向迭代。

4) 总代价函数:

本文所用总代价函数是路径长度代价、威胁代价、平滑度代价的综合,通过为各代价配置不同的权重来调整其优先级,作为每个个体对应的适应度值参与迭代。其中威胁代价和平滑度代价使用常数 T 使劣质解对应很高的适应度值,保证算法会优先处理穿越危险区和存在急转角的路径,而后才对路径长度进行精细调整。构建如式 (6) 所示路径代价函数:

$$C = \alpha_1 C_1 + \alpha_2 C_2 + \alpha_3 C_3 \quad (6)$$

式中, $\alpha_1, \alpha_2, \alpha_3$ 表示各代价的权重。

2 改进哈里斯鹰优化算法

2.1 基本 HHO

自然界中哈里斯鹰利用探索、突袭和不同的攻击策

略实现对猎物的捕捉,哈里斯鹰优化算法是一种智能优化算法,模拟了哈里斯鹰的这一行为特征,并将捕食过程划分为2个阶段:探索阶段、开发阶段。HHO算法与其他算法相比的独特之处在于其多通路特性,HHO依赖两个重要的变量选择迭代方式,即猎物逃逸能量和猎物逃逸机会,这意味着整个种群可以根据迭代次数和种群状态自适应地调整其优化方式,对问题处理更具有针对性。同时迭代过程中的计算不需要提前设置常数,而是依靠随机数来实现,避免了更改使用环境导致的参数调整步骤,使得算法在应用场景上有更强的灵活性和迁移性。

1) 阶段选择:

HHO通过生成猎物逃逸能量来实现在探索和开发两种阶段之间的选择,猎物逃逸能量随迭代时间逐渐减小,用来模拟哈里斯鹰捕猎状态切换的过程。对于优化问题而言,可以表示其前期在探索阶段大范围探索可能的解,后期根据最优解位置不断提升解质量的过程。其更新方法如下:

$$E = 2E_0 \left(1 - \frac{t}{T}\right) \quad (7)$$

式中, E_0 表示猎物初始能量,是(0,1)内的随机数; t 表示当前迭代次数; T 表示总迭代次数。

2) 探索阶段:

当 $|E| \geq 1$,认为猎物具备充足的能量逃离抓捕,哈里斯鹰会对搜索空间进行大范围的探索,实现对猎物位置的初步侦测。算法进入探索阶段,采用机会对等策略,根据随机位置及自身位置,或根据最优位置及平均位置,完成探索行为,表达式如式(8)所示:

$$h_i(t+1) = \begin{cases} h_{\text{rand}}(t) - r_1 |h_{\text{rand}}(t) - 2r_2 h_i(t)|, q \geq 0.5 \\ [h_{\text{rabbitt}}(t) - h_m(t)] - r_3 [lb + r_4 (ub - lb)], q < 0.5 \end{cases} \quad (8)$$

式中, $h_i(t)$ 和 $h_i(t+1)$ 分别表示第 i 个个体在第 t 代和第 $t+1$ 代的位置; $h_{\text{rand}}(t)$ 表示第 t 代某个随机个体的位置; $h_{\text{rabbitt}}(t)$ 表示第 t 代最优个体的位置; $h_m(t)$ 表示第 t 代群体的平均位置; q 、 r_1 、 r_2 、 r_3 、 r_4 为(0,1)内的随机数; ub 、 lb 表示搜索空间的上界和下界。

3) 开发阶段:

当 $|E| < 1$,算法进入开发阶段,模拟哈里斯鹰试图抓住猎物,猎物尝试逃脱哈里斯鹰包围的过程。实际哈里斯鹰捕捉猎物的过程是复杂多变的,用(0,1)内的随机数 r 表示猎物逃脱可能性程度,结合逃逸能量 E 选择开发策略,包括软围攻、硬围攻、渐进式软围攻、渐进式硬围攻等4种策略。

软围攻策略:当 $0.5 \leq |E| \leq 1$ 且 $r \geq 0.5$ 时,认为猎物只有较小机会逃离包围,但仍有充足体力使用跳

跃的方式尝试逃离。哈里斯鹰选择慢慢消耗猎物体力,为突袭做准备,位置更新公式如下:

$$h(t+1) = \Delta h(t) - E |Jh_{\text{rabbitt}}(t) - h(t)| \quad (9)$$

$$\Delta h(t) = h_{\text{rabbitt}}(t) - h(t) \quad (10)$$

式中, J 表示猎物的跳跃能量,为(0,2)内的随机数; $\Delta h(t)$ 第 t 代最优个体与哈里斯鹰个体间的位置差值。

硬围攻策略:当 $|E| < 0.5$ 且 $r \geq 0.5$ 时,认为猎物只有很小机会逃离包围,且没有足够的体力进行更多尝试。哈里斯鹰选择快速捕捉猎物,位置更新公式如下:

$$h(t+1) = h_{\text{rabbitt}}(t) - E |\Delta h(t)| \quad (11)$$

渐进式围攻策略:当 $r < 0.5$ 时,认为猎物有较大机会逃离包围圈,此时哈里斯鹰选择利用莱维飞行进行俯冲式围攻,选取飞行过程中的最佳位置以防止猎物逃脱。位置更新公式如下:

$$h(t+1) = \begin{cases} Y, F(Y) < F(h(t)) \\ Z, F(Z) < F(h(t)) \end{cases} \quad (12)$$

$$Z = Y + S \times LF(d) \quad (13)$$

式中, Y 为不同围攻策略的位置更新方式; $F(\cdot)$ 为适应度函数; d 为待优化问题维度; S 为 d 维随机向量; $LF(d)$ 为莱维飞行函数:

$$LF(d) = 0.01 \times \frac{u \times \sigma}{|v|^{\frac{1}{\beta}}}, \sigma = \left[\frac{\Gamma(1+\beta) \times \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) \times \beta \times 2^{\frac{\beta-1}{2}}}\right]^{1/\beta} \quad (14)$$

式中, u 、 v 为(0,1)内随机数; β 默认值设置为1.5。

其中当 $0.5 \leq |E| \leq 1$ 时,采取渐进式软围攻策略,位置更新方式 Y 如下:

$$Y = h_{\text{rabbitt}}(t) - E |Jh_{\text{rabbitt}}(t) - h(t)| \quad (15)$$

其中当 $|E| < 0.5$ 时,采取渐进式硬围攻策略,位置更新方式 Y 如下:

$$Y = h_{\text{rabbitt}}(t) - E |Jh_{\text{rabbitt}}(t) - h_m(t)| \quad (16)$$

2.2 改进哈里斯鹰优化算法

2.2.1 势能波动学习策略

结合公式(7)和阶段选择的条件可知,哈里斯鹰优化算法在迭代过程中选择探索行为的概率是逐步变小的,且会在 $T/2$ 代时减少到0,对每一代选择探索行为的概率加权求和,可得到公式(17):

$$P_e = \frac{1}{T} \sum_{t=1}^T p_e(t) \approx \frac{1}{T} \int_0^{T/2} \left[1 - \frac{1}{2(1-t/T)}\right] dt \quad (17)$$

式中, P_e 表示算法选择探索行为的次数占总迭代次数的比例, $p_e(t)$ 表示第 t 代选择探索行为的概率。对公式(17)积分计算可得算法整体计算过程仅有约15.43%的次数选择探索行为,使用平均解和任选解向空间中大范围探索,其余时间均以当前最优解为中心向其靠拢。

由于HHO算法的全局探索行为集中在前期,导致

探索阶段所得解的质量会直接影响最终的收敛速度和精度^[19]，具有一定局限性。现有的改进方案通常是调整算法的逃逸能量生成规则^[20-21]，以减少开发次数为代价增加探索次数，但这种方法仅增加了进入探索阶段的次数，并不能保证在全局空间内对种群解质量的提升，同时还会减少进入开发阶段提高局部收敛精度的机会。本文针对这一问题设计势能波动学习策略，在探索行为后进一步搜索空间内的可行解，并结合贪婪策略保留下学习过程出现的更优质解，该方案能够增强算法在前期的全局扩展能力，并且避免直接修改逃逸能量生成规则，维持原算法中行为选择阶段的平衡。

哈里斯鹰进行大范围学习探索的过程类似于弹簧弹性势能波动的过程。哈里斯鹰个体 h 对应弹簧蓄满势能的状态，以路径点在起止点连线上的投影 h_p 表示零势能点，撤去外力后，弹簧会在零势能点附近往复运动，且随着能量损失，将逐渐收敛到零势能点附近。这种往复运动具备扫描空间的能力，且因能量衰减，幅值将逐渐趋近于某一值，符合群智能算法向最优解逼近的需求。在过程中选择一点作为探索学习的结果，个体 h^* 对应解的计算公式为：

$$h^* = h_p + e^{-\xi} (h_p - h) \sin\left(2\pi \frac{t}{T}\right) \quad (18)$$

式中， h_p 为 h 在起止点连线上的投影点，表示探索空间的原点； ξ 为衰减系数，表示探索空间的缩小程度。引入贪婪策略，对原位置和学习结果的适应度值进行比较，将较优解留存在哈里斯鹰群体中，增强探索行为的多样性，探索阶段得到的结果如式所示：

$$h(t+1)' = \begin{cases} h, F(h) \leq F(h^*) \\ h^*, F(h) > F(h^*) \end{cases} \quad (19)$$

式中， h 为公式 (8) 探索行为所得解 $h(t+1)$ ， h^* 为 h 利用公式 (18) 探索学习所得解 $h^*(t+1)$ 。

2.2.2 分工算子

进入开发阶段后，哈里斯鹰个体随机生成猎物逃逸机会进行策略选择，其中围攻策略依据最优解进行位置调整，渐进俯冲式围攻则是利用贪婪策略抛弃迭代过程的劣质解，保证自身解的质量。由公式 (9) ~ (16) 可知，开发阶段中种群个体以不同的方式向当前最优个体附近靠拢，以寻找理想的全局最优个体，其依据随机猎物逃逸机会进行的策略选择如图 3 所示，种群中的个体以随机概率选择执行的策略。

如图 3 所示，在开发阶段的不同策略中，围攻策略倾向于根据当前最优个体位置进行粗调，让个体靠近最优个体的同时保持差异化，但对于个体“2”而言，其原有位置已经离理想最优个体较近（即具备优质解），而为了靠近当前最优个体，却破坏了其解的质量。渐进式围攻策略则通过设置贪婪策略和补偿计算，保证个体




图 3 基于随机逃逸机会的策略选择

能够更接近理想最优个体（即代价值逐渐减小），这是一种消耗计算性能换取最优性的方式，但对于个体“1”“4”而言，其原有位置本就远离理想最优位置，仅接近当前最优个体足够优化其解的质量，增加比较和计算步骤反而会造成资源的浪费。通过以上分析可知原有的随机生成方式存在盲目性，对于算法的收敛效率是存在影响的。

由于 HHO 算法里生成的猎物逃逸机会是随机的，对于后续策略选择存在盲目性，会影响种群的收敛效率，故本文设计分工算子，将种群分成优质子种群 G_{better} 和劣质子种群 G_{worse} ，结合子种群的优劣情况引导策略选择，避免选择不合适的策略导致冗余的搜索或对当前较优位置的破坏。将猎物逃逸机会计算公式设计为：

$$r_i = \frac{\text{rank}[h_i(t)]}{N} \quad (20)$$

式中， r_i 表示第 i 个个体对应的猎物逃逸机会； $\text{rank}(\cdot)$ 表示适应度升序排名； N 表示种群的个体总数。利用分工机制的引导，不同个体采用合适的策略。对于 $r \geq 0.5$ 的子种群 G_{worse} ，认为其分布在相距猎物较远的位置，因此需要利用围攻靠近猎物，为成功捕获提供位置优势。对于 $r < 0.5$ 的子种群 G_{better} ，认为已经足够接近猎物位置，故通过渐进俯冲式围攻，减小猎物欺骗性运动带来的影响，逐步优化自身位置。

2.2.3 精英时变莱维飞行

HHO 算法中的莱维飞行是基于更新得到的劣质解进行的，而劣质解已经远离理想最优解，这会导致莱维飞行补救效率较低，同时莱维飞行权重恒定不变，无法满足算法不同阶段对搜索多样性和收敛速度的不同需求，这在后期已经接近理想最优解时反而会增大失败的可能。Liu 等^[22]通过测试函数评估，得到在两种渐进式围攻策略中，俯冲失效后莱维飞行的有效率仅为 0.45% 和 0.03%，这也印证了本文的分析，证明对于渐进式俯冲策略的改进是非常必要的。

为了提升算法中渐进式围攻策略的收敛效率，设计精英时变莱维飞行进行改进，基于精英选择的思想，认

为俯冲失败使得原始位置被破坏, 已经远离猎物, 转而选择更优质的位置进行莱维随机游走, 提高对俯冲失败的补救成功率。将适应度值最优的解保留下来, 作为本次迭代的精英结果, 以提高种群质量, 加快收敛速度。并为莱维随机飞行设置时变权重, 个体精力在迭代过程中逐渐消耗, 随机游走的效果随着迭代不断变小。通过迭代次数控制权重变化, 平衡算法对前期跳出局部最优和后期提高收敛精度的需求, 式 (12) 和式 (13) 改进后的更新公式如下:

$$h(t+1) = \begin{cases} Y, F(Y) < F[h(t)] \\ Z', F(Z') < F[h(t)] \end{cases} \quad (21)$$

$$Z' = h(t) + \left(1 - \frac{t}{T} + \omega\right) \times S \times LF(d) \quad (22)$$

式中, ω 为非零常数, 避免莱维飞行在迭代后期几乎失效。引入精英时变莱维飞行的改进渐进式俯冲策略思路如下:

- 1) 计算俯冲所得位置 Y 对应的适应度 $F(Y)$;
- 2) 若原位置对应的 $F[h(t)] \geq F(Y)$, 表示俯冲成功, Y 作为当前个体的本次迭代结果;
- 3) 若原位置对应的 $F[h(t)] < F(Y)$, 则俯冲失败, 转而使用原位置进行精英时变莱维飞行, 得到位置 Z' ;
- 4) 若原位置对应的 $F[h(t)] \geq F(Z')$, 则精英时变莱维飞行成功, 保留新位置, 否则保留原位置等待下次迭代。

2.3 改进算法规划流程及步骤

应用本文提出的 DEHHO 算法解决无人机路径规划问题, 改进算法的具体实现流程如图 4 所示。

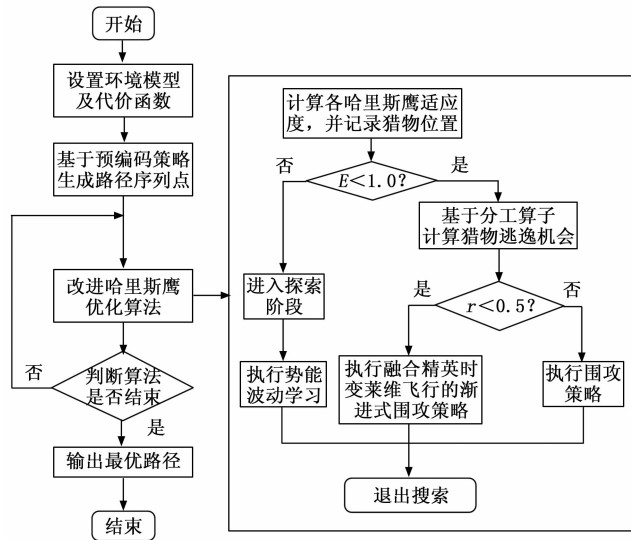


图 4 改进哈里斯鹰优化算法流程

行路径;

- 3) 计算个体适应度值, 选择最优个体作为猎物位置 h_{rabbit} ;
- 4) 根据式 (7) 生成猎物逃逸能量 E 并选择阶段, 若进入探索阶段跳到第 5) 步, 若进入开发阶段则跳到第 6) 步;
- 5) 根据式 (8) (18) (19) 更新种群位置, 跳到第 9) 步;
- 6) 根据式 (20) 区分当前种群, 较差个体跳到第 7) 步, 较优个体跳到第 8) 步;
- 7) 根据式 (9) (11) 通过围攻策略更新种群位置, 跳到第 9) 步;
- 8) 根据式 (21) (22) 通过渐进式围攻策略更新种群位置, 跳到第 9) 步;
- 9) 判断是否迭代结束, 若未结束则重复第 3) 步, 否则输出种群最优解。

3 仿真实验分析

仿真环境为 Win10、64 位操作系统, CPU 为 intel i5-8250U, 内存 8 GB, 主频 1.80 GHz, 仿真软件为 MATLAB2021b。为验证算法有效性, 将 DEHHO 算法与 GWO 算法、HHO 算法、IHHO (Improved HHO) 算法^[23]、引入分工算子的 DHHO 算法、融合势能波动学习和精英时变莱维飞行的 EHHO 算法进行对比。

仿真实验中威胁地形参数如表 1 所示, 障碍物参数如表 2 所示, 起始点为 (1, 20, 30), 目标点 (200, 160, 40), 设置算总迭代次数 200, 种群规模 30, 路径点数 12, 评价指标权重设置为 (1, 1, 1)。

表 1 威胁地形参数信息

中心点	山峰顶点高度/m	衰减系数 (X 轴)	衰减系数 (Y 轴)
(45,30)	55	20	20
(60,160)	50	15	15
(80,100)	70	30	30
(90,175)	60	20	20
(100,35)	30	20	20
(125,75)	40	15	15
(150,120)	70	30	30
(160,40)	70	20	20

表 2 障碍物参数信息

中心点	高度/m	半径/m
(50,130)	50	10
(105,140)	70	10
(110,90)	80	7
(130,30)	50	15
(170,65)	60	8

- 1) 确定环境障碍物、起始点、目标点信息;
- 2) 随机生成若干个路径点序列, 连接起始点和目标点, 该序列集表示初始化种群, 每个序列表示一条飞

如图 5 所示为各算法规划结果的三维视角对比图，图 6 为其俯视对比图，可见所有算法规划的路径都能避开环境威胁区，且各相邻路径点之间均没有较大转角，规划结果满足飞行安全要求，这表明智能优化算法能够解决路径规划问题，但在规划效果上存在较大差异。对比各算法的仿真结果，GWO 算法存在绕路和收敛效果差的情况，表明其在陷入局部最优问题上存在一定缺陷。相较于 HHO 算法，IHHO、DHHO、EHHO 具备一定改进效果，相比之下 DEHHO 算法的改进效果最为明显。图 7 为收敛曲线对比图，表明 DEHHO 不仅有最好的收敛精度，而且收敛速度上也有所提升。




图 5 三维视角对比图




图 6 俯视对比图




图 7 各算法航路适应度收敛曲线对比图

设置各算法单独规划实验 20 次，统计最优值、平均值、标准差如表 3 所示。可以看出，在本文仿真环境中解决路径规划问题时，DEHHO 算法在所有对比算法中表现最好，且相较于原始 HHO 算法，优化结果的适应度平均值降低了 7.42%，标准差减少了 84.93%，证明改进措施有效提升了算法的规划精度和稳定性，使其更适用于解算无人机路径规划问题。

表 3 各算法路径规划结果

算法	最优值	平均值	标准差
GWO	274.698 8	303.289 8	22.418 3
HHO	265.034 3	279.309 1	6.573 7
IHHO	263.109 8	269.757 8	5.109 9
DHHO	264.990 5	269.448 1	4.498 4
EHHO	260.879 4	267.064 1	3.672 2
DEHHO	257.763 4	258.582 8	0.990 3

图 8 引入箱线图对统计结果进行直观对比，结果显示，GWO 算法的规划效果较不稳定，且寻优精度有限，在解决本文路径规划问题时存在明显不足。IHHO 算法利用优势个体引导全局搜索，使算法搜索性能具备一定提升。DHHO 算法引入分工算子进行改进，EHHO 算法融合势能波动学习和精英时变莱维飞行进行改进，这两个改进算法相较于传统 HHO 算法，已经能够在中位值、四分位、边界值、箱型面积等指标上得到明显优化效果，证明本文所提子策略的有效性。DEHHO 将各改进策略融合，能够在对比算法中得到最低的中位值，表明在收敛效果上具备优越性。同时 DEHHO 的箱型面积更小，表明改进算法在多次计算过程中均能对最优解进行有效开发，且最终收敛到同一个值，证明本文方案在优化求解时的稳定性。综合来看本文提出的 DEHHO 算法在路径规划问题上有着优秀的寻优能力，能够帮助无人机在三维环境中高效地完成自主路径规划任务。




图 8 实验结果箱线图

4 结束语

本文研究了无人机路径规划问题，提出一种基于分

工的增强型哈里斯鹰优化算法。首先使用威胁等效地形和外接圆柱体模型描述飞行环境,在避免过渡消耗机载计算机资源的前提下,尽可能接近实际环境;其次,对HHO算法进行缺陷分析,设计势能波动学习策略,结合贪婪策略提高了算法前期的全局探索能力;然后,提出分工算子用于调整猎物逃逸机会,利用适应度划分种群,提高开发阶段策略选择的针对性,减少冗余计算;最后,设计精英时变莱维飞行,保证种群质量,并利用自适应步长的莱维飞行,提高了算法前期跳出局部最优的能力以及后期的收敛精度。仿真结果表明,本文所提出的各子策略能够提高算法的路径规划效果,且其组合改进能够得到适应度最优的结果。

参考文献:

- [1] RICARDO JR J A A, GIACOMOSSI JR L, TRENTIN J F S, et al. Cooperative threat engagement using drone swarms [J]. IEEE ACCESS, 2023, 11: 9529-9546.
- [2] LI C, HUANG X, DING J, et al. Global path planning based on a bidirectional alternating search A* algorithm for mobile robots [J]. Computers & Industrial Engineering, 2022, 168: 108123.
- [3] YANG F, FANG X, GAO F, et al. Obstacle avoidance path planning for UAV based on improved RRT algorithm [J]. Discrete Dynamics in Nature and Society, 2022 (2022): 1-9.
- [4] SRIVASTAVA A, VASUDEVAN V R, HARIKESH, et al. A modified artificial potential field for UAV collision avoidance [C] //2023 International Conference on Unmanned Aircraft Systems (ICUAS), Warsaw, Poland: IEEE, 2023: 499-506.
- [5] LIN C, ZHANG X, LIN C, et al. Application of UAV path planning based on parameter optimization GA-PSO fusion algorithm [J]. Journal of Physics: Conference Series, 2022, 2258 (1): 012018.
- [6] CAO Y, WEI W, BAI Y. Multi-base multi-UAV cooperative reconnaissance path planning with genetic algorithm [J]. Cluster Computing, 2019, 22: S5175-S5184.
- [7] 郭启程, 杜晓玉, 张延宇, 等. 基于改进鲸鱼算法的无人机三维路径规划 [J]. 计算机科学, 2021, 48 (12): 304-311.
- [8] 刘云平, 朱慧如, 方卫华. 改进灰狼算法的无人机路径规划 [J]. 电光与控制, 2023, 30 (7): 1-7.
- [9] SHAO S, PENG Y, HE C. Efficient path planning for UAV formation via comprehensively improved particle swarm optimization [J]. ISA TRANSACTIONS, 2020, 97: 415-430.
- [10] 陈侠, 毛海亮, 刘奎武. 基于改进自适应蚁群算法的无人机路径规划研究 [J]. 电光与控制, 2022, 29 (9): 6-10.
- [11] 卢颖, 庞黎晨, 陈雨思, 等. 一种面向城市战的无人机路径规划群智能算法 [J]. 兵工学报, 2023, 44 (s2): 146-156.
- [12] HEIDARI A AMORALLY S, FARIS H, et al. Harris hawks optimization: algorithm and applications [J]. Future Generation Computer Systems, 2019, 97: 849-872.
- [13] 李雨恒, 高尚, 孟祥宇. 基于精英引导的改进哈里斯鹰优化算法 [J]. 计算机工程与科学, 2024, 46 (2): 363-373.
- [14] YIYI C, ZHE S. Multi-strategy optimization of HHO algorithm for path planning of warehouse robots [J]. 2023 China Automation Congress (CAC), 2023: 735-40.
- [15] CAI C C, JIA C C, NIE Y, et al. A path planning method using modified harris hawks optimization algorithm for mobile robots [J]. Peerj Computer Science, 2023, 9: e1473.
- [16] HUSSINIEN A G, AMIN M. A self-adaptive Harris Hawks optimization algorithm with opposition-based learning and chaotic local search strategy for global optimization and feature selection [J]. International Journal of Machine Learning and Cybernetics, 2022, 13 (2): 309-36.
- [17] KAMBOJ V K, NANDI A, BHADORIA A, et al. An intensify harris hawks optimizer for numerical and engineering optimization problems [J]. Applied Soft Computing, 2020, 89: 106018.
- [18] 苏雯嘉, 高敏, 高欣宝, 等. 基于改进人工鱼群算法的无人机三维路径规划 [J]. 电光与控制, 2023, 30 (12): 59-65.
- [19] 黄志锋, 刘媛华, 任志豪, 等. 融合改进哈里斯鹰和改进动态窗口的机器人动态路径规划 [J]. 计算机应用研究, 2024, 41 (2): 450-458.
- [20] 胡啸, 张呈越, 卞炜, 等. 基于改进哈里斯鹰优化算法的动态路径规划研究 [J]. 控制工程, 2024, 31 (4): 591-600.
- [21] LEI X, CHEN J, CHEN X. Research on path planning of warehouse robot with improved harris hawks algorithm [J]. Journal of System Simulation, 2024, 36 (5): 1081-1092.
- [22] LIU X, LIANG T. Harris hawk optimization algorithm based on square neighborhood and random array [J]. Control and Decision, 2022, 37 (10): 2467-2476.
- [23] LIU C. An improved harris hawks optimizer for job-shop scheduling problem [J]. The Journal of Supercomputing, 2021, 77 (12): 14090-14129.