

DOI:10.19651/j.cnki.emt.2518507

基于改进冠豪猪算法山地环境无人机航迹规划*

李尧¹ 黄大庆² 殷奇缘¹ 徐文校¹ 王嘉瑞³(1.南京航空航天大学电子信息工程学院 南京 210016; 2.南京航空航天大学无人机研究院 南京 210016;
3.南京航空航天大学民航学院 南京 210016)

摘要: 现代战争需求推动了多无人机协同在军事领域的应用,为解决面临雷达、火炮等多威胁山地环境下的多无人机航迹规划问题,提出了一种改进的冠豪猪优化算法(BCPO)。对于种群缺乏多样性的问题,引入了结合反向学习的佳点集初始化,加大算法的遍历程度;针对冠豪猪算法(CPO)的开发阶段提出了基于自适应小扰动的螺旋搜索策略,进一步激发算法的全局搜索性能;针对CPO算法的探索阶段,引入了基于最优随机位置的变异三角形游走策略,有助于提高算法局部收敛效率;提出融合动态因子的莱维飞行策略,帮助算法在全局搜索和局部寻优间寻求更好的平衡。在CEC2017测试函数上进行仿真对比,验证BCPO算法具有优秀的收敛速率和精度;通过模拟山地环境进行仿真实验,表明BCPO算法相比CPO、GWO、WOA算法平均提升性能为8.834%、5.776%、21.828%,且算法稳定性有了大幅提升,该方法在面临复杂场景的多无人机航迹规划问题中具有较好的应用价值。

关键词: 冠豪猪优化器;佳点集初始化;螺旋搜索;三角形游走;莱维飞行

中图分类号: TP18;TN911;TN391 **文献标识码:** A **国家标准学科分类代码:** 510.1050

UAV trajectory planning in mountainous environment based on improved crowned porcupine algorithm

Li Yao¹ Huang Daqing² Yin Qiyuan¹ Xu Wenxiao¹ Wang Jiarui³(1. School of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;
2. Institute of Unmanned Aerial Vehicle Research, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;
3. Civil Aviation College, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: The demand of modern warfare has propelled the application of multi-UAV collaboration in the military field. To address the problem of trajectory planning for multiple UAVs in a multi-threat mountainous environment with radar, artillery, and other threats, an improved Crested Porcupine Optimizer (CPO) algorithm, namely BCPO, is proposed. To tackle the issue of population diversity, the algorithm incorporates an initialization method combining opposition-based learning and good-point set initialization, which enhances the algorithm's traversal capability. For the development phase of the CPO algorithm, a spiral search strategy based on adaptive small perturbations is introduced to further boost the global search performance. In the exploration phase of the CPO algorithm, a mutation triangle walk strategy based on the optimal random position is added to improve the local convergence efficiency. Additionally, a Lévy flight strategy with dynamic factors is proposed to help the algorithm achieve a better balance between global search and local optimization. Simulations on the CEC2017 test functions demonstrate that the BCPO algorithm has excellent convergence speed and accuracy. In a simulated mountainous environment, the BCPO algorithm shows an average performance improvement of 8.834%, 5.776%, and 21.828% compared to the CPO, GWO and WOA, respectively. Moreover, the stability of the algorithm is significantly enhanced. This method has good application value in solving multi-UAV trajectory planning problems in complex scenarios.

Keywords: crowned porcupine optimizer; good lattice points initialization; spiral search; triangle walk; Lévy flight

0 引言

现代化电子技术日渐趋于完善,无人机在众多领域扮演

了重要角色,如物流运输^[1]、抗震救灾^[2]、电能传输^[3]、电子对抗^[4]等方面。航迹规划技术作为无人机重要技术之一,特别在现代智能化电子信息作战场景下,选择恰当的航迹规划

收稿日期:2025-04-03

* 基金项目:中国高校产学研创新基金(2021ZYA04004)项目资助

技术能够急速准确击中目标、降低能源损耗和时间花费。但是随着任务需求的复杂化、多样化,单一无人机无法胜任完成任务的角色。为了更高效、安全的完成任务,多无人机组成的无人机群的航迹规划算法得到了更加广泛的运用。

无人机航迹规划算法研究价值广阔,主要包含传统启发式算法和群智能算法。传统算法具有代表意义的有 A* 算法^[5]、Dijkstra 算法^[6]、人工势场法^[7]等,然而由于三维空间求解航迹规划问题的运算量巨大,A* 算法无法较好适用^[5];人工势场法在处理航迹规划问题时,又极易陷入局部最优解和目标点不可达问题^[7]。近年来,受到自然界生物行为的启发,众多研究工作者提出了基于仿生行为的智能算法,如蚁群算法(ant colony optimization, ACO)^[8]、灰狼算法(grey wolf optimizer, GWO)^[9]、鲸鱼算法(whale optimization algorithm, WOA)^[10]。但是,没有任何一个算法是完美无缺的,ACO 算法虽然具有正反馈性强,鲁棒性好的优点,但也存在着初期搜索盲目,收敛效率低下等问题^[8];GWO 算法在处理多维度、多约束问题时,搜索速率慢,生成航迹质量差等缺陷^[9],因此,找寻一个收敛速率快、准确度高、适应复杂环境能力强的智能算法成为研究的重要目标。

冠豪猪优化器(crown porcupine optimizer, CPO)是一种利用模拟冠豪猪几种不同防御生理行为的分布式智能算法,其在局部开发方面展现出了卓越的搜索性能^[11],因此,可以利用 CPO 算法出色的收敛速率和较好的搜索能力来解决三维空间中的航迹规划问题。然而 CPO 算法的种群分布过于随机,会对算法的全局搜索能力造成一些困扰,并且其复杂的防御机制模拟和种群调整策略导致计算复杂度较高。研究人员对 CPO 进行了优化与应用,文献[12]在 CPO 算法基础上引入混沌映射,增强多样化种群分布,提高搜索效率;文献[13]将 CPO 算法运用于二维的机器人路径规划,证实了在复杂场景下的可行性。但以上文献均没有改善 CPO 算法存在的动态环境适应不足的缺陷。

本文提出一种改进的冠豪猪算法(better crown porcupine optimizer, BCPO)用来解决 CPO 算法的计算复杂度,适应能力差的问题。引入结合随机学习的佳点集初始化、基于自适应小扰动的螺旋搜索策略、基于最优随机位置的变异三角形游走策略和融合动态因子的莱维飞行策略。将 BCPO 算法与 CPO、麻雀算法(sparrow search algorithm, SSA)^[14]、遗传算法(genetic algorithm, GA)^[15]等多种算法在 CEC2017 测试函数上仿真,在模拟多威胁复杂山地环境下,将 BCPO 算法与 GWO^[9]、WOA^[10]和改进的冠豪猪算法^[16]在三维航迹规划问题上进行对比仿真。

1 多无人机航迹规划问题

假定在一个环境已知的情况下,如图 1 所示。对多无人机系统而言,不仅需要满足单架无人机所具有的路径、转向成本等,还需要满足各无人机之间的协同配合,避免相互

之间发生碰撞。多无人机航迹规划问题可以简述成起始点、终点明确,环境信息已知,威胁障碍物清晰情况下,多无人机采用最小代价到达目标点,同时避免外部碰撞和内部碰撞的问题。

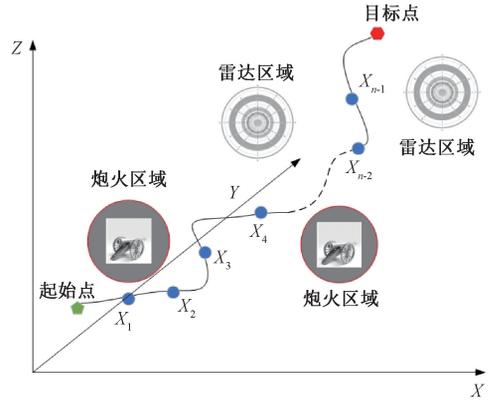


图 1 多威胁环境示意图

Fig. 1 Schematic diagram of a multi-threat environment

1.1 航迹长度成本

无人机的航迹都是由起点、终点以及两者之间的 $N - 2$ 个导航点拟合而来。第 m 架无人机的航迹点 n 坐标 $pos_{m,n}$ 如式(1)所示。

$$pos_{m,n} = (x_{m,n}, y_{m,n}, z_{m,n}) \quad (1)$$

式中: $m = 1, 2, \dots, UAV_{num}, n = 1, 2, \dots, N - 2, UAV_{num}$ 代表无人机数量。则任意一架无人机的完整航迹如式(2)所示。

$$\begin{cases} L = \sum_{n=1}^N L_n \\ L_n = \sqrt{(x_{m,n} - x_{m,n+1})^2 + (y_{m,n} - y_{m,n+1})^2 + (z_{m,n} - z_{m,n+1})^2} \end{cases} \quad (2)$$

式中: L_n 表示第 n 段的航迹长度, N 为导航点个数则总的无人机群的航迹成本 F_L 如式(3)所示。

$$F_L = \sum_{m=1}^{UAV_{num}} \sum_{n=1}^N L_{m,n} \quad (3)$$

式中: $L_{m,n}$ 表示第 m 架无人机的第 n 段的航迹长度。

1.2 航迹高度成本

为了保障多无人机系统航行的安全性,所有无人机必须要在一个限定的范围空间中飞行。设置航行高度成本 $F_{H,n}$, 如式(4)所示。

$$F_{H,n} = \sum_{n=1}^{N-2} \begin{cases} \frac{|2z_n - z_{max} - z_{min}|}{(z_{max} + z_{min})}, & z_{min} < z_n < z_{max} \\ 1, & \text{其他} \end{cases} \quad (4)$$

式中: z_{max} 和 z_{min} 为给定的最大最小航行高度, z_n 是第 n 个航迹点对应的高度信息。

1.3 炮火及雷达探测威胁

在实际战场环境,无人机群会遭受来自外界的威胁,例

如炮火打击、雷达干扰等,在航迹规划时应当予以避开。当无人机群相距炮火的中心位置越近,其遭受打击的概率就越大;同样的,机群中任何一架无人机都应该远离雷达侦察范围,以免被发现。雷达侦察成本 F_R 和炮火覆盖威胁成本 F_A 模型分别如式(5)、(6)所示。

$$F_R = \begin{cases} (J/d_r)^4, & d_r < R_{t\max} \\ 0, & d_r \geq R_{t\max} \end{cases}$$

$$d_r = \sqrt{(x_{m,n} - x_R)^2 + (y_{m,n} - y_R)^2 + (z_{m,n} - z_R)^2} \quad (5)$$

$$F_A = \begin{cases} (R_{ta})^4 / ((R_{ta})^4 + (d_a)^4), & d_a \leq R_{ta\max} \\ 0, & d_a \geq R_{ta\max} \end{cases} \quad (6)$$

式中: d_r 表示无人机和雷达信号中心距离,雷达中心位置为 (x_R, y_R, z_R) , $R_{t\max}$ 是雷达作用范围的最大半径, J 为威胁程度常量, d_a 是无人机与炮火范围中心的距离, R_{ta} 是炮火覆盖半径, $R_{ta\max}$ 是炮火覆盖范围的最大半径。当 d_r 和 d_a 越小,其对应的成本就越大,则说明危险系数高。

1.4 单机约束成本和多机协同成本

对于任何一架无人机来说,航行转向的角度都需要在合适的区间内,过高或过低都会造成无人机坠毁。航行过程中,当无人机进行姿态切换时,会保持一个稳定过程,这个过程中所经过的航迹段称为最小直线航迹段。另外无人机的飞行空间也需要禁止驶入一些禁飞场所。因此,姿态约束 F_E 、最短航迹段约束 F_T 和禁飞区约束 F_{NF} 如式(7)~(11)所示。

$$F_E = \sum_{n=1}^{N-2} f_n + \sum_{n=1}^{N-1} (\varphi_n - \varphi_{n-1}) \quad (7)$$

$$f_n = \arctan\left(\frac{\|L_n L_{n+1}\|}{L_n L_{n+1}}\right) \quad (8)$$

$$\varphi_n = \arctan\left(\frac{z_{n+1} - z_n}{\sqrt{(x_{n+1} - x_n)^2 + (y_{n+1} - y_n)^2}}\right) \quad (9)$$

$$F_T = \begin{cases} 1, & L_n > L_{\min} \\ 0, & L_n < L_{\min} \end{cases} \quad (10)$$

$$F_{NF} = \begin{cases} 1, & x_{\min}^{NF} \leq x_n \leq x_{\max}^{NF}, y_{\min}^{NF} \leq y_n \leq y_{\max}^{NF} \\ 0, & \text{其他} \end{cases} \quad (11)$$

式中: ϕ_n, φ_n 为无人机飞行过程中处于第 n 段路径所对应的偏转角度和俯仰角度, L_{\min} 为受限于无人机自身的最小航迹距离, $x_{\min}^{NF}, x_{\max}^{NF}, y_{\min}^{NF}, y_{\max}^{NF}$ 是不可航行区域的界限。

多无人机航迹规划问题,不单需要考虑外部避障,还需要无人机之间的协同处理,即时间和空间协同。时间协同是无人机群在任务需求下,各机抵达最终点的时间必须符合某种特殊条件,寻求各机同步抵达终点。但现实生活中,无人机速度是动态变化的,抵达终点的时间无法实现完全同步,若各机抵达终点的时间区间存在交集,便认为各机可同步抵达终点,由此来设置时间约束成本 F_{Time} ,如式(12)所示。

$$F_{Time} = \begin{cases} 0, & t_{\min} < t_n < t_{\max} \\ 1, & \text{其他} \end{cases} \quad (12)$$

$$t_{\min} = \frac{L_n}{v_{\max}}, t_{\max} = \frac{L_n}{v_{\min}}$$

式中: t_{\min} 和 t_{\max} 为无人机飞行的最长时间和最短时间, v_{\min} 和 v_{\max} 为最小最大速度。

空间协同是指在无人机在各自飞行航迹上,无人机应当将自身的节点坐标进行比较,要求无人机之间距离应当大于安全距离。空间协同成本 F_s 如式(13)所示。

$$F_s = \begin{cases} 0, & d_m < d_{save} \\ 1, & \text{其他} \end{cases} \quad (13)$$

式中: d_m 为某架无人机航迹点 n 与其他无人机当前时间之间距离; d_{save} 设置为安全距离。

对其上所有函数进行线性权重综合,构建多无人机航迹规划问题目标函数 F_C ,如式(14)所示。

$$F_C = \omega_a F_L + \omega_b F_{H,n} + \omega_c F_E + \omega_d F_{NF} + \omega_e F_{Time} + \omega_f F \quad (14)$$

式中: $\omega_a, \omega_b, \omega_c, \omega_d, \omega_e, \omega_f$ 为各自的权重系数,当 F_C 取得最小值时,得到的航迹即为最优航迹。

2 BCPO 算法

2.1 CPO 算法

原始 CPO 算法中,通过模拟冠豪猪的不同防御行为来进行模拟迭代位置更新。CPO 算法虽然具有较好的鲁棒性和不错的搜索性,但在一些方面仍然存在着不足之处:

1) 种群初始化过于随机,可能导致种群分布的不够均匀,无法很好的遍历全局;

2) 随着算法进入迭代后期,CPO 的各候选解行为趋于同化,会增加算法陷入局部最优解的风险。

针对以上问题,本文将在初始化阶段、开发和探索阶段分别对 CPO 算法进行优化。

2.2 BCPO 算法的改进策略

1) 结合随机学习的佳点集初始化

传统 CPO 算法同大多数智能算法一样,采用生成种群方法是随机的,因此会使得种群在整个搜索空间内分布不充分,不确定性因素较高。为了提高分布的遍历性,本文提出了结合反向学习的佳点集初始化方法来增强算法的全局搜索能力。

佳点集是一种有关数论的方法^[17],为此本文先简要介绍一些相关理论:

假设在 D 维的欧式空间中存在一个单位立方体 D_s ,其内存在点集:

$$P_n(k) = \{(\{r_1^{(n)} \cdot k\}), \dots, \{r_s^{(n)} \cdot k\}, 1 < k < n'\} \quad (15)$$

式中: $r_i \in D_s, n'$ 为样本数量, $P_n(k)$ 为佳点值, $r_i (1 \leq i \leq s)$ 为佳点。

由佳点集生成的初始化种群如式(16)所示。

$$x_n(k) = (ub - lb)\{p_n(k)\} + lb \quad (16)$$

反向学习作为在智能算法中被广泛运用的一种随机种群方法,在生成当前种群解的基础上再生成一次反向解来提高种群遍历范围,强化多样性。

随机反向学习如式(17)所示。

$$x_r = ub + lb - v_{rand} \times x_n \quad (17)$$

式中: v_{rand} 为 0~1 的随机向量。

综上,初始种群的生成方式如式(18)所示。

$$x'_n = ub + lb - v_{rand} \times x_n(k) \quad (18)$$

两者二维的时序对比如图 2 所示。

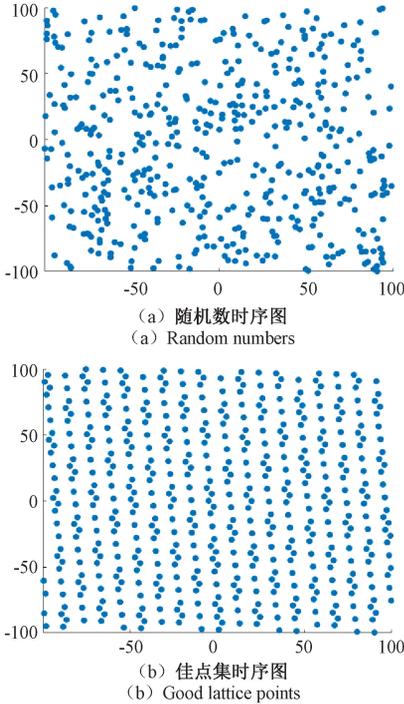


图 2 不同初始化方式时序比较图

Fig. 2 Comparison chart of time series with different initialization methods

由图 2(b)可以看出,相较于随机数初始化(图 2(a)),结合反向学习的佳点集方法的时序在空间排布均匀。

2) 基于自适应小扰动的螺旋搜索策略

在 CPO 算法中,在第一阶段的防守策略时,使用随机值策略来决定捕食者是否会靠近冠豪猪。如式(19)所示。

$$\begin{cases} x_i^{t+1} = x_i^t + \tau_1 \times |2\tau_2 \times x_{CP}^t - y_i^t| \\ y_i^t = \frac{x_i^t + x_r^t}{2} \end{cases} \quad (19)$$

式中: x_i^{t+1} 代表下一次迭代时所对应的解, x_{CP}^t 代表全局最优解, y_i^t 为当前解 x_i^t 和种群内任意解 x_r^t 所产生的向量, τ_1 是满足正态分布随机数, τ_2 是一个随机常量,范围在 0~1 之间。

虽然此策略体现了算法不错的全局搜索性,但算法随机性过大,个体间也无信息交流,减缓了算法收敛速率。在

WOA 算法中,鲸鱼围捕猎物会将自身位置与猎物位置联动,进行螺旋走位,实现位置更新,其数学模型如式(20)所示。

$$x(t+1) = D^* \cdot e^{bl} \cdot \cos(2\pi l) + x^*(t) \quad (20)$$

$$D^* = |x^*(t) - x(t)|$$

式中: $x(t+1)$ 表示第 $t+1$ 个体, $x^*(t)$ 表示全局最优个体, D^* 表示第 t 个体到最佳个体间的距离, b 是定义螺旋形状的常数, l 为随机变量,范围为 $-1 \sim 1$ 。

但明显的缺陷在于算法的全局搜索能力会受到 b 的影响,本文提出了基于自适应小扰动的螺旋搜索策略,线性、变螺旋和带小扰动的非线性变螺旋三者变化如图 3 所示。

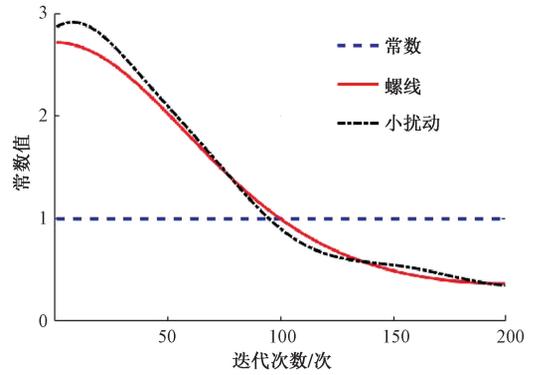


图 3 不同参数下的螺旋搜索曲线模型图

Fig. 3 Schematic diagram of spiral search curves under different parameters

将线性的变化转化为带有小扰动的非线性变螺旋轨迹,一方面在线性基础上扩大了算法的区域探索性,提高算法的多样性,增强全局搜索能力;另一方面又减少了使用变螺旋参数改进后,算法后期因收敛过快陷入局部最优解的风险,如式(21)、(22)所示。

$$\begin{cases} x(t+1) = D^* \cdot e^{f(\frac{t}{T_{max}})t} \cdot \cos(2\pi l) + x^*(t) \\ D^* = |x^*(t) - x(t)| \end{cases} \quad (21)$$

$$f(t/T_{max}) = (1 - \frac{t}{T_{max}})^2 + 0.1 \sin(\frac{3\pi t}{T_{max}}) \quad (22)$$

因此,冠豪猪第一阶段防御策略位置更新如式(23)所示。

$$\begin{cases} x_i^{t+1} = x_i^t + e^{f(\frac{t}{T_{max}})t} \cdot \cos(2\pi l) \cdot \tau_1 \cdot \\ |2 \cdot \tau_2 \cdot x_{CP}^t - y_i^t| \end{cases} \quad (23)$$

3) 基于最优随机位置的变异三角形游走策略

传统 CPO 算法中,当算法迭代进入后期稳定时,种群中的剩余个体都会朝着最佳个体靠拢,算出的函数适应度值越近乎稳定,造成搜索暂停,陷入局部最优。为了解决这一问题,本文受三角形游走策略的思想,当种群在靠近最优解位置时,也会同步在其周围进行游走,能够在一定限度的加大局部寻优能力,其数学模型如式(24)所示。

$$\begin{cases} \vec{L}_1 = x_i^t - x_j^t \\ \vec{L}_2 = \sigma_1 \cdot \vec{L}_1 \\ \beta = 2\pi\sigma_2 \\ P = \vec{L}_1^2 + \vec{L}_2^2 - 2\vec{L}_1 \vec{L}_2 \cos(\beta) \\ x_i^t = x_i^t + r_{rand} \cdot P_d \end{cases} \quad (24)$$

式中: \vec{L}_1 为第 i 个体与第 j 个体之间的距离, \vec{L}_2 为步长, σ_1 和 σ_2 是两个独立的随机向量, β 代表了行走方向, P_d 表示进行游走的个体与最佳位置之间的距离, r_{rand} 是 $0 \sim 1$ 的随机变量。

虽然此方法添加了与最优个体之间的信息交流,但若最优个体在找到目标值前就进入了局部最优时,后续的个体也会陆续掉入局部最优的困境,导致整个算法停滞不前。

为了弥补这个缺陷,强化个体间的信息交流程度,在简单三角形游走基础上,引入最优随机位置的变异策略,如图 4 所示。

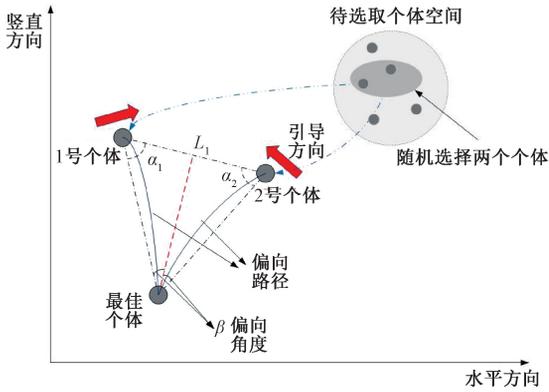


图 4 变异三角形游走策略示意图

Fig. 4 Mutation triangle walk strategy schematic

从适应度值排名前 5 的个体中随机选出 2 个个体(不包括最优个体),以他们之间的距离作为基础步长,然后分别计算这两个个体到最佳个体的距离,由此确定新的行走方向,数学模型如式(25)所示。

$$\begin{cases} x_{pop} = [x_{1best}, x_{2best}, x_{3best}, x_{4best}, x_{5best}] \\ \vec{L}_1^* = |x_{mbest} - x_{nbset}|, m \neq n \neq 1 \\ \vec{L}_2^* = \mu_1 |x_{best} - x_{mbest}| + \mu_2 |x_{best} - x_{nbset}| \\ \beta = 2\pi\sigma \\ P^* = \vec{L}_1^{*2} + \vec{L}_2^{*2} - 2\vec{L}_1^* \vec{L}_2^* \cos(\beta) \\ \mu_1 = \frac{1}{2} \cdot rand() \\ \mu_2 = 1 - \mu_1 \end{cases} \quad (25)$$

式中: x_{pop} 存放的是适应度值排名前 5 的个体, x_{mbest} 和 x_{nbset} 为前 5 个体中任取的两个不同个体, x_{best} 为整个种群最优个体, μ_1 和 μ_2 代表了引导权重, $rand()$ 表示 $0 \sim 1$ 的随机变量。因此,第二、三阶段防御位置更新公式更新为:

$$x_i^t = x_i^t + rand() \cdot P^* \quad (26)$$

4) 融合动态因子的莱维飞行策略

莱维飞行是一种被广泛使用的优化方法,通过进行随机游走从而提升算法的性能,莱维飞行数学模型如式(27)所示。

$$Levy = \frac{\mu_c}{|\nu_c|^{1/\beta_c}} \quad (27)$$

式中: μ_c, ν_c 均服从正态分布的随机向量。

$$\begin{cases} \sigma_{\mu_c} = \frac{\Gamma(1 + \beta_c) \sin(\frac{\pi\beta_c}{2})}{2^{(\beta_c-1)/2} \Gamma(\frac{1+\beta_c}{2}) \beta_c} \\ \sigma_{\nu_c} = 1 \end{cases} \quad (28)$$

式中: Γ 是伽马函数, $\beta_c = 1.5$ 。

但是对于迭代后期的种群来说,Levy 飞行的步长过长会影响算法的收敛能力,而过短又会在算法前期导致收敛速度下降。为了提高算法的收敛精度而又不影响收敛速率,在莱维飞行中引入动态因子 J_{bp} , 帮助算法更好的在全局搜索和局部搜索中得到平衡。因此,采用动态因子的莱维飞行策略数学模型以及第四防御阶段如式(29)~(32)所示。

$$\begin{cases} x_{i+1}^t = J_{bp} x_{CP}^t + (\alpha(1 - \tau_4) + \tau_4) \cdot (x_{CP}^t - x_L^t) \delta - \tau_5 \times \delta \times \gamma_t \times \vec{F}_i^t \\ J_{bp} = \frac{\tanh(2) - \tanh(2(1 - t/T_{max}))}{2 \tanh(2)} \end{cases} \quad (29)$$

$$x_L^t = \frac{\mu_c}{|\nu_c|^{1/\beta_c}} (x_r^t - x_{CP}^t) \quad (30)$$

$$\delta = \begin{cases} +1, & rand > 0.5 \\ -1, & \text{其他} \end{cases} \quad (31)$$

$$\begin{cases} \vec{F}_i^t = \tau_6 \times \frac{m_i \cdot (x_r^t - x_i^t)}{\Delta t} \\ m_i = e^{\frac{f(x_i^t)}{\sum_{n=1}^n f(x_n^t) + \epsilon}} \\ \gamma_t = 2 \cdot rand \cdot (1 - t/T_{max})^{t/T_{max}} \end{cases} \quad (32)$$

式中: α 表征收敛速率因子, $\tanh(2)$ 为双曲正切函数在 2 处的取值, τ_4 是 $0 \sim 1$ 的随机值, x_L^t 是莱维飞行步长, δ 是控制搜索方向的参数, γ_t 是防御因子, \vec{F}_i^t 是影响力,模拟一维弹性碰撞, m_i 模拟捕食者质量, $f()$ 表示适应度值函数, Δt 表示当前迭代的次数, $\tau_6 \in (0, 1)$ 。

2.3 BCPO 算法流程

BCPO 算法是将多种机制集成改进的元启发式算法,该算法的主要过程如下:

步骤 1) 初始化 BCPO 种群相关参数,如种群总数 N , 总迭代次数 T_{max} , 收敛因子 α 等;

步骤 2) 根据结合随机学习的佳点集方法初始化 N 只冠豪猪;

步骤 3) 计算待选解的适应度值,找出初始解最佳适应

度值和对应的最佳位置；

步骤 4)根据基于自适应小扰动的螺旋搜索策略启动第一防御阶段,进行位置更新；

步骤 5)根据基于最优随机位置的变异三角形游走策略启动第二、第三防御阶段,进行位置更新；

步骤 6)根据融合动态因子的莱维飞行策略启动第四防御阶段,进行位置更新；

步骤 7)根据循环种群衰减技术动态调整种群数量；

步骤 8)判断是否 $t \leq T_{max}$,若是,重复步骤 4)~步骤 7),否则执行步骤 9)；

步骤 9)重新计算适应度值,找出最佳适应度值和位置。

3 BCPO 算法的模拟实验和结果分析

本文的仿真环境为 64 位 window11 操作系统,算法运行在 MATLAB R2023a 中。另外,本文选用了 GWO、WOA 等 6 种算法同 BCPO 算法进行对比。

3.1 BCPO 算法性能验证分析

为了验证 BCPO 算法的性能提升,在 CEC2017 测试集

中选择了 6 个基准函数进行测试,各函数类型如表 1 所示。

表 1 6 种测试函数
Table 1 Six test functions

名称	序号	函数	$F_i^* = F_i(x^*)$
简单多	F1	移位和旋转的 Rosenbrock 函数	300
模态函数	F2	移位和旋转的 Rastrigin 函数	400
混合函数	F3	混合函数 1	1 000
	F4	混合函数 2	1 100
复合函数	F5	复合函数 1	2 000
	F6	复合函数 3	2 300

为了确保算法的可行性和准确性,采取统一参数设置,种群设置为 50,最大 200 次迭代,独立执行 30 次,以尽可能地减少随机性对结果的影响。关键性能指标,包括最优值、标准差、平均值。BCPO 和其他算法的比较性能结果记录在表 2 中,性能最优数值以粗体突出显示。

表 2 不同优化算法 CEC2017 测试函数结果

Table 2 Results of different optimization algorithms on CEC2017 test functions

名称	F1	F2	F3	F4	F5	F6
BCPO	最优: 300	最优: 400	最优: 1 000	最优: 1 113.55	最优: 2 024.83	最优: 2 302.51
	平均: 300	平均: 400	平均: 1 000.31	平均: 1 114.02	平均: 2 026.37	平均: 2 303.22
	标准差: 0	标准差: 0	标准差: 0.24	标准差: 5.07	标准差:22.18	标准差: 10.02
CPO	最优: 300	最优: 400	最优:1 001.03	最优:1 119.14	最优:2 035.36	最优:2 306.74
	平均: 300	平均: 400	平均:1 001.22	平均:1 121.24	平均:2 035.54	平均:2 305.24
	标准差: 0	标准差: 0	标准差:0.36	标准差:11.63	标准差:7.64	标准差:16.14
SSA	最优: 300	最优: 400	最优:1 000.31	最优:1 130.70	最优:2 067.45	最优:2 305.67
	平均: 300	平均: 400	平均:1 006.83	平均:1 150.65	平均:2 091.57	平均:2 306.04
	标准差: 0	标准差: 0	标准差:13.22	标准差:48.86	标准差:56.92	标准差:14.56
HO	最优:300	最优: 400	最优:1 000.31	最优:1 174.99	最优:2 092.50	最优:2 315.38
	平均:300	平均: 400	平均:1 002.64	平均:1 204.36	平均:2 112.02	平均:2 316.16
	标准差:0	标准差: 0	标准差:6.44	标准差:64.57	标准差:67.45	标准差:43.65
GA	最优:391.30	最优:400.06	最优:1 016.82	最优:1 832.94	最优:2 245.53	最优:2 686.39
	平均:617.62	平均:400.08	平均:1 022.44	平均:5 044.74	平均:2 267.01	平均:2 973.71
	标准差:588.46	标准差:0.09	标准差:17.94	标准差:6 247.92	标准差:96.85	标准差:654.75
WOA	最优: 300	最优: 400	最优:1 016.76	最优:1 326.67	最优:2 230.88	最优:2 347.30
	平均: 300	平均: 400	平均:1 022.64	平均:1 335.82	平均:2 238.71	平均:2 344.17
	标准差: 0	标准差: 0	标准差:16.44	标准差:114.61	标准差:73.58	标准差:36.37
GWO	最优: 300	最优: 400	最优:1 016.11	最优:1 136.37	最优:2 107.75	最优:2 310.56
	平均: 300	平均: 400	平均:1 016.76	平均:1 156.34	平均:2 127.31	平均:2 323.16
	标准差: 0	标准差: 0	标准差:10.08	标准差:40.05	标准差:67.74	标准差:50.72

整个迭代过程中 BCPO 相对于其余算法的目标值柱状图如图 5(a)~(f)所示。

图 5(a)~(c)的柱状图高度可以看出,在 F1、F2、F3 测

试函数中,GA 算法容易陷入局部最优解,其余算法均能够找到理想的最优值。图 5(d)~(f)的柱状图高度可以看出,在 F4~F6 测试函数中,BCPO 所在的柱状图对应的值

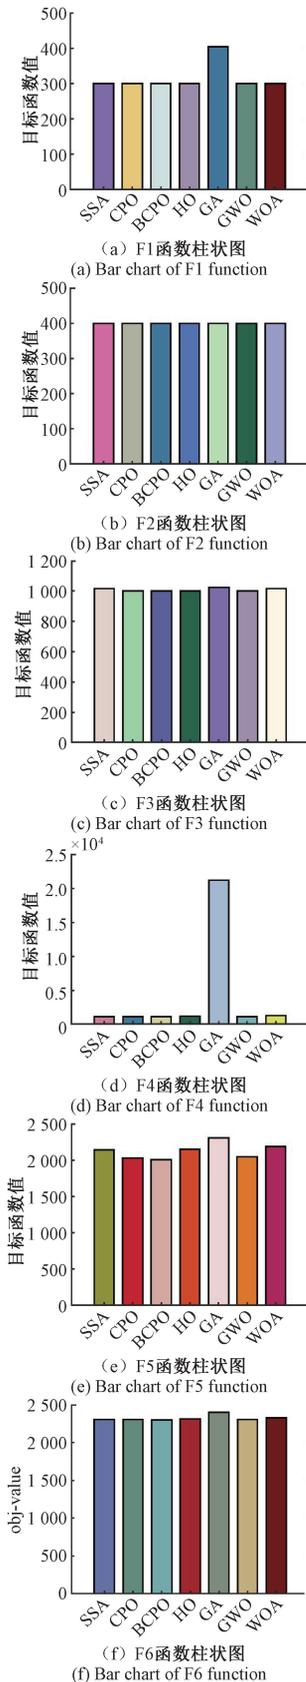


图 5 各算法目标函数值柱状图

Fig. 5 Bar chart of objective function values for each algorithm

最小,说明其具有更高的收敛精度,而表 2 的结果也表明 BCPO 算法所展现出来的收敛精度和稳定性都更加优秀。由此可以证明 BCPO 克服了 CPO 算法收敛精度低的缺陷。

3.2 多威胁山地环境仿真实验

为了进一步论证 BCPO 算法在航迹规划问题中的有效性,将其与 GWO、WOA 和改进的冠豪猪算法在真实的数字高程模型 DEM 地图中进行航迹仿真实验,环境模型如图 6 所示。

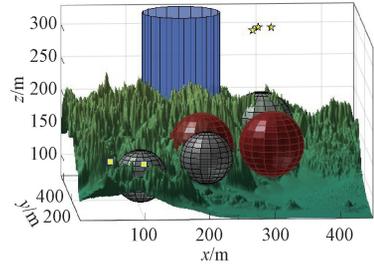


图 6 多威胁山地环境仿真图

Fig. 6 Simulation of multi-threat mountainous environment

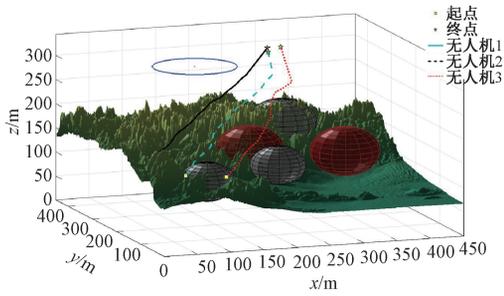
将各算法按照参考文献设置参数,种群数量设置为 30,迭代次数上限为 200,环境信息如表 3 所示。

表 3 环境信息参数表

Table 3 Environmental information parameters		
名称	坐标信息/m	半径/m
无人机 1	起点(50,50,250)	—
	终点(290,370,300)	
无人机 2	起点(20,100,180)	—
	终点(300,400,300)	
无人机 3	起点(100,20,150)	—
	终点(320,400,300)	
雷达	(100,100,120)	40
	(300,340,160)	50
火炮	(200,80,150)	40
	(300,80,170)	40
禁飞区	(200,200,150)	50
	(180,370,300)	60

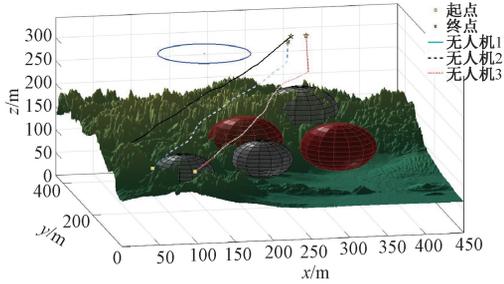
4 种不同优化算法的三维航迹图如图 7(a)~(d)所示,适应度收敛曲线如图 8 所示。为了增强实验的可靠性和真实性,减少单次实验造成的偶然误差,独立重复 30 次实验,并记录关键性能指标,包含平均适应度值,最优值和标准差,详细结果如表 4 所示。

相较于图 7(b)、(c)、(d)分别对应的算法所生成航迹曲线,图 7(a)所对应的 BCPO 算法生成的航迹曲线更加平滑,更符合无人机的可飞行性;由图 8 和表 4 可以看出,BCPO 的适应度值更小,生成的航迹质量更加优秀,相比



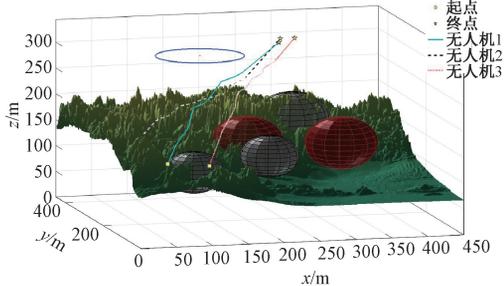
(a) BCPO算法三维航迹图

(a) Three-dimensional trajectory plot of the BCPO



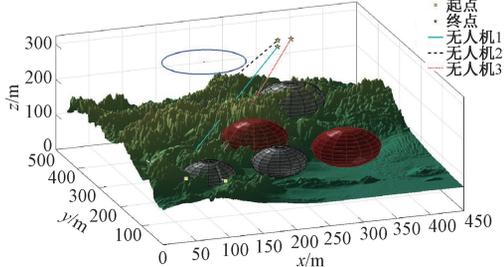
(b) CPO算法三维航迹图

(b) Three-dimensional trajectory plot of the CPO



(c) GWO算法三维航迹图

(c) Three-dimensional trajectory plot of the GWO



(d) WOA算法三维航迹图

(d) Three-dimensional trajectory plot of the WOA

图 7 各算法三维航迹图

Fig. 7 3D trajectory plots of each algorithm

表 4 4 种算法的仿真结果

Table 4 Simulation results of four algorithms

名称	最优值	平均值	标准差
BCPO	104.944 64	105.167 144	0.444 666
CPO	109.403 807	115.359 15	1.209 412
GWO	109.260 637	111.614 54	3.454 744
WOA	111.740 462	134.534 45	7.643 316

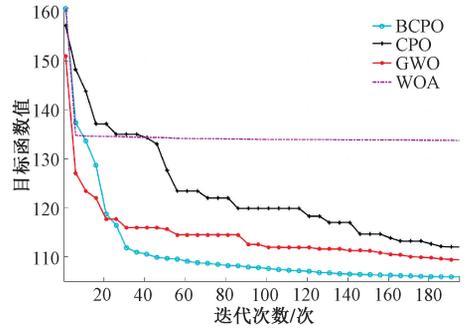


图 8 各算法适应度曲线收敛图

Fig. 8 Convergence plots of fitness curves for each algorithm

CPO、GWO、WOA 算法平均性能分别提升了 8.834%、5.776%、21.828%，并且 BCPO 的标准差很小，证实其稳定性得到了巨大提升，能够更好的适用于实际情况下的多无人机航迹规划问题。

4 结 论

针对传统搜索算法应用于面向多威胁山地环境下的多无人机航迹规划问题存在计算复杂度高，难度大，生成航迹不具备稳定性和飞行性的缺点，本文提出了一种改进的冠豪猪算法 (BCPO)。在 CEC2017 函数和多威胁复杂山地环境仿真证明了本文提出的改进方法可以有效降低航迹成本，加快收敛速率，增强算法的稳定性。由 DEC 地图仿真实验可知，本文构建的 BCPO 算法是优于 CPO 算法和其他算法的，但仍有一些方面待改进，首先，本文没有减少 CPO 算法本身参数过多导致的参数敏感性问题；其次，后续还应在更加复杂多元化的环境下验证算法的可靠性。

参 考 文 献

[1] ZHANG Y X, ZHAO Q Y, MAO P F, et al. Design and control of an ultra-low-cost logistic delivery fixed-wing UAV[J]. Applied Sciences, 2024, 14(11): 4358.

[2] ZHU W J, ZHONG S D, CHEN R J, et al. Design of a relief materials delivery system based on UAV[J]. IOP Conference Series: Materials Science and Engineering, 2020, 715(1): 012049.

[3] WANG R S, WU W B, FU ZH W, et al. Task scheduling optimization for UAV electrical image fault detection with wireless power transfer[J]. Journal of Circuits, Systems and Computers, 2024, 33(12): 2450213.

[4] FU X J, YAN H. Neural network optimal control for tripartite UAV confrontation systems based on fuzzy differential game [J]. Scientific Reports, 2024, 14(1): 21547.

[5] GIRI P R, SATO R, SAITO K. Quantum walk search based edge detection of images[J]. Physics Letters A,

- 2025, 540: 130391.
- [6] 古玉锋, 凌浩, 赵耀晶, 等. 优化时间窗改进 Dijkstra 算法的无人驾驶磁悬浮车路径规划[J]. 计算机应用研究, 2025, 42(7): 2080-2085.
GU Y F, LING H, ZHAO Y J, et al. Path planning for unmanned maglev vehicles based on optimized time window and improved Dijkstra algorithm [J]. Application Research of Computers, 2025, 42(7): 2080-2085.
- [7] 许万, 程兆, 朱力, 等. 一种基于改进人工势场法的局部路径规划算法[J]. 电子测量技术, 2022, 45(19): 83-88.
XU W, CHENG ZH, ZHU L, et al. A local path planning algorithm based on improved artificial potential field method [J]. Electronic Measurement Technology, 2022, 45(19): 83-88.
- [8] KORZEN M, KRUSZYNA M. Public transport planning using modified ant colony optimization[J]. Sustainability, 2025, 17(6): 2468.
- [9] 宋宇, 高岗, 梁超, 等. 基于多策略改进灰狼算法的无人机路径规划[J]. 电子测量技术, 2025, 48(1): 84-91.
SONG Y, GAO G, LIANG CH, et al. Path planning for UAVs based on multi-strategy improved grey wolf algorithm [J]. Electronic Measurement Technology, 2025, 48(1): 84-91.
- [10] 王兴旺, 张清杨, 姜守勇, 等. 基于改进鲸鱼优化算法的动态无人机路径规划[J]. 计算机应用, 2025, 45(3): 928-936.
WANG X W, ZHANG Q Y, JIANG SH Y, et al. Dynamic UAV path planning based on improved whale optimization algorithm [J]. Journal of Computer Applications, 2025, 45(3): 928-936.
- [11] MOHAMED A B, MOHAMED R, MOHAMED A. Crested porcupine optimizer: A new nature-inspired metaheuristic [J]. Knowledge-Based Systems, 2024(284): 111257.
- [12] 张家琛, 邱楠, 刘浩. 基于混沌自适应冠豪猪优化算法的永磁同步电机 PI 控制[J]. 微纳电子与智能制造, 2024, 6(2): 57-61.
ZHANG J CH, QIU N, LIU H. PI control of permanent magnet synchronous motor based on chaotic adaptive crowned porcupine optimization algorithm [J]. Micro-Nano Electronics and Intelligent Manufacturing, 2024, 6(2): 57-61.
- [13] 王鑫玮, 冯锋. 基于冠豪猪优化算法的机器人二维路径规划研究[J/OL]. 物联网技术, 1-4 [2025-05-06]. <http://kns.cnki.net/kcms/detail/61.1483.TP.20250221.1655.008.html>.
WANG X W, FENG F. Research on two-dimensional path planning of robots based on crowned porcupine optimization algorithm [J/OL]. Internet of Things Technology, 1-4 [2025-05-06]. <http://kns.cnki.net/kcms/detail/61.1483.TP.20250221.1655.008.html>.
- [14] 吴学礼, 王超, 赵俊棋, 等. 改进麻雀算法的无人机三维路径规划[J]. 科学技术与工程, 2024, 24(15): 6534-6542.
WU X L, WANG CH, ZHAO J Q, et al. Three-dimensional path planning for UAVs based on improved sparrow algorithm [J]. Science Technology and Engineering, 2024, 24(15): 6534-6542.
- [15] UZUN Y, BILGIN M. Medical image enhancement using war strategy optimization algorithm [J]. Biomedical Signal Processing and Control, 2025, 106: 107740.
- [16] 徐光辉, 邓赞, 王淑青, 等. 改进凤头豪猪优化算法的无人机三维路径规划[J]. 中南民族大学学报(自然科学版), 2025, 44(2): 237-244.
XU G H, DENG Y, WANG SH Q, et al. Three-dimensional path planning for UAVs based on improved crested porcupine optimization algorithm [J]. Journal of South-Central University for Nationalities (Natural Science Edition), 2025, 44(2): 237-244.
- [17] 江佩瑶, 王洪亮, 吴兴华, 等. 基于数据增强与 IEVO-GRNN 的飞机引气系统故障诊断[J]. 电子测量技术, 2025, 48(10): 42-50.
JIANG P Y, WANG H L, WU X H, et al. Fault diagnosis of aircraft bleed air system based on data augmentation and IEVO-GRNN [J]. Electronic Measurement Technology, 2025, 48(10): 42-50.

作者简介

李尧, 硕士, 主要研究方向为路径规划、算法优化。

E-mail: 1044970679@qq.com

黄大庆(通信作者), 本科, 研究员, 教授, 主要研究方向为遥控遥测、航电一体。

E-mail: radiouav@nuaa.edu.cn

殷奇缘, 博士, 主要研究方向为算法分析。

E-mail: 1046772694@qq.com

徐文校, 博士, 主要研究方向为图像检测。

E-mail: 971149614@qq.com

王嘉瑞, 硕士, 主要研究方向为防震减灾工程。

E-mail: 944189738@qq.com