

基于改进河马算法的农业无人机路径规划

韩涛 李婷婷 黄友锐

(安徽理工大学电气与信息工程学院, 淮南 232001)

摘要: 针对传统农用车辆的运输方式存在效率低、成本高以及安全性差的问题,提出了一种用于农业无人机路径规划的改进河马算法(Dynamic modified hippopotamus optimization, DMHO)。该算法综合了Lévy飞行、成长比例机制、自适应学习率的棱镜对立学习算法及随机扩散的优势,提升算法的全局搜索及探索能力。算法在23个经典基准函数的测试结果表明,与原始河马算法等8种算法相比,DMHO在21个函数上展现出最优性能。构建丘陵种植区域无人机飞行环境的三维地形,搭建农业无人机在此环境下的路径规划模型,设计满足多条件约束的代价函数。在3种不同复杂程度的飞行任务中,DMHO找寻的平均适应度最短,相较于原始河马算法标准差分别降低33.39%、72.81%和7.08%,表现出显著的优越性和稳定性。

关键词: 农业无人机; 路径规划; 河马算法

中图分类号: TP249

文献标识码: A

文章编号: 1000-1298(2026)01-0339-09

OSID:



Agricultural UAV Path Planning Based on Improved Hippopotamus Optimization Algorithm

HAN Tao LI Tingting HUANG Yourui

(College of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, China)

Abstract: Aiming to address the inefficiency, high cost, and poor safety of traditional agricultural vehicle-based transport, a dynamic modified hippopotamus optimization (DMHO) was proposed for agricultural UAV path planning. The algorithm synthesized the advantages of Lévy flight, growth ratio mechanism, lens opposition-based learning (LOBL) algorithm with adaptive learning rate and stochastic diffusion to comprehensively improve the algorithm's global search and exploration capabilities. Based on the test results of the algorithm on 23 classical benchmark functions, it was shown that dynamic modified hippopotamus optimization exhibited optimal performance on 21 of these functions and had the best optimization searching effect compared with eight algorithms such as the original hippopotamus optimization algorithm. The three-dimensional terrain of the unmanned aerial vehicle flight environment in the hilly planting area was constructed, the trajectory planning model of the agricultural unmanned aerial vehicle in this environment was built, and the trajectory planning cost function was designed to satisfy the multi-conditional constraints. In the three different complexity tasks, dynamic modified hippopotamus optimization had the lowest average fitness result among all the compared algorithms, and the standard deviation in the test results was decreased by 33.39%, 72.81% and 7.08%, respectively, in comparison with hippopotamus optimization algorithm. The dynamic modified hippopotamus optimization algorithm demonstrated remarkable superiority and stability in experimental evaluations.

Key words: agricultural UAV; path planning; hippopotamus optimization algorithm

0 引言

面对丘陵地带的复杂地形,传统农用车辆的农

与农产品运输方式,不仅效率低、成本高,更存在极大的人力安全风险。无人机能够在各类复杂环境中灵活适应并快速响应各类紧急情况^[1],且无需载人操

作。这些优势使无人机在搜索巡逻^[2]、抢险救灾^[3]等特殊任务,以及物流配送^[4]、电力巡检^[5]、农业气象^[6]等领域均得到广泛应用。然而,无人机路径规划尚存在操作性差和成本高的问题,需要合理规划以提升避障性能,有效缩短飞行时间和距离^[7]。

无人机路径规划算法主要分为经典算法和元启发式算法。经典算法在搜索空间的维度呈指数级增长时缺乏竞争力。元启发式算法在飞行任务中可以优化飞行成本函数适应度^[8],但是元启发式算法在无人机路径规划中普遍存在计算效率低、参数设置复杂的问题,且容易陷入局部最优解,导致无法找到全局最优路径。

AMIRI 等^[9]于 2024 年提出了河马优化算法(Hippopotamus optimization,HO),具有收敛速度快、求解精度高、鲁棒性强和适应性广等优点。CHEN 等^[10]为了解决变分模态分解算法的局限性,利用河马优化算法卓越的优化性能对变分模态分解算法进行改进,实现了信号初步去噪处理,为后续电力系统宽带振荡分析提供了理论指导和技术支持。文献[11]提出了一个基于河马算法的优化框架,通过集成电动汽车充电站、光伏系统和配电静态补偿器,显著提高了电网性能,减少了电能损耗,并具有经济上的长期收益。文献[12]将深度学习网络与 HO 算法结合用于手语识别,模型准确度为 98.7%。

本文以农业无人机为切入点,提出面向丘陵的农业无人机路径规划算法,寻求两点之间满足要求的最短路径。针对农业无人机在丘陵地带的复杂地形下物资运输的安全路径规划问题,搭建无人机路径规划,并设计融合多重约束条件的代价函数。针对 HO 算法容易陷入局部最优、稳定性差的不足,进行改进和优化,提出 DMHO 算法,使用 Lévy 飞行改进种群初始化,并引入成长比例机制、自适应学习率的棱镜对立学习算法和随机扩散。以期为丘陵区域的物资运输问题提供有效的解决方案,提高路径计算效率和安全保障。

1 算法设计

1.1 Lévy 飞行初始化种群

本文用 Lévy 飞行^[13]代替原始 HO 算法初始化种群的方式,增加种群的多样性和全局搜索能力,帮助算法避免陷入局部最优解,从而提高优化算法的鲁棒性和性能。假设搜索空间为 $[l_b,u_b]^d$,则第 i 个个体的初始位置 X_i 可表示为

$$X_i = l_b + L(\lambda)(u_b - l_b)$$

(1)

式中 $L(\lambda)$ ——莱维步长,用于在解空间内生成具有长跳跃特性的初始解

1.2 成长比例机制

河马算法中,大多数未成熟的河马都在母亲身边,但由于好奇,有时未成熟的河马会与种群分离或远离母亲。如果 T 大于 0.6,这意味着未成熟的河马已经与母亲拉开了距离,计算式为

$$T = \exp\left(-\frac{i_c}{i_{\max}}\right)$$

(2)

式中 T ——选择概率参数
 i_c ——当前迭代次数
 $i_{\max}$ ——最大迭代次数

本文将未成熟的河马与母亲拉开距离的事件条件重新建模,改成不固定的比例

$$T = \frac{f_b}{f_i}$$

(3)

式中 f_b ——当前最优适应度
 f_i ——当前适应度

如果未成熟的河马的适应度高,则可以与母亲拉开距离。这种成长比例机制更容易寻求到更好的解。

河马算法定义了 5 种场景,表示为

$$\begin{cases} h_1 = I_2 r_1 + (\sim q_1) \\ h_2 = 2r_2 - 1 \\ h_3 = r_3 \\ h_4 = I_1 r_4 + (\sim q_2) \\ h_5 = r_5 \end{cases}$$

(4)

式中 $h_1 \sim h_5$ ——用于位置更新的随机向量或标量
 I_1, I_2 ——随机整数,取 1 或 2
 $r_1 \sim r_4$ ——在 $[0,1]$ 范围内均匀分布的随机向量
 r_5 ——在 $[0,1]$ 范围内均匀分布的随机标量
 q_1, q_2 ——随机整数,取 0 或 1
 $\sim q_1, \sim q_2$ ——对 q_1, q_2 取逻辑非
对未成熟和雌性河马的行为进行建模

$$X_i^{FB} : x_{ij}^{FB} = \begin{cases} x_{ij} + h_1(D_h - I_2 M_{Gi}) & (T > 1) \\ H_0 & (T \leq 1) \end{cases}$$

(5)

$$H_0 = \begin{cases} x_{ij} + h_2(M_{Gi} - D_h) & (r_6 > 0.5) \\ l_{bj} + r_7(u_{bj} - l_{bj}) & (r_6 = 0.5) \end{cases}$$

(6)

式中 X_i^{FB} ——第 i 个雌性或未成熟河马更新后的新位置向量
 x_{ij}^{FB} ——雌性和未成熟河马在算法一次迭代后的新位置
 x_{ij} ——第 i 个河马在第 j 维上的当前位置坐标
 D_h ——当前种群中最优个体的位置

M_{Gi} ——从种群中随机选取若干河马位置的
平均值
 $r_6、r_7$ —— $[0,1]$ 区间内均匀分布的随机数
 $u_{bj}、l_{bj}$ ——第 j 维决策变量的上界和下界
 N ——种群中河马的总数
 m ——决策变量的维度数

当 r_6 大于 0.5 时,意味着未成熟的河马已经与
母亲保持距离,但仍在种群内或附近。否则,它已经
与种群分离。

种群内雄性和雌性或未成熟河马的位置更新表
示为

$$X_i = \begin{cases} X_i^M & (F_i^M < F_i) \\ X_i^{FB} & (F_i^{FB} < F_i) \\ X_i & (\text{其他}) \end{cases} \quad (7)$$

式中 X_i ——第 i 个个体当前位置向量
 X_i^M ——雄性河马候选新位置向量
 F_i ——目标函数值
 F_i^M ——雄性河马的目标函数值
 F_i^{FB} ——雌性或未成熟河马的目标函数值

1.3 自适应学习率的棱镜对立学习算法

在原始 HO 算法的开发阶段加入自适应学习率
的棱镜对立学习算法 (Lens opposition-based
learning, LOBL) [14],旨在增强多目标优化问题的搜
索效率。

借鉴光学成像原理,如图 1 所示,区间的中点为
透镜。假设有一个高度为 H 的物体,通过透镜成像
的数学关系可表示为

$$\frac{0.5(l_b + u_b) - x}{x^* - 0.5(l_b + u_b)} = \frac{H}{H^*} \quad (8)$$

式中 x ——物体所在位置横坐标
 x^* ——物体成像所在位置横坐标
 H ——物体高度
 H^* ——物体成像高度




图 1 LOBL 示意图

Fig. 1 Schematic of LOBL

设 $f = H/H^*$,式(8)可以简化为

$$x^* = \frac{l_b + u_b}{2} + \frac{l_b + u_b}{2f} - \frac{x}{f} \quad (9)$$

参数 f 是一个随迭代次数增加而动态变化的系
数,其增长速率由 $(i_c/i_{\max})^{1/2}$ 控制,并以 10 的幂次放
大,计算式为

$$f = [1 + (i_c/i_{\max})^{1/2}]^{10} \quad (10)$$

新位置 $P_o(t)$ 可以表示为

$$P_o(t) = \frac{l_b + u_b}{2} + \frac{l_b + u_b}{2f} - \frac{P_c(t)}{f} \quad (11)$$

式中 P_c ——当前个体的位置

P_o ——相反点的位置

将此更新方法应用于河马优化的开发阶段,有
效增强其全局搜索能力。

本文将 f 值的选取与随机数 r 结合,计算式为

$$f = 3r - 3 \quad (12)$$

自适应学习率的小孔成像反向学习策略,能够
动态调整搜索步长,提高模型的训练效果和泛化能
力,最终实现在复杂优化问题中搜索更有效和发现
全局最优解。

1.4 随机扩散

在河马遇到一群捕食者或无法击退单个捕食者
时,则会尝试逃离该区域。本文使用随机扩散来模
拟这一行为,个体扩散步长 s 计算式为

$$s = 0.1R(1,d)(u_b - l_b) \quad (13)$$

式中 d ——问题维度

$R(1,d)$ 生成一个与问题维度相同长度的随机
数向量,每个元素的值在 0 到 1 之间。这个随机数
向量乘以扩散因子 0.1 和搜索空间的范围 $(u_b \sim l_b)$
来确定步长。

个体的新位置 $X(i+1,:)$ 通过在当前位置
 $X(i,:)$ 加上步长 s 得到,即

$$X(i+1,:) = X(i,:) + s \quad (14)$$

随机扩散的引入增加了算法的探索能力,有助
于避免局部最优解,提高算法的全局搜索能力。

2 实验

2.1 实验设置及评价标准

实验仿真平台环境配置为 Windows 10 系统,模
型搭载 Intel(R) Core(TM) i5-12490F 3.0 GHz 中央
处理器,编程环境为 Matlab R2021b。

本文在 CEC2005 测试函数上进行算法性能验
证,如表 1 所示。同时为了保证实验的公平性和有
效性,消除随机性对测试结果的影响,所有算法在每
个基准函数上独立运行 50 轮。并将平均值、标准偏
差以及秩作为算法性能评价指标。

2.2 性能测试

在对比实验中,本文选择近几年常用于路径规
划的群智能优化算法:蜣螂优化算法 (Dung beetle
optimizer, DBO) [15]、火鹰优化算法 (Fire hawk
optimizer, FHO) [16]、蜜獾算法 (Honey badger

表 1 测试函数
Tab.1 Test functions

测试函数	维度	取值范围	理论最小值
$f_1(x)=\sum_{i=1}^nx_i^2$	30	[−100,100]	0
$f_2(x)=\sum_{i=1}^n x_i +\prod_{i=1}^n x_i $	30	[−10,10]	0
$f_3(x)=\sum_{i=0}^{n-1}\left(\sum_{j=0}^{j<i}x_i\right)^2$	30	[−100,100]	0
$f_4(x)=\max_i\{ x_i ,1\leqslant i\leqslant n\}$	30	[−100,100]	0
$f_5(x)=\sum_{i=1}^{n-1}[100(x_{i+1}-x_i^2)^2+(x_i-1)^2]$	30	[−30,30]	0
$f_6(x)=\sum_{i=1}^n\lfloor x_i+0.5\rfloor^2$	30	[−100,100]	0
$f_7(x)=\sum_{i=1}^nix_i^4+R[0,1)$	30	[−1.28,1.28]	0
$f_8(x)=\sum_{i=1}^n-x_i\sin(\sqrt{ x_i })$	30	[−500,500]	−12 569.4
$f_9(x)=\sum_{i=1}^n(x_i^2-10\cos(2\pi x_i)+10)$	30	[−5.12,5.12]	0
$f_{10}(x)=-20\exp\left(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^nx_i^2}\right)-\exp\left(\frac{1}{n}\sum_{i=1}^n\cos(2\pi x_i)\right)+20+e$	30	[−32,32]	0
$f_{11}=(1/4\ 000)\sum_{i=1}^nx_i^2-\prod_{i=1}^n\cos(x_i/\sqrt{x+1})+1$	30	[−600,600]	0
$f_{12}(x)=(\pi/n)\left\{10\sin^2(\pi y_1)+(y_n-1)^2+\sum_{i=1}^{n-1}(y_i-1)^2[1+10\sin^2(\pi y_{i+1})]\right\}+\sum_{i=1}^nu(x_i,10,100,4)$	30	[−50,50]	0
其中 $y_i=1+(x_i+1)/4$ $u(x_i,a,k,m)=\begin{cases}k(x_i-a)^m & (x_i>a) \\ 0 & (-a<x_i<a) \\ k(-x_i-a)^m & (x_i<-a)\end{cases}$			
$f_{13}(x)=0.1\left\{\sum_{i=1}^n(x_i-1)^2[1+\sin^2(3\pi x_1+1)]\cdot\sin^2(3\pi x_1)+(x_n-1)^2[1+\sin^2(2\pi x_{ni})]\right\}+\sum_{i=1}^nu(x_i,5,100,4)$	30	[−50,50]	0
$f_{14}(x)=\left[1/500+\sum_{j=1}^{25}1/\left(j+\sum_{i=1}^2(x_i-a_{ij})^6\right)\right]^{-1}$	2	[−65,65]	1
$f_{15}(x)=\sum_{i=1}^{11}[a_i-x_1(b_i^2+b_ix_2)/(b_i^2+b_ix_3+x_4)]^2$	4	[−5,5]	0.000 030 75
$f_{16}(x)=4x_1^2-2.1x_1^4+x_1^6/3+x_1x_2-4x_2^2+4x_2^4$	2	[−5,5]	−1.031 628 5
$f_{17}(x)=\left(x_2-\frac{5.1x^2}{4\pi^2}+\frac{5x_1}{\pi}-6\right)^2+10\left(1-\frac{1}{8\pi}\right)\cos x_1+10$	2	[−5,5]	0.398
$f_{18}(x)=[1+(x_1+x_2+1)^2(19-14x_1+3x_1^2-14x_2+6x_1x_2+3x_2^2)]\cdot[30+(2x_1-3x_2)^2(18-32x_1+12x_1^2+48x_2-36x_1x_2+27x_2^2)]$	2	[−2,2]	3
$f_{19}(x)=-\sum_{i=1}^4c_i\exp\left(-\sum_{j=1}^3a_{ij}(x_j-p_{ij})^2\right)$	3	[0,1]	−3.86
$f_{20}(x)=-\sum_{i=1}^4c_i\exp\left(-\sum_{j=1}^6a_{ij}(x_j-p_{ij})^2\right)$	6	[0,1]	−3.32
$f_{21}(\boldsymbol{x})=-\sum_{i=1}^5[(\boldsymbol{x}-\boldsymbol{a}_i)(\boldsymbol{x}-\boldsymbol{a}_i)^T+c_i]^{-1}$	4	[0,10]	−10
$f_{22}(\boldsymbol{x})=-\sum_{i=1}^7[(\boldsymbol{x}-\boldsymbol{a}_i)(\boldsymbol{x}-\boldsymbol{a}_i)^T+c_i]^{-1}$	4	[0,10]	−10
$f_{23}(\boldsymbol{x})=-\sum_{i=1}^{10}[(\boldsymbol{x}-\boldsymbol{a}_i)(\boldsymbol{x}-\boldsymbol{a}_i)^T+c_i]^{-1}$	4	[0,10]	−10

algorithm HBA)^[17]、哈里斯鹰优化算法 (Harris hawks optimization, HHO)^[18],还包括被广泛认可的粒子群优化器 (Particle swarm optimization, PSO)^[19]、灰狼优化算法 (Grey wolf optimizer, GWO)^[20],同时选取了基于物理现象的引力搜索算法 (GSA)^[21] 以及原始 HO 算法与本文提出的 DMHO 算法对 CEC2005 的 23 个测试函数进行实验并比较。在评估优化算法性能的过程中,采取统一的环境设置以确保公平性和可靠性。种群大小统一设定为 30,最大迭代次数为 500 次,确保各算法在相同的条件下进行比较。9 种算法在部分测试函数中循环 50 轮的实验结果如表 2 所示。在 7 个单

峰基准函数上,DMHO 算法寻优结果的平均值及标准差在所有比较算法中均为最小。 $f_8 \sim f_{13}$ 为多模态函数,在 f_8 、 f_9 、 f_{11} 、 f_{13} 上,DMHO 算法均能获得最高的精度,且在 f_9 、 f_{11} 上具有最低标准差。在 f_8 、 f_{13} 上,DMHO 算法的标准差略高于 GSA 算法。在 f_{10} 上,FHO、GSA、HHO、HO 均能寻找到最优值,DMHO 仅次于这些算法。在 f_{12} 上,GSA 能够寻找到平均精度最高的解,HHO 具有最小的标准差,DMHO 的精度及标准差在所有算法中均居于第 3 位。在 $f_{14} \sim f_{23}$ 这类固定维度的基准函数中,DMHO 在所有对比算法上均能获得最高的精度。在 f_{14} 上,HO 算法及 DMHO 算法的标准差小于其他算法。在 $f_{16} \sim f_{18}$ 上

表 2 9 种算法在部分测试函数中循环 50 轮的实验结果

Tab.2 Experimental results of DMHO and eight comparison algorithms under 50 cycles of 23 partial test functions							
函数	算法	平均值	标准差	函数	算法	平均值	标准差
f_1	DBO	$9.373\ 1 \times 10^{-111}$	$6.171\ 3 \times 10^{110}$	f_{13}	DBO	0.549 32	0.523 50
	FHO	$6.478\ 6 \times 10^{-73}$	$4.519\ 2 \times 10^{-72}$		FHO	$1.086\ 2 \times 10^{-2}$	$5.087\ 1 \times 10^{-3}$
	GSA	$1.447\ 5 \times 10^{-233}$	0		GSA	$6.561\ 7 \times 10^{-5}$	$1.055\ 0 \times 10^{-4}$
	GWO	$1.492\ 8 \times 10^{-27}$	$2.281\ 7 \times 10^{-27}$		GWO	0.594 33	0.233 35
	HBA	$8.627\ 1 \times 10^{-134}$	$5.151\ 5 \times 10^{-133}$		HBA	0.405 47	0.272 92
	HHO	$3.148\ 6 \times 10^{-96}$	$1.531\ 1 \times 10^{-95}$		HHO	$1.239\ 5 \times 10^{-4}$	$1.733\ 2 \times 10^{-4}$
	PSO	2.300 9	1.036 2		PSO	0.615 41	0.266 94
	HO	0	0		HO	$2.894\ 8 \times 10^{-3}$	$9.482\ 1 \times 10^{-3}$
	DMHO	0	0		DMHO	$6.513\ 3 \times 10^{-5}$	$1.702\ 2 \times 10^{-4}$
f_6	DBO	0	0	f_{18}	DBO	3.000 0	$2.567\ 6 \times 10^{-15}$
	FHO	0	0		FHO	3.003 0	$3.116\ 7 \times 10^{-3}$
	GSA	0	0		GSA	8.078 4	10.833
	GWO	0	0		GWO	3.000 0	$5.940\ 3 \times 10^{-5}$
	HBA	0	0		HBA	4.620 0	11.455
	HHO	0	0		HHO	3.000 0	$1.516\ 2 \times 10^{-6}$
	PSO	5.480 0	3.065 5		PSO	3.000 0	$4.580\ 1 \times 10^{-15}$
	HO	0	0		HO	3.000 0	$2.145\ 5 \times 10^{-9}$
	DMHO	0	0		DMHO	3.000 0	$6.498\ 9 \times 10^{-10}$
f_9	DBO	1.174 1	5.880 1	f_{21}	DBO	-7.614 2	2.560 3
	FHO	0	0		FHO	-8.199 0	1.939 4
	GSA	0	0		GSA	-10.149	$1.026\ 3 \times 10^{-2}$
	GWO	3.552 0	5.006 7		GWO	-9.645 3	1.533 5
	HBA	0	0		HBA	-9.701 8	1.804 7
	HHO	0	0		HHO	-5.571 6	1.610 4
	PSO	$1.748\ 2 \times 10^2$	33.431		PSO	-7.392 4	3.248 2
	HO	0	0		HO	-10.153	$4.310\ 2 \times 10^{-6}$
	DMHO	0	0		DMHO	-10.153	$1.655\ 0 \times 10^{-6}$
f_{11}	DBO	0	0	f_{23}	DBO	-8.301 4	3.051 9
	FHO	0	0		FHO	-9.373 8	0.545 59
	GSA	0	0		GSA	-10.535	$3.028\ 2 \times 10^{-3}$
	GWO	$2.793\ 7 \times 10^{-3}$	$5.868\ 9 \times 10^{-3}$		GWO	-10.373	1.147 4
	HBA	0	0		HBA	-8.781 7	3.169 3
	HHO	0	0		HHO	-5.249 8	1.401
	PSO	0.112 82	$4.438\ 2 \times 10^{-2}$		PSO	-9.072 1	2.667 8
	HO	0	0		HO	-10.536	$2.152\ 5 \times 10^{-6}$
	DMHO	0	0		DMHO	-10.536	$9.917\ 2 \times 10^{-7}$

DMHO 未获得最佳表现,但其标准差在 HO 的基础上显著提升。在 f_{19} 上,PSO 具有最好的稳定性,DMHO 稳定性略低于 PSO 和 HO。在 23 个基准函数中,DMHO 在除 f_{10} f_{12} 之外的 21 个函数上均能获得最高精度,中标率为 91.3%。同时,此算法仅在 9 个函数中未获得最高稳定性,远超其他算法。实验结果表明,DMHO 具有更好的稳定性、更强的跳出

局部最优的能力。

2.3 Friedman 测试结果

将 9 种算法在测试结果的平均值和标准差之和按从小到大的顺序进行排序。当排名存在并列情况时,则给予平均排名。通过 Friedman 检验,为 9 种优化算法的性能比较提供了一个公平可靠的统计依据,具体的排名如表 3 所示。

表 3 9 种算法在 23 个基准函数中的 Friedman 检验结果

Tab.3 Friedman test results for nine algorithms in 23 benchmark functions

函数	DBO	FHO	GSA	GWO	HBA	HHO	PSO	HO	DMHO
f_1	5	7	3	8	4	6	9	1.5	1.5
f_2	5	7	3	8	4	6	9	2	1
f_3	7	6	3	8	4	5	9	1.5	1.5
f_4	5	7	3	8	4	6	9	2	1
f_5	7	5	2	8	6	3	9	4	1
f_6	4.5	4.5	4.5	4.5	4.5	4.5	9	4.5	4.5
f_7	7	6	2	8	5	4	9	3	1
f_8	7	2.5	2.5	8	6	5	9	2.5	2.5
f_9	7	3.5	3.5	8	3.5	3.5	9	3.5	3.5
f_{10}	6	2.5	2.5	7	9	2.5	8	2.5	5
f_{11}	4	4	4	8	4	4	9	4	4
f_{12}	5	7	1	8	6	2	9	4	3
f_{13}	9	5	1	7	6	3	8	4	2
f_{14}	4	6	3	9	8	5	7	1.5	1.5
f_{15}	6	7	3	9	8	4	5	2	1
f_{16}	4.5	4.5	9	4.5	4.5	4.5	4.5	4.5	4.5
f_{17}	3	8	9	7	3	6	3	3	3
f_{18}	3	7	9	6	8	3	3	3	3
f_{19}	6	7	9	4	8	5	2	2	2
f_{20}	6	7	9	5	4	8	3	2	1
f_{21}	7	6	3	4	5	9	8	2	1
f_{22}	8	5	3	4	7	9	6	2	1
f_{23}	8	5	3	4	7	9	6	2	1
秩和排名	134	129.5	95	155	128.5	117	162.5	63	50.5
平均排名	5.826 1	5.630 4	4.130 4	6.739 1	5.587 0	5.087 0	7.065 2	2.739 1	2.195 6
总排名	7	5	3	8	6	4	9	2	1

从表 3 数据来看,DMHO 在 Friedman 测试的数据平均秩和排名为 2.195 6,总排名居于第 1 位。这一结果表明,9 种比较算法在 23 个基准函数测试上,DMHO 算法展现出高效的全局搜索能力和较强的局部开采能力。Friedman 检验的统计分析结果证实了 DMHO 在解决优化问题方面的优势。

3 无人机路径规划

由于无人机路径规划是一个复杂的多目标优化问题,可以视为在三维空间中寻找一条满足多种约束条件的最优路径。将 DMHO 在 3 种不同障碍密度的仿真环境中测试,验证算法性能。

3.1 环境建模

为验证所提 DMHO 算法在无人机路径规划中

的有效性,本文在仿真环境下对其有效性进行验证。无人机最低飞行高度 $H_{\min}$ 为 20 m,飞行速度设置为 20 m/s,最大转弯角 ϕ 为 60° ,最大爬升角与最大俯冲角 θ 均为 30° ,最大路径长度 $L_{\max}$ 设置为 600 m。本文设置了 3 种仿真环境,无人机飞行区域均为长 200 m、宽 200 m、高 100 m 的三维空间。3 种飞行环境障碍参数如表 4 所示。其中,环境 1 代表山峰较少的区域,类似中等复杂度的丘陵地形,环境 2 类似于高复杂度丘陵地形,环境 3 类似丘陵与高原过渡地形。3 种地形从简单到复杂,广泛地涵盖了复杂多样的地形,如图 2 所示。

3.2 约束函数与代价函数

最低飞行高度 $H_{\min}$ 是指无人机在执行任务时必须遵守的最小离地高度限制。飞行高度必须大于允

表 4 3 种飞行环境障碍参数

Tab.4 Three flight environment obstacle parameters

飞行区域	起点、终点坐标/m	山峰坐标/m	高度/m	山峰 x 方向坡度/(°)	山峰 y 方向坡度/(°)
环境 1	(0,0,20) (200,200,40)	(30,120)	50	20	20
		(160,60)	30	35	30
		(180,150)	80	15	15
		(120,170)	60	10	40
环境 2	(0,0,20) (200,200,40)	(180,170)	40	20	20
		(120,30)	80	35	18
		(100,90)	30	15	30
		(30,90)	20	60	45
		(80,180)	45	30	50
		(160,10)	50	30	40
环境 3	(0,200,20) (200,0,20)	(40,100)	40	15	15
		(50,160)	35	20	15
		(90,50)	20	20	10
		(180,50)	22	5	10
		(120,70)	20	12	35
		(170,130)	30	20	15
		(160,180)	20	30	20
		(60,190)	25	25	20




图 2 3 种环境的三维建模及其俯视图

Fig.2 3D modeling of three environments and their top views

许的最低飞行高度。设在某一飞行航段的最小离地高度为 H_i ,则该约束为

$$H_i \geq H_{\min} \quad (i = 1, 2, \cdots, n) \tag{15}$$

最小路径段长度 $L_{\min}$ 是指无人机在开始改变飞行姿态前必须保持直飞的最短距离。设路径 $\{l_i | i = 1, 2, \cdots, n\}$ 由 n 个路径段 l_i 组成,则每个路径段长度 l_i 要比最小路径段长度 $L_{\min}$ 大,表示为

$$l_i \geq L_{\min} \tag{16}$$

最大转弯角 ϕ 是指无人机在水平面内转弯时,其转弯角度不能超过的一个预先设定的最大值。这个约束条件确保无人机在转弯时不会因为转弯过快而导致失速或翻滚,从而保障飞行安全。设路径段 $\parallel l_i \parallel$ 在水平方向上的投影为

$$\boldsymbol{a}_i = (x_i - x_{i-1}, y_i - y_{i-1})^T \tag{17}$$

式中 (x_i, y_i) ——水平方向上的坐标

则最大转弯角 ϕ 约束可表示为

$$\frac{\boldsymbol{a}_i^T \boldsymbol{a}_{i+1}}{\parallel \boldsymbol{a}_i \parallel \parallel \boldsymbol{a}_{i+1} \parallel} \geq \cos \phi \quad (i = 2, 3, \cdots, n - 1) \tag{18}$$

式中 $\parallel \boldsymbol{a}_i \parallel$ —— $\boldsymbol{a}_i$ 的模长,即 (x_{i-1}, y_{i-1}) 到 (x_i, y_i) 的欧氏距离

最大爬升角和最大俯冲角是无人机在垂直平面内进行爬升或下滑时的角度限制。假设允许的最大爬升/俯冲角为 θ ,该约束条件可表示为

$$\frac{|z_i - z_{i-1}|}{|\boldsymbol{a}_i|} \leq \tan \theta \quad (i = 2, 3, \cdots, n) \tag{19}$$

式中 z_{i-1} ——第 $i - 1$ 段路径的起点高度

z_i ——第 i 段路径的终点高度

最大路径长度 $L_{\max}$ 是指无人机规划路径的总长度不能超过的一个预先设定的距离。这个距离通常

由无人机所携带的燃料量以及指定任务中到达目标的允许飞行时间决定。该约束可表示为

$$\sum_i^n \|l_i\| \leqslant L_{\max}$$

(20)

式中 $\|l_i\|$ —— l_i 的模,路径起点和终点的欧氏距离

无人机路径规划中,路径评价通常考虑多个约束条件,如无人机的机动性能、离地高度、威胁区域和路径长度等。路径代价函数 C 可表示为

$$C = \sum_i^n (\omega_1 l_i^2 + \omega_2 h_i^2 + \omega_3 g_i)$$

(21)

式中 h_i ——第 i 段路径中无人机离地高度
 g_i ——第 i 段路径中的威胁指数
 $\omega_1, \omega_2, \omega_3$ ——权重系数




图 3 9 种算法在 3 种障碍地图中的最优飞行路径

Fig. 3 Optimal flight paths for nine algorithms in three obstacle maps




图 4 9 种算法在 3 种障碍地图中的平均适应度收敛曲线

Fig. 4 Average fitness convergence curves for nine algorithms in three obstacle maps

表 5 9 个算法在 3 个障碍地图中适应度的平均值与标准差

Tab.5 Mean and standard deviation of nine algorithms in three obstacle maps

算法	环境 1 的适应度		环境 2 的适应度		环境 3 的适应度	
	平均值	标准差	平均值	标准差	平均值	标准差
DBO	288.855	7.763	284.814	1.977	124.246	6.378
FHO	288.799	6.508	286.020	1.686	139.515	4.950
GSA	305.583	21.611	313.297	31.886	152.549	10.687
GWO	285.906	5.130	284.761	0.679	124.099	4.786
HBA	285.616	3.507	283.383	0.786	125.148	8.199
HHO	302.325	19.404	303.306	31.875	168.833	129.740
PSO	285.004	3.511	283.991	1.392	157.892	82.644
HO	284.114	2.099	284.239	1.263	122.674	7.226
DMHO	283.803	1.398	282.844	0.343	122.603	6.714

图 3 为 9 种算法在不同障碍个数下的飞行路径的可视化结果。在环境 1 和环境 2 中所有算法都经过相似路径,但在环境 3 中,FHO 和 GSA 与其他算法路径选择相差较大。

权重系数满足 $\omega_1 + \omega_2 + \omega_3 = 1$ 。通过调整权重系数,可以各因素对路径的影响程度。在本文中,设置 3 个权重系数分别为 0.4、0.4、0.2。

3.3 实验结果与分析

在 3 个不同的三维模拟环境中,对 9 种不同的对比算法进行实验。如图 3 展示的是这些算法在 3 种环境中的飞行路径。每个算法的种群规模被设定为 30,最大迭代次数限制为 50 次。为了确保结果的准确性并排除其他变量的干扰,所有算法都使用了统一的参数设置。每个算法独立执行了 10 次,并计算出最优路径的平均长度。图 3 展示了 9 种算法得到的最优路径,图 4 为 9 种算法在 3 种障碍地图中的平均飞行适应度收敛曲线,表 5 则提供了详细的统计数据。

图 4 为 9 种算法 50 次迭代后的结果。在图 4a 中,DMHO 从第 4 次迭代之后一直处于首位,收敛速度快,精度高。在图 4b 中,DMHO 在前 17 次之后持续领先。在图 4c 中,DMHO 在第 3 次迭代时就已经领先其他对比算法,在 10 次迭代时就已经收敛到了一个稳定的值。虽然对 HO 的改进增加了其计算复杂度,但其收敛速度完全可以弥补。

如表 5 数据所示,DMHO 算法在障碍地图的 50 次迭代取得的适应度平均值最低。且在 3 个环境中,DMHO 的标准差相较于 HO 算法分别降低了 33.39%、72.81%、7.08%,标准差相对较小,提高了算法稳定性。

在 3 种不同复杂度的丘陵的仿真环境中测试结果表明,DMHO 算法显著提高了三维路径规划问题的求解效率和优化精度,表现出优异的稳定性和全局搜索能力。

4 结论

(1) 针对农业无人机路径规划中遇到容易陷入局部最优、稳定性差的问题,本文提出了 DMHO 算法。通过整合 Lévy 飞行、成长比例机制、自适应学习率的 LOBL 算法和随机扩散策略,显著增强了算法的全局搜索、多样性和解寻求能力。

(2) 为评估 DMHO 算法的性能,使用了 CEC2005 中 23 个基准函数进行测试,并与 8 种算法

进行了全面比较。结果表明,DMHO 算法在 23 个函数中的平均值中标率为 91.3%,充分证明了其在解决复杂优化问题上的有效性和优越性。

(3) 通过 3 种不同环境丘陵的无人机多障碍路径规划场景,进一步验证了 DMHO 算法在实际应用中的稳定性和优越性。实验结果表明,与其他对比算法相比,DMHO 算法能够找到更符合实际飞行需求的路径,展示了其在无人机路径规划领域的巨大潜力。

参 考 文 献

[1] LIU G, LI X, SUN S, et al. Design of a multi-component system-based fixed-wing unmanned aerial vehicle maintenance policy and its case study[J]. Computers & Industrial Engineering, 2024,198: 110701.

[2] COUTINHO R W L, BOUKERCHE A F M. UAV-mounted cloudlet systems for emergency response in industrial areas[J]. IEEE Transactions on Industrial Informatics, 2022, 18: 8007 – 8016.

[3] LIN Z, XU X, DEMIR E, et al. Optimizing task assignment and routing operations with a heterogeneous fleet of unmanned aerial vehicles for emergency healthcare services[J]. Computers & Operations Research, 2025, 174: 106890.

[4] LEE H W, LEE C S. Research on logistics of intelligent unmanned aerial vehicle integration system[J]. Journal of Industrial Information Integration, 2023, 36: 100534.

[5] PUPPALA H, MAGANTI L S, PEDDINTI P R T, et al. Thermographic inspections of solar photovoltaic plants in india using unmanned aerial vehicles: analysing the gap between theory and practice[J]. Renewable Energy, 2024, 237(B): 121694.

[6] 孙钊,谢运鸿,王宝莹,等. 基于无人机多维数据集的森林地上生物量估测模型研究[J]. 农业机械学报,2024,55(6): 186 – 195,236.

SUN Zhao, XIE Yunhong, WANG Baoying, et al. Development of forest aboveground biomass estimation model based on multidimensional dataset of UAV[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(6):186 – 195, 236. (in Chinese)

[7] CHAN Y Y, NG K K H, LEE C K M, et al. Wind dynamic and energy-efficiency path planning for unmanned aerial vehicles in the lower-level airspace and urban air mobility context[J]. Sustainable Energy Technologies and Assessments, 2023, 57: 103202.

[8] 吕石磊,范仁杰,李震,等. 基于改进蝙蝠算法和圆柱坐标系的农业无人机航迹规划[J]. 农业机械学报,2023,54(1): 20 – 29,63.

LÜ Shilei, FAN Renjie, LI Zhen, et al. Track planning of agricultural UAV based on improved bat algorithm and cylindrical coordinate system[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(1):20 – 29,63. (in Chinese)

[9] AMIRI M H, MEHRABI HASHJIN N, MONTAZERI M, et al. Hippopotamus optimization algorithm: a novel nature-inspired optimization algorithm[J]. Scientific Reports, 2024, 14(1): 5032.

[10] CHEN Y, WU F, SHI L, et al. Identification of sub-synchronous oscillation mode based on HO – VMD and SVD-regularized TLS-prony methods[J]. Energies, 2024, 17: 5067.

[11] ABDELAZIZ M A, ALI A A, SWIEF R A, et al. Optimizing energy-efficient grid performance: integrating electric vehicles, DSTATCOM, and renewable sources using the hippopotamus optimization algorithm[J]. Scientific Reports, 2024, 14: 28974.

[12] BAIHAN A, ALUTAIBI A I, ALSHEHRI M. Sign language recognition using modified deep learning network and hybrid optimization: a hybrid optimizer (HO) based optimized CNNSa – LSTM approach[J]. Scientific Reports, 2024, 14: 26111.

[13] SUN Y, WANG X, CHEN Y, et al. A modified whale optimization algorithm for large-scale global optimization problems[J]. Expert Systems with Applications, 2018, 114: 563 – 577.

[14] YU F, GUAN J, WU H, et al. Lens imaging opposition-based learning for differential evolution with cauchy perturbation[J]. Applied Soft Computing, 2024, 152: 111211.

[15] WANG Z, HUANG L, YANG S, et al. A quasi-oppositional learning of updating quantum state and Q-learning based on the dung beetle algorithm for global optimization[J]. Alexandria Engineering Journal, 2023, 81: 469 – 488.

[16] SELVA RANI B, VAIRAMUTHU S, SUBRAMANIAN S. Archimedes fire hawk optimization enabled feature selection with deep maxout for network intrusion detection[J]. Computers & Security, 2024, 140: 103751.

[17] HASHIM F A, HOUSSEIN E H, HUSSAIN K, et al. Honey badger algorithm: new metaheuristic algorithm for solving optimization problems[J]. Mathematics and Computers in Simulation, 2022, 192: 84 – 109.

[18] WANG M, ZHAO G, WANG S. Hybrid random forest models optimized by Sparrow search algorithm (SSA) and Harris Hawks optimization algorithm (HHO) for slope stability prediction[J]. Transportation Geotechnics, 2024, 48: 101305.

[19] PARDO X C, GONZÁLEZ P, BANGA J R, et al. Population based metaheuristics in Spark: towards a general framework using PSO as a case study[J]. Swarm and Evolutionary Computation, 2024, 85: 101483.

[20] MEMARIAN S, BEHMANESH-FARD N, ARYAI P, et al. TSFIS-GWO: metaheuristic-driven takagi-sugeno fuzzy system for adaptive real-time routing in WBANs[J]. Applied Soft Computing, 2024, 155: 111427.

[21] ADITYA N, MAHAPATRA S S. An adaptive gravitational search algorithm for optimizing mechanical engineering design and machining problems[J]. Engineering Applications of Artificial Intelligence, 2024, 138: 109298.