http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2025.0846

基于自适应改进蜣螂算法的高原森林灭火多无人机路径规划

朱培*，吕孝龙，陈凯森，宋睿，张剑高，邵荃
(南京航空航天大学 民航学院，南京 211106)

摘 要：针对高原森林复杂环境下无人机灭火救援路径规划问题，提出基于自适应改进蜣螂(AIDBO)算法的多无人机路径规划方法。基于数字高程模型(DEM)数据建立高原森林山区三维地理空间模型，考虑复杂地形、环境风、海拔等因素的影响，以最小飞行时间、风险代价、能耗代价为目标函数，建立从救援临时基地起飞，抵达可能存在灾害区域的多约束条件下多无人机路径规划模型；通过混沌映射与反向学习优化种群初始化，引入鲸鱼优化算法(WOA)的螺旋搜索策略丰富位置更新机制，采用自适应柯西变异增强种群摆脱局部最优的能力，提出一种AIDBO算法进行求解。结果表明：AIDBO算法平均适应度较传统蜣螂(DBO)算法、改进蜣螂(IDBO)算法分别提升10.59%、9.82%；与平原海拔340 m环境相比，海拔2 400 m环境下无人机最长飞行时间略微增加了0.997%，而最大飞行能耗代价增加了58.96%；同时，风向和风速也会对飞行时间和能耗有一定影响。所提AIDBO算法能显著优化高原森林多无人机路径，为高原森林无人机灭火救援调度提供决策支持。

关 键 词：多无人机；路径规划；高原森林；灭火救援；改进蜣螂算法；自适应
中图分类号：U116; V328.4
文献标志码：A **文章编号**：1001-5965(2026)09-2987-14

高原森林复杂环境下，因地形复杂、地面救援受限等，灭火救援难度大，而无人机具有快速机动、不受地形影响的优势，将逐步成为重要的灭火救援手段。然而，高海拔低气压、陡峭地形及强风突变等高原特殊条件，给无人机的飞行性能与安全等带来严峻挑战。因此，开展面向高原森林复杂环境的灭火无人机路径规划优化研究可为实际灭火救援调度决策提供理论支持。

针对森林火灾环境下的救援路径规划问题，潘卫军等[1]以救援航空器升限、航空器最小离地高度、燃油量等性能为约束限制，提出一种自适应动态调整权重的路径规划求解算法；郑玉斌等[2]考虑部分可观测环境、历史观测信息、高维动作空间和奖励稀疏性等因素，提出基于门控循环单元-近端策略优化(gated recurrent unit-proximal policy optimization, GRU-PPO)的多无人机协同追捕方法；滕菲等[3]考虑状态空间、动作空间、动态障碍物和安全约束等因素，提出基于改进PPO算法的无人机动态避障规划方法；朱元军等[4]考虑城市建筑障碍、运行风险、路径长度等因素，提出基于风险约束A*(risk-constrained A*, RC-A*)算法的无人机城市空域安全路径规划方法；朱弥雪[5]提出了考虑无人机转弯、悬停能耗、地形坡度、避障能力等的无人机飞行路径优化模型；余顺金等[6]提出一种基于改进人工势

收稿日期：2025-12-08；**录用日期**：2026-03-06；**网络出版时间**：2026-04-02 09:01
网络出版地址：link.cnki.net/urlid/11.2625.V.20260401.0915.002
基金项目：国家自然科学基金(52202416)；民航应急科学与技术重点实验室开放基金(NJ2022022)
* **通信作者**. E-mail：zpei@nuaa.edu.cn

引用格式：朱培，吕孝龙，陈凯森，等. 基于自适应改进蜣螂算法的高原森林灭火多无人机路径规划[J]. 北京航空航天大学学报，2026，52(9)：2987-3000. Zhu P，Lyu X L，Chen K S，et al. Multi-UAV path planning for forest fire-fighting in plateau based on adaptive improved dung beetle optimization algorithm[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(9)：2987-3000 (in Chinese).

场法的森林防火无人机路径规划模型；李锐君等[7]考虑灭火无人机路径长度、障碍物威胁、航程高度及水平转角等因素，提出了基于粒子群(particle swarm optimization, PSO)算法的灭火无人机路径规划方法；Gao等[8]建立了考虑误差修正约束和航迹约束的多目标规划模型。除地形、气象环境等对无人机性能的影响，森林火场风险威胁同样影响其飞行航线规划。Demir、Radmanesh和Aggarwal[9-11]等基于火灾风险地图和火场辐射威胁，提出集群无人机路径规划方法；Çoğay等[12]提出了一种以无人机能耗最小、火点覆盖率最大为目标，考虑无人机飞行安全高度、飞行时间及能耗约束的路径规划模型；Hasan和Xu[13-14]等分析了风、高温及地形特征对火灾发生的影响，提出了综合考虑无人机、地形、动态障碍物及气象数据的路径规划方法。当在高海拔森林山区环境下执行救援任务时，随着海拔增加，空气密度降低，将对无人机动力学性能产生影响，进而可能影响无人机飞行时间和能耗成本，然而，现有研究较少考虑高海拔低气压等特殊环境的影响。

在无人机路径规划方法方面，元启发式算法因其良好的全局搜索能力和对复杂约束问题的适应性而被广泛应用。经典元启发式算法中，PSO算法结构简单，但易陷入局部最优；遗传算法(genetic algorithm, GA)全局搜索能力强但收敛慢；鲸鱼优化算法(wale optimization algorithm, WOA)在探索与开发间平衡较好，但在高维复杂环境中仍可能过早收敛。而受蜣螂的滚球、舞蹈、觅食和繁殖等行为启发而被提出的蜣螂(dung beetle optimization, DBO)算法[15]有着较强的全局探索与局部开发能力，但在复杂环境下，传统DBO算法在全局优化方面存在一定局限。众多学者对DBO算法进行了改进。Lyu等[16]采用混沌映射增强种群多样性，并提出一种全局探索策略取代了DBO算法的滚动阶段，改善了信息交换，并最大限度地减少了参数依赖性；Chen等[17]将指数递减的惯性权重纳入算法中，提高了收敛速度和探索能力；Zhu等[18]提出了产卵蜣螂和觅食蜣螂数量之间的收敛因子和动态平衡，使得算法能够在早期阶段专注于全局搜索；Shen等[19]使用Beta分布动态生成反射解决方案，以探索更多的搜索空间，并允许个体跳出局部最优值，但增加了算法求解时间；刘微等[20]引入正余弦搜索算法，减少结果陷入局部最优的可能。然而，现有路径规划研究中往往较多考虑无人机自身约束限制，但面对高原复杂环境下缺乏自适应能力，算法易陷入局部最优，或全局搜索时难以快速找到最优解。

因此，本文针对高原环境下灭火救援无人机路径规划问题，建立多约束下的多目标路径规模模型，并提出自适应改进蜣螂(adaptive improved dung beetle optimization, AIDBO)算法求解，为实际高原山区灾害救援提供决策支撑。

1 问题描述与模型建立

1.1 问题描述与假设

高原森林地区的复杂地形和强风会对无人机的飞行速度产生影响，且高海拔和低气压会导致大气密度变化，进而影响无人机的升力和其他空气动力学特性，导致飞行过程中需要更多的能量以保持稳定飞行。为确保无人机能够快速、安全地到达救援区域并有效执行任务，必须对无人机的飞行路径进行优化，综合考虑飞行时间、能量消耗和潜在风险，确保救援任务的高效完成。

基于上述问题，本文做如下假设：

1) 通过各种技术手段已知救援存在区域范围；

2) 路径规划任务的起点和终点已知；

3) 无人机飞行空速保持恒定；

4) 无人机携带的设备(如传感器、摄像头等)产生的能耗忽略不计，仅计算飞行所消耗的能耗；

5) 无人机飞行环境的环境信息已知；

6) 所有无人机机型相同；

7) 不考虑无人机发生故障等情况。

1.2 三维地理空间建模

为更真实地模拟森林地形环境，采用栅格法基于真实数字高程模型(digital elevation model, DEM)数据，结合函数模拟模型对真实山地环境进行建模。将基准地形函数(式(1))和山峰函数(式(2))作为一种噪声源加入DEM数据中，用来模拟地形的微小起伏，增加地形的复杂性。

$$Z_1(x,y)=\sin(y+a)+b\sin(x)+c\cos\left(d\sqrt{x^2+y^2}\right)+e\cos(y)+f\sin\left(g\sqrt{x^2+y^2}\right) \tag{1}$$

式中：$Z_1(x,y)$为使用基准地形函数公式生成的高程数据；a、b、c、d、e、f、g为常数，用于调节函数的形状和特征，不同的取值组合可以得到不同的地形特征，本文依据参考文献[21]分别取值8.0, 0.1, 0.1, 0.4, 1.0, 0.1, 0.1；x、y为投影水平坐标点。

$$Z_2(x,y)=\sum_{i=1}^{k}h_{0i}\exp\left[-\left(\frac{x-x_{0i}}{x_{si}}\right)^2-\left(\frac{y-y_{0i}}{y_{si}}\right)^2\right] \tag{2}$$

式中：$Z_2(x,y)$为使用山峰函数公式生成的高程数据；h_{0i}取决于第i座山体的高度；(x_{0i},y_{0i})用于描述第i座山峰的基本形状，如坡度衰减值；k为山峰数量；x_{si}、y_{si}表示第i座山峰分别沿x、y轴方向与倾斜坡度相关的参数，决定山峰的陡峭程度，取值越小山峰越陡峭，取值越大山峰越平缓。

将原始 DEM 数据、基准地形数据与山峰地形数据融合, 融合后的地形数据可以更为精确地模拟出复杂的森林地形。融合后的地形数据可表示为

$$z(x,y)=Z_0(x,y)+Z_1(x,y)+Z_2(x,y) \tag{3}$$

式中: $z(x,y)$为最终融合后的地形高程数据; $Z_0(x,y)$为原始 DEM 高程数据。

1.3　模型建立

1.3.1　目标函数

高原森林救援无人机路径规划需考虑多种影响因素, 本文以飞行时间、风险代价、能耗代价最小为目标函数, 考虑飞行安全距离, 建立从起飞站点到灾害区域的多无人机路径规划模型。

1) 飞行时间代价。无人机飞行时间代价用于衡量无人机在完成任务时所需的最短飞行时间。时间代价模型以降低执行任务的总时间为目标, 通过优化路径规划以尽可能缩短无人机在任务执行过程中花费的时间。第$i-1$个路径点到第i个路径点之间的时间$T_{i-1,i}$可以通过式(4)表达:

$$T_{i-1,i}=\frac{l_{i-1,i}}{v_{\mathrm{d},i-1,i}} \tag{4}$$

式中: $l_{i-1,i}$为路径上第$i-1$个路径点到第i个路径点之间的距离; $v_{\mathrm{d},i-1,i}$为无人机地速。在无风情况下, 无人机的飞行速度(空速)不受环境风速的影响, 此时空速与地速相等。然而, 当有风存在时, 无人机的地速则为空速与风速的矢量之和。

无人机地速$v_{\mathrm{d},i-1,i}$表示为

$$\begin{bmatrix}\cos\theta_{i-1,i}\\ \sin\theta_{i-1,i}\end{bmatrix}v_{\mathrm{d},i-1,i}=\begin{bmatrix}\cos\varphi_{i-1,i} & \cos\phi_{i-1,i}\\ \sin\varphi_{i-1,i} & \sin\phi_{i-1,i}\end{bmatrix}\begin{bmatrix}v_{\mathrm{a}}\\ v_{\mathrm{wind},i-1,i}\end{bmatrix} \tag{5}$$

式中: v_{a}为无人机空速; $v_{\mathrm{wind},i-1,i}$为第$i-1$个路径节点到第i个路径节点的风速; $\theta_{i-1,i}$为地速航向角; $\varphi_{i-1,i}$为空速航向角; $\phi_{i-1,i}$为第$i-1$个路径节点到第i个路径节点的风向。

无人机总飞行时间表示为

$$T=\sum_{i=1}^{n}T_{i-1,i} \tag{6}$$

因此, 为获取无量纲飞行时间代价, 定义实际飞行时间T与理论最短直线飞行时间T_0的比值为飞行时间代价, 如下:

$$f_T=\frac{T}{T_0} \tag{7}$$

式中: $T_0=L_0/v_{\mathrm{d}}$, T_0为起始点到目标点直线飞行时间, L_0为起始点到目标点距离。f_T=1表示无人机无干扰沿直线飞行, 为理想下限; f_T>1则反映了规避地形威胁, 大气威胁保持飞行安全等约束所必须付出的额外时间成本; 最小化飞行时间代价f_T即是在满足所有安全与物理约束的前提下, 尽可能逼近最短时间路径, 其取值范围为接近 1 的最优值。

2) 风险代价。山区中由于地形的阻挡, 通信信号可能存在盲区, 导致可能失去与地面控制站通信的风险。为降低无人机飞向盲区的概率, 将整个无人机飞行的林场环境按照通信盲区、地形威胁等因素预先划分为多个风险等级的区域, 并定义风险值范围 (0,1) 区间。为综合评估整个飞行路径的风险, 可以将路径上每一个点的风险值加权求和, 得到路径的总风险值$R(C_1)$, 表示为

$$R(C_1)=\sum_{i=1}^{n}\left(R\left(C_1^i\right)l_{i-1,i}\right)/1\,000 \tag{8}$$

式中: $R\left(C_1^i\right)$为路径上第i个点的风险值; $l_{i-1,i}$为路径上第$i-1$个路径点到第i个路径点之间的距离, 表示权重; $R(C_1)$取值范围处于 (0,1) 区间。

同时, 森林山区存在的风切变等气象环境将影响飞行安全, 将此类区域定义为大气威胁区。为尽可能避免飞入大气威胁区, 本文将其视为圆柱体, 半径为R_w, 如图 1 所示。图中: O_w为第w个大气威胁区的中心点位置。同时, 为减少由于过度避开大气威胁区而增加的飞行路径, 增加安全冗余度, 对大气威胁区半径进行裕度扩展, 扩展宽度为D_{mar}, 无人机主要在扩展区内飞行。因此, 大气威胁区对无人机的威胁成本代价$R(C_2)$可用式 (9) 计算:

$$\begin{cases}R(C_2)=\sum_{i=1}^{n}\sum_{w=1}^{q}K_{i-1,i,w}\\ K_{i-1,i,w}=1-\dfrac{g_{i-1,i}^{w}}{R_w+D_{\mathrm{mar}}} \qquad R_w<g_{i-1,i}^{w}<R_w+D_{\mathrm{mar}}\end{cases} \tag{9}$$

式中: $K_{i-1,i,w}$为第$i-1$个路径点到第i个路径点之间的威胁代价; $g_{i-1,i}^{w}$为第$i-1$个路径点到第i个路径点连线到O_w点的垂直距离, 即在区间$(R_w, R_w+D_{\mathrm{mar}})$范围内。因此, $K_{i-1,i,w}$取值为 (0,1)。大气威胁值$R(C_2)$为有限个大气威胁区的威胁代价值总和。

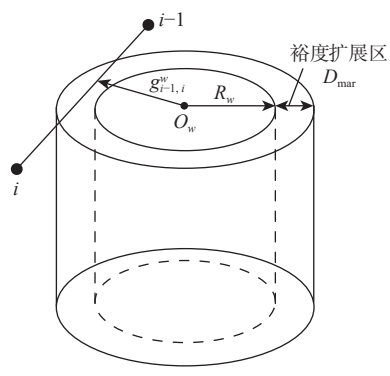

图 1　大气威胁区示意图

Fig. 1　Schematic diagram of atmospheric threat zone

无人机路径风险代价f_R可表示为

$$f_R = R(C_1) + R(C_2) \tag{10}$$

3）能耗代价。飞行能耗影响续航时间和任务执行效率，决定灭火救援任务能否有效完成。无人机从第$i-1$个路径点到第i个路径点所消耗功率$P_{i-1,i}$可表示为

$$P_{i-1,i} = P_{i-1,i}^{\text{blade}}\left(1+\frac{3v_{\text{d},i-1,i}^2}{U_{\text{tip}}^2}\right)+\frac{P_{i-1,i}^{\text{induced}}v_0}{v_{\text{d},i-1,i}}+\frac{1}{2}d_0\rho_{i-1,i}sAv_{\text{d},i-1,i}^3 \tag{11}$$

式中：$P_{i-1,i}^{\text{blade}}$和$P_{i-1,i}^{\text{induced}}$分别为无人机悬停状态下的叶型功率和悬停状态下的诱导功率；U_{tip}为旋翼叶片的叶尖速度；v_0为悬停状态下平均转子诱导速度；d_0为机身阻力比；s为转子固体度；A为转子盘面积；ρ为大气密度。

$P_{i-1,i}^{\text{blade}}$和$P_{i-1,i}^{\text{induced}}$分别表示为

$$P_{i-1,i}^{\text{blade}} = \frac{\delta}{8}\rho_{i-1,i}sA\Omega^3R_{\text{r}}^3 \tag{12}$$

$$P_{i-1,i}^{\text{induced}} = (1+\kappa)\frac{W^{\frac{3}{2}}}{\sqrt{2\rho_{i-1,i}A}} \tag{13}$$

式中：δ为剖面阻力系数；Ω为叶片角速度；R_{r}为转子半径；κ为对感应功率的增量修正系数；W为无人机质量。大气密度ρ会随着海拔升高而降低，其与温度及大气压力的关系可表示如下：

$$\rho = \frac{P_{\text{a}}}{0.286\,9\left(T_{\text{temp}}+273.1\right)} \tag{14}$$

式中：T_{temp}为摄氏温度；P_{a}为环境压强。

依据大气压力与海拔间的经验公式：

$$P_{\text{a}} = 101.3\left[1-0.025\,5\frac{H}{1\,000}\left(\frac{6\,357}{6\,357+\frac{H}{1\,000}}\right)\right]^{5.256} \tag{15}$$

式中：H为海拔。

因此，考虑海拔影响的无人机总能耗可表示为

$$\sum_{i=1}^{n}E_{i-1,i} = \sum_{i=1}^{n}\frac{l_{i-1,i}}{v_{\text{d},i-1,i}}P_{i-1,i} \tag{16}$$

式中：$l_{i-1,i} = \sqrt{(x_i-x_{i-1})^2+(y_i-y_{i-1})^2+(z_i-z_{i-1})^2}$为各路径段长度；$P_{i-1,i}$为无人机消耗功率。

无人机的能耗代价f_{E}可表示为

$$f_E = \frac{\sum_{i=1}^{n}E_{i-1,i}}{E_{\text{s}\to\text{p}}} \tag{17}$$

式中：$\sum_{i=1}^{n}E_{i-1,i}$为无人机总能耗；$E_{\text{s}\to\text{p}}$为起始点到目标点直线距离能耗。$f_E=1$表示无人机沿直线无干扰飞行的能耗代价；$f_E>1$则反映了规避地形威胁，大气威胁保持飞行安全等约束需付出的额外能耗成本。因此，最小化f_E即在满足所有安全与物理约束的前提下，尽可能逼近最小能耗代价，取值范围为接近1的最优值。

4）总代价目标函数。综上，单架高原森林灭火无人机路径规划模型目标函数可表示为

$$f = \omega_1 f_T + \omega_2 f_R + \omega_3 f_E \tag{18}$$

式中：$\omega_1+\omega_2+\omega_3=1$。

多灭火无人机路径规划模型目标函数表示为

$$f' = \omega_1 f_{T,\text{sum}} + \omega_2 f_{R,\text{sum}} + \omega_3 f_{E,\text{sum}} \tag{19}$$

式中：$f_{T,\text{sum}}$、$f_{R,\text{sum}}$、$f_{E,\text{sum}}$分别为所有无人机总飞行时间代价、总风险代价、总能耗代价，即所有无人机代价求和值。本文中，为体现“打早、打小”的火灾扑救原则对快速响应的要求，时间权重设置为$\omega_1=0.4$；为确保路径安全，避免无人机受到大气威胁而失联或坠毁，风险权重设置为$\omega_2=0.2$；由于高海拔对无人机续航能力影响较大，保证无人机能耗极为关键，能耗权重设置为$\omega_3=0.4$。

1.3.2 约束条件

1）飞行高度约束。设无人机在第i个路径点飞行高度为h_i，此时对应的地形高度为$h_{i,\text{m}}$，无人机需要与山体保持一定高度距离h_{safe}防止撞击山体，同时，飞行高度应小于最大飞行高度值$H_{\max}$。

$$h_{i,\text{m}} + h_{\text{safe}} \leqslant h_i \leqslant H_{\max} \tag{20}$$

2）俯仰角约束。为确保无人机能够在不同飞行阶段保持适当的姿态并有效应对外部环境的变化，必须对俯仰角进行合理的约束。

$$0 \leqslant \mu_i = \frac{|z_i - z_{i-1}|}{\sqrt{(x_i-x_{i-1})^2+(y_i-y_{i-1})^2}} \leqslant \tan\mu_{\max} \tag{21}$$

式中：μ_i为无人机在第i个路径点的俯仰角；$\mu_{\max}$为最大俯仰角。

3）能耗约束。无人机的任务执行能力受到电池容量和能耗效率的制约，需设定给定任务的能耗约束，确保其具备足够续航时间完成任务。

$$\sum_{i=1}^{n}E_{i-1,i} \leqslant E_{\text{total}} \tag{22}$$

式中：E_{total}为无人机路径规划任务总能耗。

4）无人机间安全约束。多无人机执行任务时，需设置安全距离限制防止碰撞。将无人机体积简化为质点，并假设2个无人机分别为无人机p、无人机q，每架无人机之间的距离为d_{pq}，将无人机之间的最小安全距离设定为$d_{pq,\min}$，则需满足：

$$d_{pq} \geqslant d_{pq,\min} \tag{23}$$

2　算法设计

为解决陷入局部最优的问题, 本文提出了一种 AIDBO 算法, 提升其全局搜索能力和适应性。该算法通过基于混沌映射与反向学习的种群初始化, 减少初始解的集中性; 引入 WOA 的螺旋搜索策略, 丰富位置更新机制; 采用自适应柯西变异策略增强蜣螂种群摆脱局部最优解的能力, 有效扩展搜索空间范围。

2.1　传统蜣螂算法

DBO 算法将种群分为 4 类: 滚球蜣螂、繁殖蜣螂、觅食小蜣螂、偷窃蜣螂。

2.1.1　滚球蜣螂位置更新机制

滚球蜣螂分为有障碍模式和无障碍模式。当无障碍时, 执行全局搜索, 快速搜索整个三维空间, 找到初步的候选路径点, 其位置更新如下:

$$\boldsymbol{X}_i(t+1)=\boldsymbol{X}_i(t)+k\alpha\boldsymbol{X}_i(t-1)+b_n\Delta\boldsymbol{X} \tag{24}$$

式中: t为迭代次数; $\boldsymbol{X}_i(t)$和$\boldsymbol{X}_i(t+1)$分别为第t次和第$t+1$次迭代时滚球蜣螂的位置信息; $k\in(0,0.2]$为偏转系数; α为自然数, 用于表示是否偏离原来的方向, $\alpha=1$时表示没有偏离, $\alpha=-1$时表示偏离原来的滚球方向; b_n为属于 (0,1) 的自然系数, 取 0.3; $\Delta\boldsymbol{X}=|\boldsymbol{X}_i(t)-\boldsymbol{X}^w|$用于模拟光强, 即距离全局最差解$\boldsymbol{X}^w$的距离。

当蜣螂遇到障碍物会通过舞蹈重新定位以寻找新的路径, 其舞蹈行为可用正切函数模拟, 从而获取新的滚动方向。滚球蜣螂的位置更新如下:

$$\boldsymbol{X}_i(t+1)=\boldsymbol{X}_i(t)+\tan\theta_{\mathrm{d}}|\boldsymbol{X}_i(t)-\boldsymbol{X}_i(t-1)| \tag{25}$$

式中: $\theta_{\mathrm{d}}\in[0,\pi]$。

2.1.2　繁殖蜣螂位置更新机制

繁殖蜣螂进行局部区域精细搜索, 以找到安全通过障碍物的路径, 其位置更新如下:

$$\boldsymbol{B}_i(t+1)=\boldsymbol{X}^*+\left(\boldsymbol{B}_i(t)-\boldsymbol{L}_{\mathrm{b}}^*\right)\times\boldsymbol{b}_1+\left(\boldsymbol{B}_i(t)-\boldsymbol{U}_{\mathrm{b}}^*\right)\times\boldsymbol{b}_2 \tag{26}$$

$$\begin{cases}\boldsymbol{L}_{\mathrm{b}}^*=\max\left((1-R_{\mathrm{c}})\boldsymbol{X}^*,\boldsymbol{L}_{\mathrm{b}}\right)\\ \boldsymbol{U}_{\mathrm{b}}^*=\min\left((1+R_{\mathrm{c}})\boldsymbol{X}^*,\boldsymbol{U}_{\mathrm{b}}\right)\end{cases} \tag{27}$$

式中: "×" 表示逐元素相乘; $\boldsymbol{B}_i(t)$和$\boldsymbol{B}_i(t+1)$分别为第t次和第$t+1$次迭代时繁殖蜣螂的位置信息; $\boldsymbol{L}_{\mathrm{b}}^*$和$\boldsymbol{U}_{\mathrm{b}}^*$分别为产卵最优区域的下界和上界; $R_{\mathrm{c}}=1-t/t_{\max}$, R_{c}为动态变化的参数, 用于控制产卵区域随迭代次数动态缩小的速度, $t_{\max}$为最大的迭代次数; $\boldsymbol{X}^*$为当前种群的局部最优位置; $\boldsymbol{b}_1$、$\boldsymbol{b}_2$为$1\times D$大小的独立随机向量, D为优化问题的维度。

2.1.3　觅食小蜣螂位置更新机制

觅食小蜣螂负责探索新区域, 通过大范围搜索帮助跳出局部最优, 增加搜索多样性, 位置更新方式如下:

$$\boldsymbol{X}_i(t+1)=\boldsymbol{X}_i(t)+\left(\boldsymbol{X}_i(t)-\boldsymbol{L}_{\mathrm{b}}^{\mathrm{b}}\right)C_1+\left(\boldsymbol{X}_i(t)-\boldsymbol{U}_{\mathrm{b}}^{\mathrm{b}}\right)\times\boldsymbol{C}_2 \tag{28}$$

式中:

$$\begin{cases}\boldsymbol{L}_{\mathrm{b}}^{\mathrm{b}}=\max\left((1-R_{\mathrm{c}})\boldsymbol{X}^{\mathrm{b}},\boldsymbol{L}_{\mathrm{b}}\right)\\ \boldsymbol{U}_{\mathrm{b}}^{\mathrm{b}}=\min\left((1+R_{\mathrm{c}})\boldsymbol{X}^{\mathrm{b}},\boldsymbol{U}_{\mathrm{b}}\right)\end{cases} \tag{29}$$

式中: $\boldsymbol{L}_{\mathrm{b}}^{\mathrm{b}}$和$\boldsymbol{U}_{\mathrm{b}}^{\mathrm{b}}$分别为小蜣螂最优觅食区的下界和上界; $\boldsymbol{X}^{\mathrm{b}}$为全局最优位置; $C_1\sim N(0,1)$为随机数并服从正态分布; $\boldsymbol{C}_2$为 (0,1) 的随机向量。

2.1.4　偷窃蜣螂位置更新机制

偷窃蜣螂在路径优化的中后期, 偷窃蜣螂通过模仿其他个体的优秀解来改进自身路径, 位置更新公式如下:

$$\boldsymbol{X}_i(t+1)=\boldsymbol{X}^{\mathrm{b}}+S\boldsymbol{g}\left(|\boldsymbol{X}_i(t)-\boldsymbol{X}^*|+\left|\boldsymbol{X}_i(t)-\boldsymbol{X}^{\mathrm{b}}\right|\right) \tag{30}$$

式中: $\boldsymbol{g}$为$1\times D$大小的正态分布随机向量; S为常数。

2.2　自适应改进蜣螂算法

2.2.1　种群初始化改进

由于在初始化阶段缺乏参考的全局最优信息, 初始种群应尽可能均匀覆盖搜索空间, 以减少对全局探索的依赖, 从而更快速地找到全局最优解。传统 DBO 算法的初始种群通常采用随机生成方式, 可能导致种群分布不均、多样性不足, 影响全局搜索效率。首先, 采用 Tent 混沌映射生成具有遍历性和均匀性的初始解, 避免种群过早聚集, 如下:

$$\varphi_{n+1}=\begin{cases}\dfrac{\varphi_n}{\gamma} & 0<\varphi_n<\gamma\\ \dfrac{1-\varphi_n}{1-\gamma} & \gamma\leqslant\varphi_n\leqslant 1\end{cases} \tag{31}$$

式中: 混沌映射状态值$\gamma\in(0,1)$; φ_n为当前迭代步的混沌状态值; φ_{n+1}为下一步的混沌状态值。

其次, 为增强种群的多样性和探索能力, 加快算法的收敛速度, 并有效避免陷入局部最优, 采用反向学习方法生成与当前解对立的解(反向解), 并对比这 2 个解的适应度值, 选择适应度较优的解进行下一次迭代。然而, 由于 2 个解的距离为固定值, 缺少随机性, 引入随机因子J进一步增强该策略在全局搜索能力:

$$\boldsymbol{X}_{nd}=\boldsymbol{L}_{\mathrm{b}}+y_{nd}(\boldsymbol{U}_{\mathrm{b}}-\boldsymbol{L}_{\mathrm{b}}) \tag{32}$$

$$\hat{\boldsymbol{X}}_{nd}=\boldsymbol{U}_{\mathrm{b}}+\boldsymbol{L}_{\mathrm{b}}-J\boldsymbol{X}_{nd} \tag{33}$$

式中: $\boldsymbol{X}_{nd}$为第n个种群的第d维数; y_{nd}为由 Tent 混沌变换产生的混沌序列; $\boldsymbol{U}_{\mathrm{b}}$和$\boldsymbol{L}_{\mathrm{b}}$分别为搜索的上界

和下界；$\hat{\boldsymbol{X}}_{nd}$为$\boldsymbol{X}_{nd}$的反向解，即反向种群个体；$J$为(0,1)间的随机数。将原始种群与其对应的反向种群合并生成新种群，计算新种群中每个个体的适应度函数值，对其进行排序，最终选择适应度最优的N个个体作为新的初始种群。

2.2.2 融合WOA螺旋搜索策略的位置更新方法

WOA凭借其独特的螺旋搜索策略，在处理复杂优化问题时展现了强大的潜力。DBO算法中，繁殖蜣螂的位置更新主要依赖于局部最优信息，在复杂高维环境中易导致搜索范围受限。为提升DBO算法的性能，本文将WOA的螺旋搜索策略融入繁殖蜣螂的位置更新机制，从而增强其全局搜索能力，在复杂的优化环境中实现更高效的探索与开发。螺旋搜索公式如下：

$$\boldsymbol{X}_i(t+1)=\boldsymbol{D}'\mathrm{e}^{cr^*}\cos(2\pi r^*)+\boldsymbol{X}^* \tag{34}$$

$$\boldsymbol{D}'=|\boldsymbol{X}^*-\boldsymbol{X}_i(t)| \tag{35}$$

式中：$\boldsymbol{D}'$为个体和当前最优位置之间的距离；r^*为[0,1]间的随机数；c为决定对数螺旋形状的常量系数。当c取值较大时，易导致衰减过快从而陷入局部最优，当c取值较小时会导致收敛较慢。因此，引入动态螺旋搜索形状的参数cr^*，表示为

$$cr^*=\exp\left(c\cdot\cos\left(\frac{\pi t}{t_{\max}}\right)\right) \tag{36}$$

因此，繁殖蜣螂位置更新公式表示为

$$\begin{aligned}\boldsymbol{B}_i(t+1)=&\boldsymbol{X}^*+\mathrm{e}^{cr^*}\cos(2\pi r^*)\left(\boldsymbol{B}_i(t)-\boldsymbol{L}_{\mathrm{b}}^*\right)\times\boldsymbol{b}_1+\\&\mathrm{e}^{cr^*}\cos(2\pi r^*)\left(\boldsymbol{B}_i(t)-\boldsymbol{U}_{\mathrm{b}}^*\right)\times\boldsymbol{b}_2\end{aligned} \tag{37}$$

2.2.3 自适应柯西变异策略

在DBO算法的迭代收敛后期，蜣螂种群通常会集中在最优个体附近，可能导致整体多样性的降低，陷入局部最优。本文引入了一种自适应柯西变异策略，用于调整蜣螂种群的位置，该策略不仅增强了算法摆脱局部最优解的能力，还扩展了搜索空间范围，其公式如下：

$$\boldsymbol{Y}^{\mathrm{b}}(t)=\boldsymbol{X}^{\mathrm{b}}(t)+\boldsymbol{X}^{\mathrm{b}}(t)\cdot\mathrm{Cauchy}(0,1) \tag{38}$$

式中：$\boldsymbol{Y}^{\mathrm{b}}(t)$为第$t$次迭代中当前最优位置在柯西变异后的解；$\mathrm{Cauchy}(0,1)$为柯西变异算子，表示为

$$\mathrm{Cauchy}(x)=\frac{1}{\pi}\left(\frac{1}{x^2+1}\right)\qquad -\infty<x<\infty \tag{39}$$

因此，本文提出的AIDBO算法是在传统DBO算法基础上，融合了混沌映射与反向学习的种群初始化策略、WOA螺旋搜索策略和自适应柯西变异策略。

2.3 算法求解流程

本文基于上述改进策略提出了AIDBO算法求解流程。在算法求解中，为保证生成的路径满足约束条件，采用剔除策略对无效路径进行约束处理，即在种群初始化阶段，对每个个体进行约束检查，剔除不满足约束的个体并重新生成，直至初始种群全部满足约束条件；在每次迭代中，滚球蜣螂、繁殖蜣螂、觅食小蜣螂和偷窃蜣螂的位置更新后，再次进行约束检查，若新位置违反约束，则将该个体标记为无效，不参与本次迭代的适应度评估和后续的变异操作。通过这种方式，确保算法搜索过程中的所有候选路径均为物理可行解。路径规划问题求解流程如图2所示，算法求解具体步骤如下：

输入：最大迭代次数$T_{\max}$，种群大小N。

输出：最优位置$\boldsymbol{X}^{\mathrm{b}}$及对应的适应度$f_{\min}$。

1. 利用混沌映射与反向学习进行种群初始化$i\leftarrow1,2,\cdots,N$。

2. while $t\leqslant T_{\max}$ do

3. for i 属于滚球蜣螂 do

4. α=rand(1)

5. if $\alpha\leqslant0.9$ then

6. 使用式(24)更新滚球蜣螂位置。

7. 检查新位置是否满足约束，若不满足则重新生成或标记为无效，无效值不参与后续步骤。

8. else

9. 使用式(25)模拟存在障碍物情况下的位置更新。

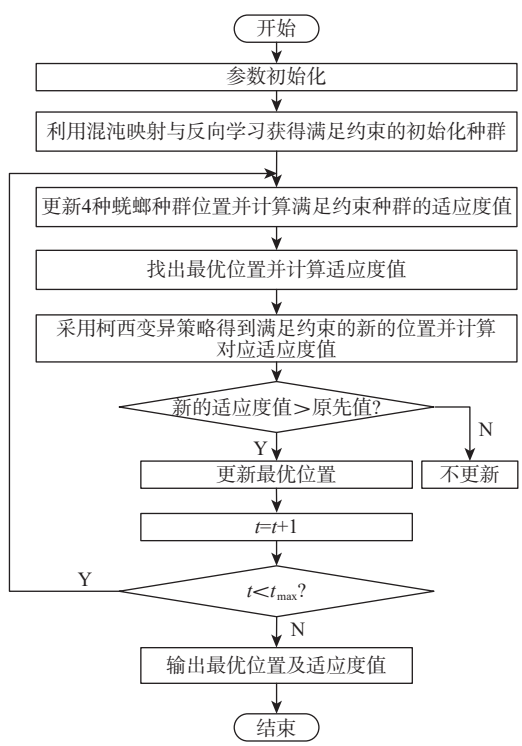

图2 自适应改进蜣螂优化算法流程

Fig. 2 Flowchart of adaptive improved dung beetle optimization algorithm

10. 检查新位置是否满足约束, 若不满足则重新生成或标记为无效, 无效值不参与后续步骤。

11. end if

12. end for

13. for i 属于繁殖蜣螂 do

14. 使用式 (27) 确定繁殖蜣螂更新范围, 并使用式 (37) 更新繁殖蜣螂位置。

15. 检查新位置是否满足约束, 若不满足则重新生成或标记为无效, 无效值不参与后续步骤。

16. end for

17. for i 属于觅食小蜣螂 do

18. 使用式 (29) 确定小蜣螂觅食更新范围, 并使用式 (28) 更新小蜣螂位置。

19. 检查新位置是否满足约束, 若不满足标记为无效, 无效值不参与后续步骤。

20. end for

21. for i 属于偷窃蜣螂 do

22. 使用式 (30) 更新偷窃蜣螂位置。

23. 检查新位置是否满足约束, 若不满足标记为无效, 无效值不参与后续步骤。

24. end for

25. 选择当前最优解, 利用式 (38) 实现自适应柯西变异。

26. 检查变异后的解是否满足约束, 若不满足则放弃变异, 保留原解。

27. if 变异后的解比当前解更优 then

28. 更新最优解。

29. end if

30. t=t+1

31. end while

32. return 适应度 $f_{\min}$

3　算例分析

3.1　算法有效性

3.1.1　基准函数测试

为验证本文提出的 AIDBO 算法的有效性, 选用 IEEE 发布的 CEC200 测试集作为评估标准。测试中选取 3 个单峰基准函数和 3 个多峰基准函数进行验证。其中, F_1、F_2、F_3为单峰函数, 用于评估算法的收敛速度及局部开发能力; F_4、F_5、F_6为多峰函数, 用来测试算法的全局探索性能。函数具体表达式如表 1 所示。

实验设置最大迭代次数为 500, 种群规模为 30。滚球蜣螂、繁殖蜣螂、觅食小蜣螂、偷窃蜣螂的数量分别设置为 6、6、7、11。对 WOA、传统 DBO 算法、IDBO 算法[17]、3 类改进策略组合算法和 AIDBO 算法分别进行 10 次独立测试。其中, 3 类不同策略组合的算法是为验证改进策略对算法的影响: ①DBO-1, 在传统 DBO 算法基础上增加混沌映射与反向学习的种群初始化策略; ②DBO-2, 在传统 DBO 算法基础上增加融合 WOA 螺旋搜索策略; ③DBO-3, 在传统 DBO 算法基础上增加混沌映射与反向学习的种群初始化策略和融合 WOA 螺旋搜索策略。WOA 参数 b_h、p 分别设置为 1、0.5; DBO 算法和 IDBO 算法中, 根据参考文献 [18] 将参数 k、w、b、λ 分别设置为 0.1、0.9、0.3、0.5; AIDBO 算法中, 根据参考文献 [16,18], 将参数 k、w、b、λ、γ、c 分别设置为 0.1、0.9、0.3、0.5、0.5、1。从图 3 的结果可看出, 在 6 个经典测试函数实验中, 相较于其他算法, AIDBO 算法在性能上表现出显著优势。在单峰和多峰函数中, AIDBO 算法的平均值更优, 具有更好的鲁棒性, 能够快速且稳定地达到最优解, 而其他算法的收敛速度较为缓慢, 且通常难以接近最优值。

表 1　测试函数表达式

Table 1　Test Function Expression

函数	表达式	维度	搜索范围
F_1	$F_1(x)=\sum_{i=1}^{n}x_i^2$	30	[−100,100]
F_2	$F_2(x)=\sum_{i=1}^{n}\lvert x_i\rvert+\prod_{i=1}^{n}\lvert x_i\rvert$	30	[−10,10]
F_3	$F_3(x)=\sum_{i=1}^{n}\left(\sum_{j=1}^{i}x_j^2\right)^2$	30	[−100,100]
F_4	$F_4(x)=\sum_{i=1}^{n}ix_i^4+\mathrm{random}[0,1)$	30	[−1.28,1.28]
F_5	$F_5(x)=\sum_{i=1}^{n}[x_i^2-10\cos(2\pi x_i)+10]$	30	[−5.12,5.12]
F_6	$F_6(x)=-20\exp\left(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^{n}x_i^2}\right)-\exp\left(\frac{1}{n}\sum_{i=1}^{n}\cos(2\pi x_i)\right)$	30	[−32,32]

3.1.2　实例场景

为验证本文路径规划模型与算法的有效性和合理性, 选择云南省丽江市(平均海拔 2 400 m)某森林区域为例, 其地形以山地、丘陵为主, 沟壑纵横, 地形起伏显著, 气候昼夜温差大、季风明显, 植被以云南松为主要建群种, 伴有栎类等阔叶树, 是典型高原森林山区。本文通过地理空间数据云公开平台获取 DEM 数据; 利用 ArcGIS 截取某 4 000 m×4 000 m 区域(地图分辨率为 30 m, 高度 1 590～2 444 m)用于仿真验证, 将该区域作为无人机执行任务的路径规划环境, 使用 MATLAB 对该环境进行模拟展示。本文采用某型号多旋翼灭火无人机执行任务, 无人机性能参数均来自文献 [22], 如表 2 所示。设置 5 架无人机, 起始点坐标、目标点坐标、大气威胁区参数及风向风速等环境参数设置如

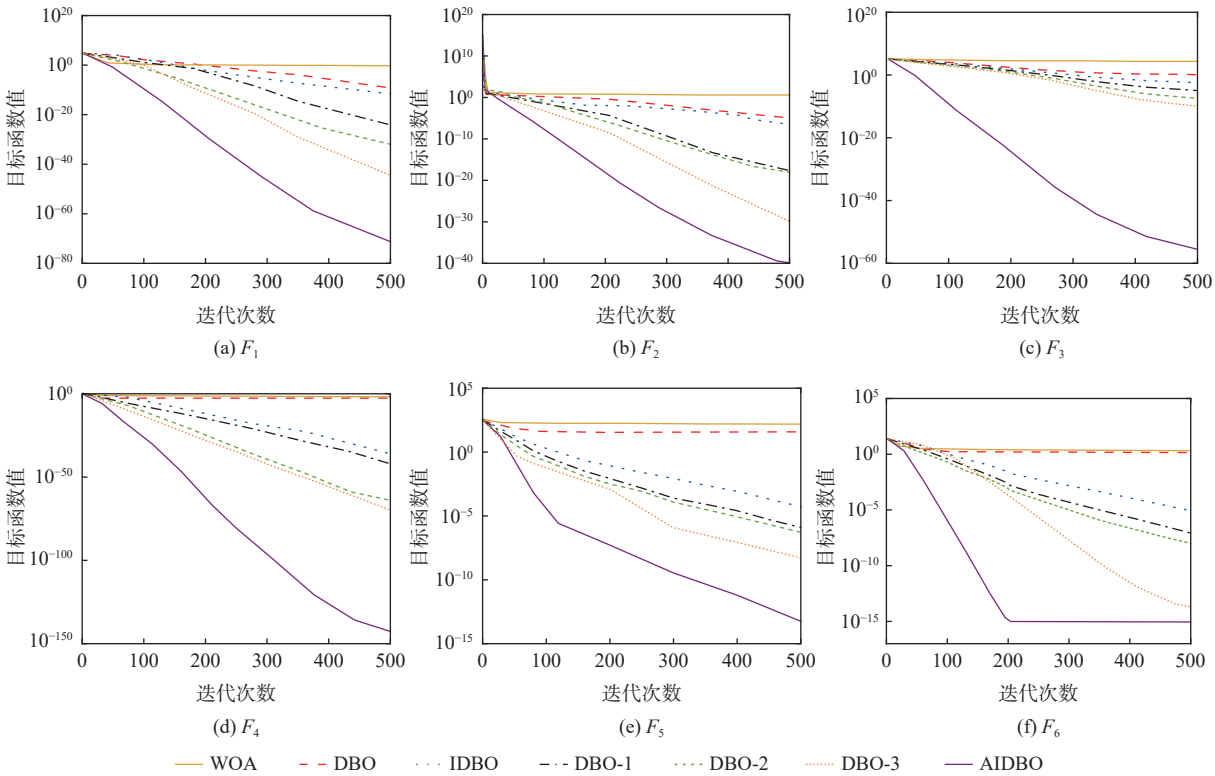

图3 基准测试收敛曲线

Fig. 3 Benchmark convergence curves

表2 无人机性能参数设置[22]

Table 2 UAV performance parameter configuration[22]

参数	数值
转子半径R_r/m	0.5
转子盘面积A/m^2	0.785
剖面阻力系数δ	0.008
叶片角速度Ω/(rad·s^{-1})	180
机身阻力比d_0	0.6
转子固体度s	0.05
感应功率增量修正系数κ	0.1
无人机总质量W_q/kg	60
无人机空速v_a/(m·s^{-1})	15
最大飞行高度H_{max}/m	300
安全距离h_{safe}/m	80
无人机之间的安全距离$d_{pq,min}$/m	10

表3 环境参数设置

Table 3 Environment parameter configuration

参数	设置
无人机1起始点坐标/m	(600,3 620,2 000)
无人机2起始点坐标/m	(600,3 600,2 000)
无人机3起始点坐标/m	(600,3 580,2 000)
无人机4起始点坐标/m	(580,3 600,2 000)
无人机5起始点坐标/m	(620,3 600,2 000)
目标点坐标/m	(3 000,300,2 300)
大气威胁区1坐标$_1$/m	(1 300,1 600)
大气威胁区1半径$_2$/m	200
大气威胁区2坐标$_1$/m	(2 000,1 500)
大气威胁区2半径$_2$/m	200
风速/(m·s^{-1})	8
风向	西北(以y轴正向为北,x轴正向为东)
温度/℃	15
大气威胁区裕度扩展宽度D_{mar}/m	50

表3所示。不同区域风险值设置如图4所示。

3.1.3 算法对比验证分析

为验证模型和算法在求解实例场景路径规划的有效性,采用不同算法进行路径规划求解,并对比分析算法性能。

首先,为验证AIDBO算法中改进策略关键参数的可信性,避免经验依赖性,分别对涉及的混沌映射参数γ和螺旋搜索常数c等关键参数进行敏感性分析,其他参数依据文献数据保持默认值,计算其最优适应度、平均适应度和标准差,结果如表4和表5所示。

根据表4的结果,当γ=0.5时,算法获得最优适应度值和最低平均适应度值,表明此参数设置下的初始种群质量最高。γ值控制Tent混沌映射的序列分布特性,γ值偏离0.5时,序列分布偏向0或1,导致初始种群在解空间一侧过度集中,降低了搜索效率。根据表5的结果,c=1.0时,螺旋搜索能够在探索新区域和开发已知区域之间取得最佳平衡,特

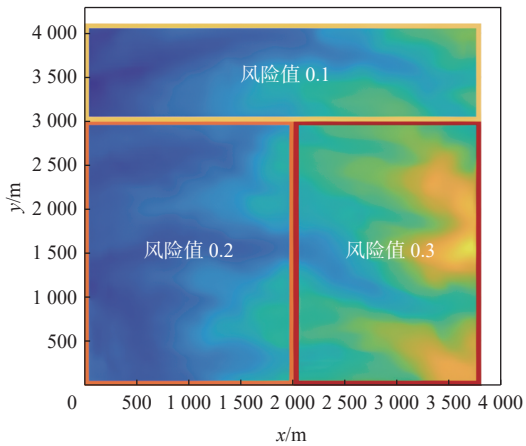

图 4　不同区域风险值设置

Fig. 4　Setting of risk values for different areas

表 4　混沌映射参数γ对算法性能的影响

Table 4　Influence of chaotic mapping parameter γ on algorithm performance

γ	最优适应度值	平均适应度值	标准差
0.3	3.305	3.425	0.235
0.5	2.984	3.224	0.251
0.7	3.412	3.589	0.312

表 5　螺旋搜索参数c对算法性能的影响

Table 5　Influence of spiral search parameters c on algorithm performance

c	最优适应度值	平均适应度值	标准差
0.5	3.284	3.476	0.267
1.0	2.984	3.224	0.251
2.0	3.396	3.512	0.301

别适合高原复杂地形中多威胁区的路径规划问题。c值过小则探索不足, 易陷入局部最优; c值过大则过度探索, 收敛速度慢。

其次, 为验证不同算法求解路径规划问题的优劣, 对比了不同算法在实例场景路径规划模型求解性能。表 6 为 7 种算法在运行 10 次后的最优适应度、平均适应度及适应度标准差; 同时, 图 5 给出了各算法路径规划的收敛曲线。

从表 6 和图 5 对比结果可以看出, AIDBO 算法在最优适应度、平均适应度及收敛性能上均表现最好, 其中, 最优适应度值和平均适应度值分别为 2.984 和 3.224。相较于 WOA、DBO 和 IDBO 算法, AIDBO 算法的平均适应度分别优化了 24.30%、10.59% 和 9.82%, 最优适应度分别优化了 20.34%、11.51%、8.24%。与 WOA 和 DBO 算法相比, IDBO 算法和本文提出的 3 种改进策略算法在适应度上均有所提升, 特别是 DBO-3 算法, 这说明融合改进策略的蜣螂在跳出局部最优陷阱方面有一定优势。在运行时间上, 3 种改进策略算法和 AIDBO 算

表 6　算法性能对比

Table 6　Algorithm performance comparison

算法	最优适应度值	平均适应度值	标准差	平均运行时间/s
WOA	3.746	4.259	0.415	28.7
DBO	3.372	3.606	0.330	25.2
IDBO	3.252	3.575	0.285	26.9
DBO-1	3.275	3.523	0.367	25.8
DBO-2	3.198	3.512	0.325	26.5
DBO-3	3.102	3.401	0.298	26.3
AIDBO	2.984	3.224	0.251	26.5

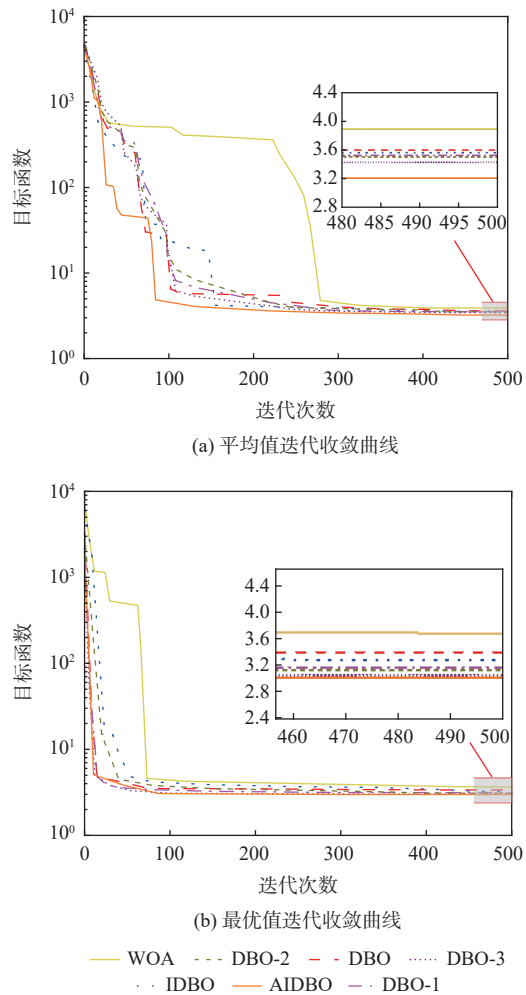

图 5　7 种算法路径规划收敛曲线

Fig. 5　Convergence curves of seven algorithms for path planning

法求解时间接近, 但均小于 WOA 算法, 这表明尽管 AIDBO 算法引入多种改进策略, 但未导致运行时间的显著增加。同时, AIDBO 算法的适应度标准差远低于其他算法, 表明其优化过程更加稳定, 能够在多次运行中保持较高的一致性和可靠性。因此, AIDBO 算法综合性能均优于其他算法, 表现出较强的全局搜索能力和收敛效率, 不仅提升了跳出局部最优的能力, 还改善了收敛精度和寻优稳定

性，验证了其在解决复杂优化问题中的应用潜力。

图 6 给出了 WOA、DBO、IDBO、AIDBO 这 4 种算法求解的无人机三维路径轨迹结果，表 7 给出了 4 种算法求解的路径规划子目标函数中每架无人机的具体飞行时间、风险代价和能耗结果。从图 6 中看出，AIDBO 算法在无人机路径规划中展现出最优的综合性能，其在 5 架无人机（UAV1～UAV5）的飞行时间上均最短，总的风险代价值（0.486）和总的能耗代价值（1.044×10^5 kJ）整体低于其他对比算法。结果表明，AIDBO 算法在全局搜索能力和局部优化能力之间实现了良好的平衡，能够有效避免陷入局部最优解。相比其他 3 种算法，AIDBO 算法表现出更高的稳定性和优越性，能够在复杂地形条件下规划出更优的路径。

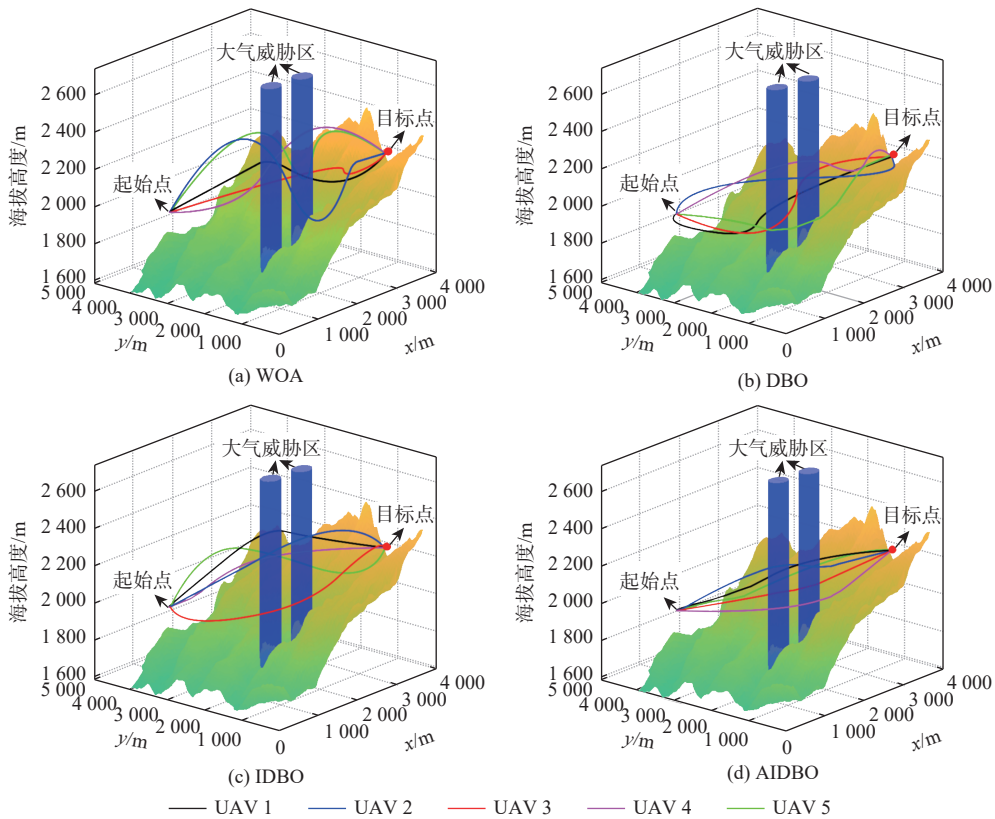

图 6 不同算法求解路径规划结果

Fig. 6 Results of path planning solved by different algorithms

表 7 不同算法路径规划结果对比

Table 7 Comparison of path planning results of different algorithms

算法	UAV	飞行时间/s	风险代价	能耗代价/10^4 kJ
WOA	UAV1	309.996	0.810	2.29
	UAV2	442.991	0.130	2.67
	UAV3	333.989	0.120	2.54
	UAV4	369.994	0.130	2.31
	UAV5	366.980	0.120	2.32
DBO	UAV1	346.398	0.125	2.40
	UAV2	320.627	0.116	2.39
	UAV3	306.521	0.108	2.42
	UAV4	314.929	0.113	2.51
	UAV5	334.831	0.122	2.39
IDBO	UAV1	306.998	0.102	2.13
	UAV2	305.944	0.103	2.19
	UAV3	312.998	0.099	2.23
	UAV4	333.909	0.107	2.22
	UAV5	317.997	0.108	2.11
AIDBO	UAV1	280.997	0.094	2.08
	UAV2	276.812	0.096	2.10
	UAV3	273.999	0.095	2.04
	UAV4	302.994	0.103	2.13
	UAV5	296.976	0.098	2.09

3.2 结果分析讨论

为探讨不同环境因素对无人机路径选择及能耗的影响及进一步验证本文方法的有效性，通过改变海拔、风速风向等参数，探究各因素影响。

3.2.1 海拔影响

为对比分析不同海拔对无人机飞行时间和能耗的影响，考虑平均海拔 340 m 和 2 400 m 代表平原和高原山区，同时固定西北风 8 m/s 环境风参数，其余风险参数不变的情况下，在较高海拔飞行会大幅增加能耗，而飞行时间在不同海拔条件下差异不显著，不同海拔下无人机路径规划结果如表 8 所示，而无人机三维路径轨迹如图 7 所示。

根据对比结果可以发现，海拔对无人机飞行时间影响较小，但对能耗的影响较为显著。根据表 8 所示，在海拔 340 m 和 2 400 m 环境下，无人机最长飞行时间分别为 301.982 s 和 304.993 s，最大飞行能耗代价分别为 1.34×10^4 kJ 和 2.13×10^4 kJ。因此，相

表 8　不同海拔路径规划结果对比

Table 8　Comparison of path planning results at different altitudes

平均海拔/m	UAV	飞行时间/s	风险代价	能耗代价/10^4 kJ
340	UAV1	281.984	0.097	1.31
	UAV2	301.982	0.103	1.29
	UAV3	283.999	0.096	1.29
	UAV4	279.998	0.095	1.34
	UAV5	299.997	0.098	1.29
2 400	UAV1	280.997	0.094	2.08
	UAV2	276.812	0.096	2.10
	UAV3	273.999	0.095	2.04
	UAV4	304.993	0.103	2.13
	UAV5	296.976	0.098	2.09

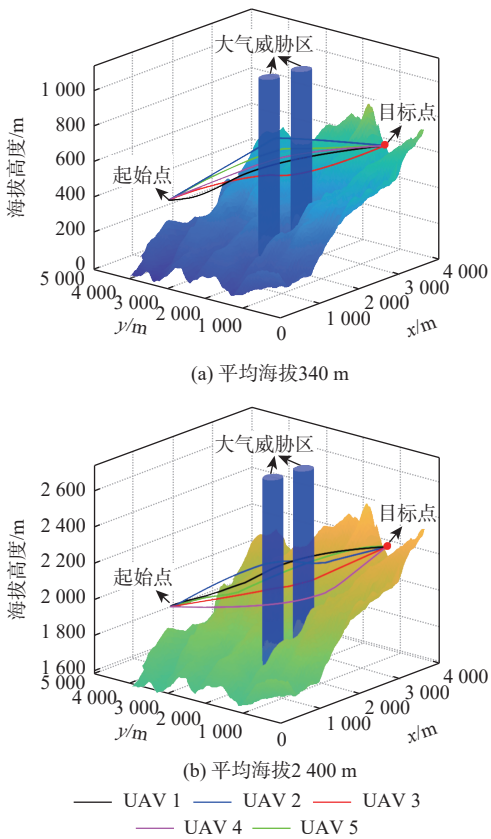

图 7　不同海拔路径规划结果

Fig. 7　Results of path planning by different altitudes

对于平原环境而言, 在高海拔环境下, 无人机最长飞行时间略微增加了 0.997%, 能耗增加了 58.96%。这一结果表明, 在高海拔稀薄空气条件下, 动力系统需要更高的功率输出以维持飞行。因此, 在高原环境下进行灭火救援时, 需要重视无人机的能耗保障, 对其能源管理进行优化。

3.2.2　风速风向影响

针对风影响下的无人机路径规划问题, 考虑表 9 中参数设置, 探究不同风速风向对无人机能耗的影响。

表 9　风速风向影响参数设置

Table 9　Parameter settings for investigating impact of wind speed and direction

工况	平均海拔/m	风速/(m·s^{-1})	风向
1	2 400	8	西北风(顺风)
2	2 400	8	东南风(逆风)
3	2 400	10	西北风(顺风)
4	2 400	10	东南风(逆风)

表 10 为不同风速和风向下无人机路径规划的各子目标函数中每架无人机的具体飞行时间、风险代价和能耗结果, 图 8 给出了不同风速和风向下无人机三维路径轨迹结果。通过结果对比分析可知, 随着工况条件的变化(工况 1～工况 4), 无人机集群的飞行风险代价显著上升, 尤其在工况 3 和工况 4 中, 部分无人机风险代价增至 0.237 以上, 最高达 0.91; 同时, 5 架无人机的总能耗代价也从工况 1 的 1.044×10^5 kJ 逐步上升至工况 4 的 1.265×10^5 kJ。结果表明, 风速与风向的恶化会明显增加路径规划的风险与能耗, 其中, 工况 1 在安全性与能耗方面均表现最优。由图 8 可以看出, 风速和风向对无人机任务执行性能的影响具有一定规律性和显著性, 顺风条件下飞行时间短于逆风, 但两者航线差异较

表 10　不同风速风向路径规划结果对比

Table 10　Comparison of path planning results at different wind speed and direction paths

工况	UAV	飞行时间/s	风险代价	能耗代价/10^4 kJ	总能耗代价/10^5 kJ
1	UAV1	280.997	0.094	2.08	1.044
	UAV2	276.812	0.096	2.10	
	UAV3	273.999	0.095	2.04	
	UAV4	302.994	0.103	2.13	
	UAV5	296.976	0.098	2.09	
2	UAV1	284.953	0.094	2.25	1.122
	UAV2	286.330	0.099	2.25	
	UAV3	278.997	0.097	2.20	
	UAV4	304.996	0.103	2.29	
	UAV5	291.997	0.096	2.23	
3	UAV1	294.979	0.104	2.38	1.181
	UAV2	279.958	0.103	2.21	
	UAV3	281.996	0.237	2.49	
	UAV4	305.943	0.446	2.31	
	UAV5	285.998	0.756	2.42	
4	UAV1	289.959	0.334	2.52	1.265
	UAV2	304.989	0.719	2.46	
	UAV3	284.990	0.099	2.48	
	UAV4	322.988	0.839	2.75	
	UAV5	287.916	0.910	2.44	

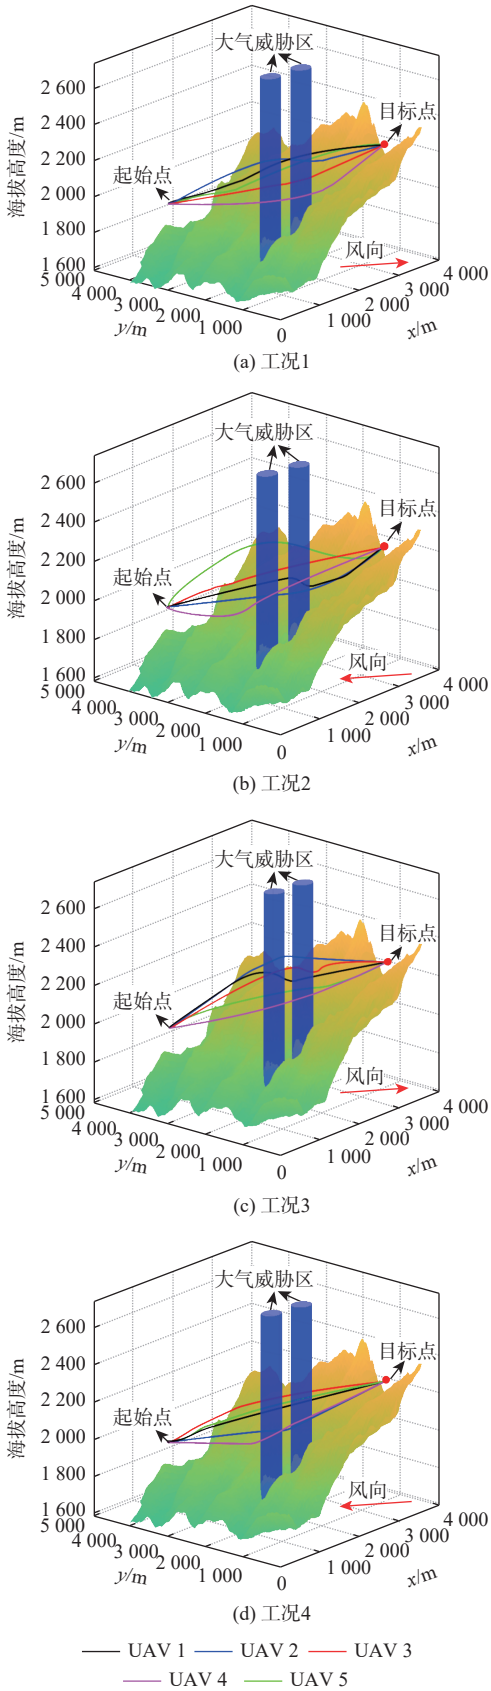

图 8 不同风速风向工况下路径规划结果

Fig. 8 Results of path planning by different wind speed and direction conditions

小。在 8 m/s 风速下，逆风比顺风无人机总能耗代价增加 7.47%，而在 10 m/s 风速下，逆风比顺风无人机总能耗代价增加 7.11%。能耗的提升主要归因于逆风条件下无人机需要额外的功率来克服气流阻力，从而导致更高的能耗。

在相同逆风方向下，不同风速对无人机飞行时间和能耗的影响尤为显著。根据表 10 所示，风速 8 m/s 时无人机最大飞行时间为 304.996 s，飞行总能耗代价为 1.122×10^5 kJ，而风速 10 m/s 时分别为 322.988 s 和 1.265×10^5 kJ。因此，相对于 8 m/s 风速，10 m/s 风速下，最大飞行时间和飞行总能耗代价分别增加了 5.90% 和 12.75%。这种差异表明，高风速环境会加剧无人机任务执行的复杂性，不仅影响任务完成时间，还显著提升了能耗成本，尤其是在长距离任务中，这种累积效应更为明显。此外，风速和风向不仅影响无人机的能耗和时间，还间接提高了风险成本。逆风条件下，飞行时间延长，使无人机在高风险区域的暴露时间增加，从而加大任务风险。

4 结 论

本文针对高原森林复杂环境下无人机路径规划问题，考虑海拔、环境风和威胁区等因素，构建了以最小飞行时间、风险代价及能耗为目标函数的多无人机路径规划模型，并提出 AIDBO 算法进行求解。主要结论如下：

1）实例算法验证中，相较于 WOA、DBO 和 IDBO 算法，AIDBO 算法的平均适应度分别优化了 24.30%、10.59% 和 9.82%，最优适应度分别优化了 20.34%、11.51%、8.24%；证明 AIDBO 具有更好的鲁棒性，能够快速且稳定地达到最优解。

2）海拔主要对无人机能耗影响显著，与平均海拔 340 m 环境相比，平均海拔 2 400 m 时无人机最长飞行时间增加了 0.997%，能耗增加了 58.96%。

3）风速和风向对无人机飞行时间和能耗成本均产生影响。在 8 m/s 风速下，逆风比顺风能耗增加 7.47%；而 10 m/s 风速条件下，最大飞行时间相较于 8 m/s 风速增加了 5.90%，能耗增加幅度达到 12.75%。

由于高原森林环境复杂、影响因素较多，使得本文研究仍存在一些不足。未来研究可进一步考虑动态风场环境影响且无人机动力学性能受环境影响动态变化，采用实时动态调整飞行策略提供鲁棒性。同时，针对无人机失效和碰撞风险，设计更加安全的路径调整策略。

参考文献（References）

[1] 潘卫军, 黄园晶, 骆晨, 等. 森林火灾多机型救援三维航迹规划[J].

科学技术与工程, 2023, 23(23): 10152-10159.
Pan W J, Huang Y J, Luo C, et al. 3D route planning for forest fire rescue by multi-aircraft[J]. Science Technology and Engineering, 2023, 23(23): 10152-10159(in Chinese).

[2] 郑玉斌, 李新凯, 孟月, 等. 基于 GRU-MAPPO 的多无人机协同追捕方法[J/OL]. 北京航空航天大学学报, 2025(2025-07-02)[2025-11-19]. https://link.cnki.net/urlid/11.2625.V.20250702.1040.001.
Zheng Y B, Li X K, Meng Y, et al. Multi-UAV cooperative pursuit method based on GRU-MAPPO[J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 2025(2025-07-02) [2025-11-19]. https://link.cnki.net/urlid/11.2625.V.20250702.1040.001(in Chinese).

[3] 滕菲, 王迎春, 姚永辉, 等. 基于深度强化学习的无人机动态避障规划[J/OL]. 北京航空航天大学学报, 2025(2025-05-23)[2025-11-19]. https://link.cnki.net/urlid/11.2625.V.20250523.1437.002.
Teng F, Wang Y C, Yao Y H, et al. UAV dynamic obstacle avoidance planning based on deep reinforcement learning[J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 2025(2025-05-23)[2025-11-19]. https://link.cnki.net/urlid/11.2625.V.20250523.1437.002(in Chinses).

[4] 朱元军, 李妍, 张学军, 等. 基于风险约束的城市空域无人机安全路径规划[J/OL]. 北京航空航天大学学报, 2025(2025-03-27)[2025-11-19]. https://link.cnki.net/urlid/11.2625.V.20250327.1510.001.
Zhu Y J, Li Y, Zhang X J, et al. Risk-constrained safe path planning for unmanned aerial vehicles in urban airspace[J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 2025(2025-03-27)[2025-11-19]. https://link.cnki.net/urlid/11.2625.V.20250327.1510.001(in Chinese).

[5] 朱弥雪. 基于无人机的林火检测研究[D]. 呼和浩特: 内蒙古工业大学, 2023.
Zhu M X. Research on UAV-based forest fire detection[D]. Hohhot: Inner Mongolia University of Tehchnology, 2023(in Chinese).

[6] 余顺金, 冯建辉, 秦建明, 等. 基于改进人工势场的无人飞行器三维路径规划[J]. 云南电力技术, 2024, 52(3): 64-68.
Yu S J, Feng J H, Qin J M, et al. Three-dimensional path planning of UAV based on improved artificial potential field[J]. Yunnan Electric Power, 2024, 52(3): 64-68(in Chinese).

[7] 李锐君, 董素鸽. 基于粒子群算法的无人机灭火路径规划仿真[J]. 计算机仿真, 2023, 40(9): 43-48.
Li R J, Dong S G. Simulation of UAV fire extinguishing path planning based on particle swarm optimization algorithm[J]. Computer Simulation, 2023, 40(9): 43-48(in Chinese).

[8] Gao J F, Zheng Y, Ni K, et al. Fast path planning for firefighting UAV based on A-star algorithm[J]. Journal of Physics: Conference Series, 2021, 2029(1): 012103.

[9] Demir K, Tumen V, Kosunalp S, et al. A deep reinforcement learning algorithm for trajectory planning of swarm UAV fulfilling wildfire reconnaissance[J]. Electronics, 2024, 13(13): 2568.

[10] Radmanesh M, Sharma B, Kumar M, et al. PDE solution to UAV/UGV trajectory planning problem by spatio-temporal estimation during wildfires[J]. Chinese Journal of Aeronautics, 2021, 34(5): 601-616.

[11] Aggarwal R, Soderlund A, Kumar M, et al. Risk-aware path planning for unmanned aerial systems in a spreading wildfire[J]. Journal of Guidance, Control, and Dynamics, 2022, 45(9): 1692-1708.

[12] Çoğay S, Seçinti G. Phoenix: aerial monitoring for fighting wildfires[J]. Drones, 2023, 7(1): 19.

[13] Hasan Z, Kumar S, Patel V, et al. UAV Path planning for wildfires-sustainably fighting wildfires with automated path planning for UAVs: NASA/TM—20220015156[R]. Washington, D. C. : NASA, 2022.

[14] Xu Y Q, Li J M, Zhang F Q. A UAV-based forest fire patrol path planning strategy[J]. Forests, 2022, 13(11): 1952.

[15] 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.

[16] Lyu L X, Jiang H, Yang F. Improved dung beetle optimizer algorithm with multi-strategy for global optimization and UAV 3D path planning[J]. IEEE Access, 2024, 12: 69240-69257.

[17] Chen Q, Wang Y J, Sun Y F. An improved dung beetle optimizer for UAV 3D path planning[J]. The Journal of Supercomputing, 2024, 80(18): 26537-26567.

[18] Zhu F, Li G S, Tang H, et al. Dung beetle optimization algorithm based on quantum computing and multi-strategy fusion for solving engineering problems[J]. Expert Systems with Applications, 2024, 236: 121219.

[19] Shen Q W, Zhang D M, Xie M S, et al. Multi-strategy enhanced dung beetle optimizer and its application in three-dimensional UAV path planning[J]. Symmetry, 2023, 15(7): 1432.

[20] 刘微, 任腾腾, 韩广雨, 等. 多策略改进蜣螂优化算法及其应用[J]. 电子测量技术, 2024, 47(12): 109-121.
Liu W, Ren T T, Han G Y, et al. Multi strategy improvement of dung beetle optimization algorithm and its application[J]. Electronic Measurement Technology, 2024, 47(12): 109-121(in Chinese).

[21] 李晓萌. 高原狭窄区域下多无人机协同飞行控制[D]. 南京: 南京航空航天大学, 2019.
Li X M. Cooperative flight control of multi-UAVs in narrow plateau area[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2019(in Chinese).

[22] Zeng Y, Xu J, Zhang R. Energy minimization for wireless communication with rotary-wing UAV[J]. IEEE Transactions on Wireless Communications, 2019, 18(4): 2329-2345.

Multi-UAV path planning for forest fire-fighting in plateau based on adaptive improved dung beetle optimization algorithm

ZHU Pei*，LYU Xiaolong，CHEN Kaisen，SONG Rui，ZHANG Jiangao，SHAO Quan

(College of Civil Aviation，Nanjing University of Aeronautics and Astronautics，Nanjing 211106，China)

Abstract：Aiming at the problem of UAV fire-fighting and rescue path planning in the complex environment of plateau forest, a multi-UAV path planning method based on an adaptive improved dung beetle optimization (AIDBO) algorithm was proposed. Based on the digital elevation model (DEM) data, a three-dimensional geospatial model of the plateau forest and mountainous area was established. Considering the influence of complex terrain, environmental wind, altitude and other factors, a multi-UAV path planning model under multiple constraints was established, taking the minimum flight time, risk cost and energy consumption as the objective function. Chaotic mapping and reverse learning optimize the population initialization, the whale optimization algorithm (WOA) introduces the spiral search strategy to enhance the position update mechanism, and adaptive Cauchy mutation improves the population's capacity to eliminate local optima. An AIDBO algorithm is proposed to solve the problem. The results showed that the average fitness of AIDBO was 10.59% and 9.82% higher than that of the original dung beetle optimization (DBO) algorithm and the improved dung beetle optimization (IDBO) algorithm, respectively. Compared with a 340 m plain environment, the maximum flight time of the UAV in a 2 400 m altitude environment is slightly increased by 0.997%, while the energy consumption is increased by 58.96%. At the same time, the wind direction and speed will also have a certain impact on the flight time and energy consumption. In addition to providing decision assistance for UAV firefighting and rescue scheduling in the plateau forests, the adaptive improved dung beetle algorithm presented in this research may greatly optimize the multi-UAV path in the plateau forests.

Keywords：multi-UAV；path planning；plateau forest；fire-fighting and rescue；improved dung beetle optimization algorithm；adaptive

Received：2025-12-08；**Accepted**：2026-03-06；**Published Online**：2026-04-02 09：01

URL：link.cnki.net/urlid/11.2625.V.20260401.0915.002

Foundation items：National Natural Science Foundation of China (52202416); Opening Fund of Key Laboratory of Civil Aviation Emergency Science & Technology (NJ2022022)

* **Corresponding author**. E-mail：zpei@nuaa.edu.cn