

文章编号:1671-6833(2026)03-0057-10

基于蝴蝶优化改进算法的无人机三维路径规划

汪果果^{1,2}, 白艺杰², 柴梦娟², 余道杰², 王怡澄²

(1. 郑州大学 网络空间安全学院, 河南 郑州 450001; 2. 信息工程大学 信息工程学院, 河南 郑州 450001)

摘要: 针对无人机在多重威胁环境下路径规划复杂度高、难以在有效时间内生成高质量路径的问题, 提出一种多策略融合的粒子群-蝴蝶优化改进算法(IPSBOA)。通过 Tent 混沌映射结合反向学习策略优化初始种群, 增强种群多样性; 引入非线性参数调整和动态转换概率机制, 平衡全局搜索与局部开发; 结合粒子群算法, 在局部搜索阶段引入速度项, 提出在速度动态变化的位置更新方程, 提升搜索效率。分别基于三维静态和动态环境下不同威胁场景, 将 IPSBOA 与蝴蝶优化算法及其他多种优化算法进行对比。实验结果表明: IPSBOA 在静态环境的 3 种场景下相较于蝴蝶优化算法, 最优适应度值分别优化 1.8%、17% 和 44%, 路径长度分别优化 1.8%、42.4% 和 61.3%; 在动态环境下实现全局路径跟踪与实时避障的结合, 生成更平滑、安全性更高的路径。

关键词: 蝴蝶优化算法; 动态窗口法; Tent 混沌映射; 反向学习; 路径规划

中图分类号: TP18; TP301

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2026.03.005

随着现代高新技术的快速发展, 无人机在军用和民用领域广泛应用, 低空经济作为新兴产业, 如农业^[1]、物流^[2]、搜索救援^[3]、空中交通^[4]等, 不仅提高了执行任务的效率, 而且还减轻了地面交通的压力。由于无人机飞行环境的复杂多变以及自身性能的约束, 找到一条安全高效的飞行路线成为无人机应用中的技术难题, 受到越来越多学者的关注。

无人机路径规划的算法通常包括传统经典算法和智能优化算法, 相比于传统经典算法, 智能优化算法在复杂的三维环境中, 具有较强的寻优能力, 更能获得高质量的解, 成为当前无人机路径规划的主要手段。如粒子群算法 (particle swarm optimization, PSO)、萤火虫算法 (firefly algorithm, FA)、灰狼优化算法 (grey wolf optimizer, GWO) 和蝴蝶优化算法 (butterfly optimization algorithm, BOA) 等, 这些经典的智能优化算法已经被开发并广泛应用于无人机的路径规划中。高岳林等^[5]将经典的 PSO 进行改进优化, 应用于无人机路径规划中, 明显提高了路径的寻优精度和稳定性; 虞馥泽等^[6]将 FA 进行改进优

化, 解决多机器人在静态环境中的路径规划问题; Yu 等^[7]将 GWO 与差分进化算法混合, 应用于无人机路径规划中, 最终使无人机飞行路径更短; Xu 等^[8]将改进的 BOA 应用于复杂环境下的无人机路径规划中, 获得了实用有效的路径。其中, 蝴蝶优化算法具有更好的全局优化能力, 因其具有结构简单、参数少、灵活高效且容易实现等优点, 得到了广泛关注和应用, 但其在应用时也存在迭代后期收敛速度慢、易陷入局部极值等问题。

为了提高 BOA 的收敛精度和跳出局部极值的能力, 许多学者提出了改进与优化方法。尚俊娜等^[9]引入自适应权重增强 BOA 的信息素系数, 采用动态切换概率来平衡 BOA 中全局和局部搜索的比例, 并在全局和局部搜索两个阶段引入一种新的位置更新策略, 改善了全局和局部搜索之间的平衡。Li 等^[10]在算法初期引入基于对立的学习机制, 以增加初始种群的多样性, 采用分段调整因子来提高算法的优化精度, 在算法后期采用精英突变策略来防止算法的早熟。Zhou 等^[11]引入聚类竞争和混沌精英学习机制来提高蝴蝶优化算法的性能。Long

收稿日期: 2025-12-12; 修订日期: 2026-02-10

基金项目: 国家自然科学基金资助项目 (61871405)

作者简介: 汪果果 (1996—), 女, 河南许昌人, 郑州大学硕士研究生, 主要从事智能优化算法、航迹规划研究, E-mail: wangguoguo9613@163.com。

通信作者: 余道杰 (1978—), 男, 河南信阳人, 信息工程大学教授, 博士, 博士生导师, 主要从事高功率微波技术研究, E-mail: yudj2003@163.com。

引用本文: 汪果果, 白艺杰, 柴梦娟, 等. 基于蝴蝶优化改进算法的无人机三维路径规划[J]. 郑州大学学报(工学版), 2026, 47(3): 57-66. (WANG G G, BAI Y J, CHAI M J, et al. Based on butterfly optimization improvement algorithm for UAVs 3D path planning[J]. Journal of Zhengzhou University (Engineering Science), 2026, 47(3): 57-66.)

等^[12]通过引入自适应全局最优解和惯性权重,有效提高了开发能力和精度,并采用一种基于光学原理的针孔成像学习策略,避免过早收敛。Peng等^[13]利用肯特映射初始化蝴蝶个体的位置,引入自适应转换概率,以平衡全局和局部搜索,引入自适应权重系数和柯西变量来调整蝴蝶的搜索方向和移动步长。上述提出的改进策略均从不同的角度增强了BOA的寻优能力,使改进后的BOA具有更好的收敛精度。

本文首先通过制定一个目标函数来解决无人机的路径规划问题,该目标函数包含了无人机及其飞行路径相关的各种要求和约束。然后引入一种多策略融合的粒子群-蝴蝶优化改进算法(improved particle swarm-butterfly optimization algorithm for multi-strategy fusion, IPSOBOA),该算法能够利用无人机的航行环境来生成高质量的解。通过使用Tent混沌映射来产生优化算法所需的混沌序列,并利用反向学习策略生成混沌序列的反向解,筛选并生成蝴蝶初始种群,有效提升了算法多样性,并避免算法过早收敛到局部最优;调整幂指数 a 和转换概率 p 以平衡全局搜索和局部开发;将PSO融入BOA中,动态调整其惯性权重,给出了速度动态变化的位置更新方程,提升算法的搜索能力。最后,对改进的算法与其他智能算法进行三维环境的仿真实验,以评估其性能,并改善路径规划的稳定性。

1 适应度函数

在无人机路径规划中,可以利用适应度函数来评价算法所生成路径的优劣。本节设计了包含4个代价的适应度函数来约束无人机的可行路径,分别是路径长度代价、障碍物威胁代价、飞行高度代价和平滑度代价。适应度函数数值越小,生成的路径越优。

1.1 路径长度代价

如果无人机在整个路径上保持匀速运动,那么路径的长度成本也可以看作是时间成本。将每条完整的飞行路径 W_i 视为一个个体,由 N 个航点组成列表,每个航点对应路径的一个节点,其中每个节点表示为 $P_{i,j} = (x_{i,j}, y_{i,j}, z_{i,j})$ 。将每两个相邻节点之间的欧氏距离求和,则路径 W_i 对应的路径长度代价 F_1 为

$$F_1(W_i) = \sum_{j=1}^{N-1} \|P_{i,j} - P_{i,j+1}\|。 \quad (1)$$

1.2 威胁代价

规划的路径还需要引导无人机有效躲避三维空

间中的障碍物,遵守空域规则,进而达成安全、高效且稳定的飞行状态,以确保其安全飞行。本文假设飞行场景中有一个雷达威胁,用浅蓝色半球体表示;一个禁飞区威胁,用紫色圆柱体表示; K 个障碍物威胁,用红色圆柱体表示。

1.2.1 雷达威胁

无人机在飞行过程中,有可能穿越敌方雷达部署区域,本文主要考虑作战场景下常见的雷达侦测威胁,威胁建模的主要思想是以威胁源为中心,根据侦测半径或者打击半径构建圆形或扇形威胁区域,在这里用浅蓝色半球体模拟雷达威胁区域,用紫色圆柱体表示禁飞区,用红色圆柱体表示障碍物,如图1所示。




图1 三维空间仿真地图^[14]

Figure 1 3D space simulation map

雷达的威胁程度通常与无人机和威胁源的距离有关,距离越小,威胁程度越高。假设场景中雷达具备 360° 全方位扫描侦测,则无人机被雷达侦测到的概率表达式为

$$P_r(d_r) = \begin{cases} 0, & d_r > R_{\max}; \\ \frac{1}{d_r^4}, & R_{\min} \leq d_r \leq R_{\max}; \\ 1, & d_r < R_{\min}. \end{cases} \quad (2)$$

$$F_i(P_r) = \begin{cases} \infty, & P_r = 1, i \leq N; \\ T \cdot P_r, & 0 \leq P_r < 1, i \leq N. \end{cases} \quad (3)$$

式中: d_r 为无人机与雷达的距离,m; R_{\max} 为雷达最大侦测半径,m; R_{\min} 为高危区域半径,m; T 为雷达威胁代价常量。当无人机与雷达距离小于阈值 R_{\min} 时,一定会被侦测到。

1.2.2 禁飞区及障碍物威胁

无人机禁飞区是指在特定区域内,无人机被禁止飞行或受到严格限制的区域。这些区域的设立通常是为了保障公共安全、国家安全、隐私保护以及避免对其他航空器造成干扰。其威胁切面示意图如图2所示。

将无人机的大小考虑为直径 D , C 为两个节点间的飞行安全距离,每一个障碍物的投影半径为




图2 威胁切面示意图^[14]

Figure 2 Threat aspect diagram

$R_k, d_{k,j}$ 为路径 W_i 中第 k 个威胁中心到第 j 个路径段的最短距离,即无人机必须在阴影之外的区域飞行,才能确保其安全性。路径 W_i 对应的威胁代价 F_2 计算如下:

$$T(W_i) = \begin{cases} 0, d_k > C + D + R_k; \\ \sum_{j=1}^{N-1} \sum_{k=1}^k (C + D + R_k) - d_k, D + R_k < d_k \leq C + D + R_k; \\ \infty, d_k \leq D + R_k. \end{cases} \quad (4)$$

$$F_2(W_i) = T(W_i) + F_i(P_r). \quad (5)$$

1.3 飞行高度代价

无人机的飞行高度通常被限定在给定的两个极值之间,即最大高度 h_{max} 和最小高度 h_{min} 。在飞行过程中,合理的飞行高度不仅能够减少燃料消耗,提高能效,而且使飞行更具有安全性。相应的路径 W_i 对应的高度代价计算如下:

$$F_3(W_i) = \sum_{j=1}^N H_{i,j}. \quad (6)$$

$$H_{i,j} = \begin{cases} \left| h_{i,j} - \frac{(h_{max} + h_{min})}{2} \right|, h_{min} \leq h_{i,j} \leq h_{max}; \\ \infty, \text{其他}. \end{cases} \quad (7)$$

式中: $h_{i,j}$ 为航点 $P_{i,j}$ 相较于地面的飞行高度。

1.4 平滑度代价

平滑度代价是对无人机产生可行路径所必需的转弯和爬升速率进行评估,主要是为了确保无人机的飞行轨迹尽可能平滑,从而提高飞行的稳定性和安全性,减少能源消耗。与该值相关的因素包括转弯角度和爬升角度。转角 $\phi_{i,j}$ 为两个连续路径段 $P'_{i,j}P'_{i,j+1}$ 和 $P'_{i,j+1}P'_{i,j+2}$ 投影在水平面 xOy 上的夹角,计算如下:

$$P'_{i,j}P'_{i,j+1} = k \times (P'_{i,j}P'_{i,j+1} \times k). \quad (8)$$

$$\phi_{i,j} = \arctan\left(\frac{\|P'_{i,j}P'_{i,j+1} \times P'_{i,j+1}P'_{i,j+2}\|}{P'_{i,j}P'_{i,j+1} \cdot P'_{i,j+1}P'_{i,j+2}}\right). \quad (9)$$

式中: k 为 z 轴正方向的单位矢量。

爬升角 $\theta_{i,j}$ 为路径段 $P'_{i,j}P'_{i,j+1}$ 在铅垂平面上的投影和水平面之间的夹角,即

$$\theta_{i,j} = \arctan\left(\frac{z_{i,j+1} - z_{i,j}}{\|P'_{i,j}P'_{i,j+1}\|}\right). \quad (10)$$

此时,路径 W_i 对应的平滑度代价 F_4 为

$$F_4(W_i) = \sum_{j=1}^{N-2} (a_1 \phi_{i,j} + a_2 |\theta_{i,j+1} - \theta_{i,j}|). \quad (11)$$

式中: a_1 和 a_2 分别为转角和上升角惩罚系数,令 $a_1 = a_2 = 1$ 。

此时,路径 W_i 对应的总代价函数 F 定义为

$$F(W_i) = \sum_{k=1}^4 c_k F_k(W_i). \quad (12)$$

2 蝴蝶优化改进算法

针对传统蝴蝶优化算法^[15]易陷入局部最优及收敛速度慢的问题,提出了一种多策略融合的粒子群-蝴蝶优化改进算法(IPSBOA)。

2.1 Tent 混沌映射结合反向学习策略

为保证蝴蝶种群的多样性及在搜索空间中更均匀地分布,采用 Tent 混沌映射结合反向学习策略来初始化 BOA 的种群个体位置。

常用的混沌映射有 Logistic 混沌映射和 Tent 混沌映射等,Tent 混沌映射在相同序列个数条件下,由于其特定的数学属性,所生成的序列在 $[0, 1]$ 之间展示出更优的均匀分布性^[16]。因此,本文采用 Tent 混沌映射进行种群初始化,其数学表达式为

$$x_{i+1} = \begin{cases} 2x_i, 0 \leq x_i \leq 0.5; \\ 2(1 - x_i), 0.5 < x_i \leq 1. \end{cases} \quad (13)$$

式中: i 代表初始化种群的第 i 个个体。

受计算机字长影响,Tent 混沌映射产生的序列在 $[0, 1]$ 会出现小周期 $\{0.2, 0.4, 0.6, 0.8\}$ 和不稳定周期点 $\{0, 0.25, 0.5, 0.75\}$ 的现象^[17]。为解决该问题,增加了一个随机变量 $\text{rand}(0, 1)/N$ 来对 Tent 混沌映射进行改进,如式(14)所示。

$$x_{i+1} = \begin{cases} 2x_i + \text{rand}(0, 1)/N, 0 \leq x_i < 0.5; \\ 2(1 - x_i) + \text{rand}(0, 1)/N, 0.5 < x_i \leq 1. \end{cases} \quad (14)$$

图3为改进前后 Tent 混沌映射生成的混沌序列元素的平面分布图。由图3可知,加入随机变量后,所得序列点集分布得更加均匀。

采用混沌映射生成初始解后,应用反向学习策略进行调整,对生成的初始解进行扰动,以增强种群的多样性。反向学习策略的数学表达式为

$$x'_i = \frac{(ub + lb)}{2} + \frac{(ub - lb)}{2k} - \frac{x_i}{n}. \quad (15)$$

式中: ub, lb 分别为决策空间的上、下限; n 为伸缩因子,此时可以设计 n 的表达式为

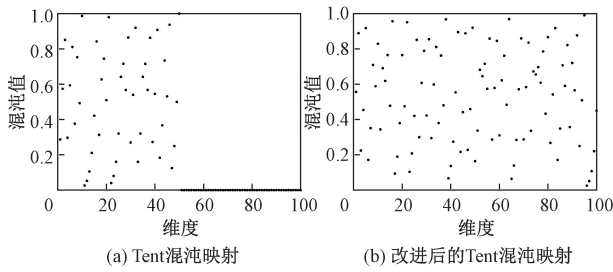


图3 改进前后 Tent 混沌映射生成的混沌序列元素的平面分布图

Figure 3 Planar distribution of chaotic sequence elements generated by Tent chaotic mapping before and after improvement

$$n = \left[1 + \left(\frac{1}{T_{\max}} \right)^{0.5} \right]^{10}. \quad (16)$$

最终得到的初始解是分别进行 Tent 混沌映射和反向学习得到的正向解和反向解的合并,再根据其适应度值的大小进行升序或者降序排列,选取适应度值较优的前 N 个个体作为初始种群的解。

2.2 非线性参数调整和动态转换概率控制策略

2.2.1 非线性参数调整控制策略

传统 BOA 中,幂指数 a 是引导蝴蝶搜索行为的关键因素,是一个固定的值。选择合适的幂指数,有助于加快收敛速度,防止陷入局部最优。受文献[18]的启发,本文提出了一种动态变化的策略,如式(17)所示。

$$a_t = a_{\min} + (a_{\max} - a_{\min}) \sin\left(\pi r_3 \left(\frac{t}{T_{\max}}\right)^2\right). \quad (17)$$

式中: r_3 为 $[0, 1]$ 内的随机数; $T_{\max} = 500$; a_{\min} 为 0.1, a_{\max} 为 0.9。

随着迭代次数的增加,幂指数 a 的变化曲线和收敛曲线如图 4 所示。由图 4(a)可知,基于正弦函数的非线性参数调整控制策略在迭代前期斜率大,收敛速度比较快,有利于进行大范围的搜索;而迭代后期比较缓慢,便于进行局部开发,有利于找到最优解。图 4(b)是选取 Solomon 函数进行检验的收敛曲线结果图,由图可知,改进后的算法能更快地收敛到最优值,即寻优性能相比传统 BOA 更好。

2.2.2 动态转换概率控制策略

传统 BOA 中,转换概率 p 作为控制蝴蝶行为的关键参数,通常被设定为一个固定的常数。选择合适的 p 值,对于更有效地平衡全局搜索和局部开发是至关重要的。本文提出了一种动态转换概率的控制策略,使 p 值随着迭代次数的增加而动态调整,如式(18)所示。

$$p = 0.9 - 0.5 \left(\frac{t}{T_{\max}} \right)^2. \quad (18)$$




图4 两种幂指数 a 下的变化曲线和在 Solomon 函数下的收敛曲线

Figure 4 Variation curves under two power exponents a and convergence curves with the Solomon function

由图 5(a)可知,传统 BOA 算法中的 p 值为常数 0.6,而在 IPSOBOA 算法中,转换概率 p 的值在迭代过程中动态调整,以适应不同阶段的搜索需求。




图5 两种转换概率 p 下的变化曲线和在 Griewank 函数下的收敛曲线

Figure 5 Variation curves under two transition probabilities p and convergence curves with the Griewank function

在迭代的初期阶段,主要以更高的探索概率进行全局搜索,避免算法过早收敛;随着迭代的进行,通过动态调整的概率来使算法更精细化地局部搜索,找到当前最好的解。该策略有效加快了算法的收敛速度,提高了最优解的质量。图 5(b)是选取 Griewank 函数进行检验的收敛曲线结果图。由此可知,改进后的算法寻优性能相比传统 BOA 更好。

2.3 混合蝴蝶优化算法

粒子群优化算法 (particle swarm optimization, PSO)^[19]收敛速度快且具有记忆能力,通过在个体历史最优和全局历史最优的双重指导下引导粒子移动,且利用速度项控制搜索范围,既可以在全局范围内以较大的速度广泛搜索,又能以较小的速度进行局部精细搜索。因此,为了提高 BOA 的收敛速度以及平衡其全局搜索和局部开发能力^[20],将 PSO 的这些特性引入 BOA 中,在全局搜索时,融入随机惯性权重 ω_1 来更好地控制算法的收敛速度,并考虑该个体的历史最优位置;在局部开发阶段,重新设计一个动态的惯性权重 ω_2 ,并引入速度项 $v_{ij}(t+1)$,给出了一个速度动态变化的位置更新方程。混合改进

算法的数学模型如下。

惯性权重系数 ω 的计算公式为

$$\omega_1 = \omega_{\max} - \left(\frac{\omega_{\max} - \omega_{\min}}{T_{\max}} \right) \cdot t; \quad (19)$$

$$\omega_2 = 1 + \cos\left(\frac{\pi t}{2T_{\max}} + \pi\right)。 \quad (20)$$

式中: $\omega_{\max} = 0.9, \omega_{\min} = 0.4$ 分别为惯性权重的上、下限; T_{\max} 为最大迭代次数。

全局搜索阶段。引入 PSO 中的随机惯性权重 ω_1 , 则得到表达式

$$x_i^{t+1} = \omega_1 x_i^t + [(r^2 \cdot p_{\text{best}} - x_i^t) + (r^2 \cdot g - x_i^t)] \cdot f_i。 \quad (21)$$

局部搜索阶段。引入 PSO 中的速度项, 则得到表达式

$$x_i^{t+1} = \omega_2 x_i^t + (r^2 \cdot x_j^t - x_k^t) \cdot f_i + v_{ij}(t+1)。 \quad (22)$$

多策略融合的粒子群-蝴蝶优化改进算法伪代码如算法 1 所示, 流程如图 6 所示。

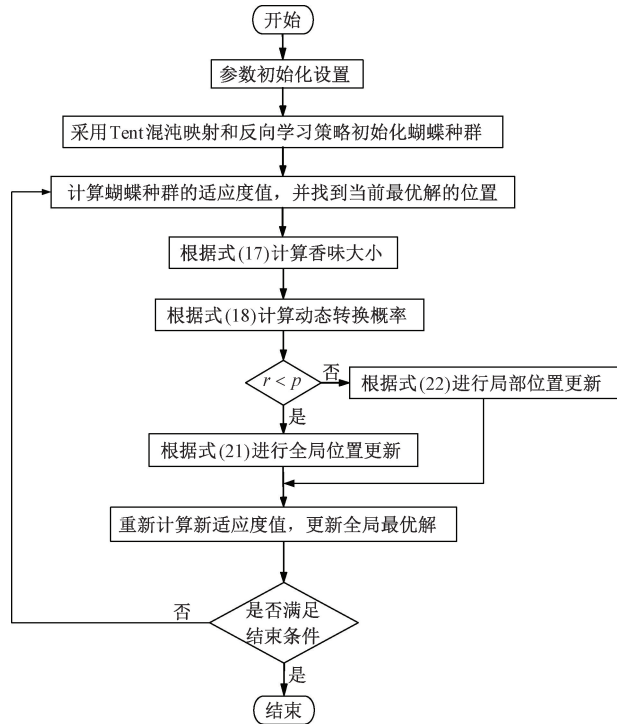


图 6 IPSOBOA 流程图

Figure 6 Flow chart of IPSOBOA

算法 1 IPSOBOA 算法

输入: $N, T_{\max}, a, c, \omega$;

输出: $x_i, f(x_i)$ 。

- ① 初始化蝴蝶种群, 计算每只蝴蝶个体的适应度值
- ② while $t = 1 : T_{\max}$
- ③ For $t = 1 : N$
- ④ 根据式(17)计算每只蝴蝶的香味, 生成随机数 r
- ⑤ 根据式(18)计算转换概率 p
- ⑥ If $r < p$

- ⑦ 根据式(21)进行全局位置更新
- ⑧ Else
- ⑨ 根据式(22)进行局部位置更新
- ⑩ End if
- ⑪ End for
- ⑫ 重新计算新的适应度值
- ⑬ End while

2.4 时间复杂度分析

本小节对 IPSOBOA 的时间复杂度进行分析, 该算法主要由 Tent 混沌映射结合反向学习策略初始化种群、非线性参数调整和动态转换概率机制以及将 PSO 融入 BOA 中, 并在局部搜索阶段引入速度项等操作组成。设种群规模为 N , 最大迭代次数为 T_{\max} , 则 IPSOBOA 每个程序的时间复杂度为

- (1) 算法参数设置和种群初始化: $O(N)$;
- (2) 非线性参数调整和动态转换概率机制: $O(1)$;
- (3) 计算种群适应度值并更新最优位置 $O(N)$;
- (4) 开始迭代, 将 PSO 融入 BOA 中, 并在局部搜索阶段引入速度项 $O(NT_{\max})$ 。

综上所述, IPSOBOA 的时间复杂度为 $O(NT_{\max})$, 与 BOA 一致, 但寻优能力优于 BOA, 尤其是对于高维函数而言。

3 动态窗口法的改进

在标准的动态窗口法 (dynamic window approach, DWA)^[21] 中, 往往只能通过固定的评价因子来评估每个速度窗口的优劣。在实际应用中, 环境是动态变化的, 固定的评价因子可能无法适应所有情况。因此, 提出了一种改进的动态窗口法 (improved dynamic window approach, IDWA)。

3.1 线速度变化评价函数

在标准的 DWA 中, 航迹规划的决策受到速度分辨率和预测时间范围的影响。标准 DWA 在每个控制周期内选择的是当前分辨率下最优的行驶速度, 这种选择虽然能够确保无人机接近目标并避开障碍物, 但也存在一些不足之处。特别是对于无人机这种需要高精度控制和长期续航的飞行器, 过高的速度可能会增加控制难度, 频繁的速度变化会增加电机的能耗。受文献[22]的启发, 在评价函数中添加线速度变化评价函数, 即

$$\text{change}(v, \omega_1, \omega_2) = \frac{1}{v_{i+1} - v_i}。 \quad (23)$$

3.2 自适应调整权重系数

方向变化评价函数旨在评估无人机前进方向与目标方向之间的一致性,鼓励无人机沿着预定目标方向前进,而在动态环境中,无人机需要绕过障碍物或选择次优方向以保证安全性,过于严格的方向一致性要求可能会限制这种灵活性。为了能够快速适应新的目标方向,对其权重系数 α 进行调整,具体方法如下。

$$\alpha_1 = \alpha(a_{\text{obs}}/a + \mu)。 \quad (24)$$

式中: μ 为常数; α 为检测区域的面积; a_{obs} 为检测区域中障碍物的面积,这里的检测区域是以预测轨迹终端为圆心,以检测距离为半径的球体。

IDWA 的评价函数为

$$G_1(v, \omega_1, \omega_2) = \sigma[\alpha_1 \text{head}(v, \omega_1, \omega_2) + \beta \text{dist}(v, \omega_1, \omega_2) + \gamma \text{vel}(v, \omega_1, \omega_2) + \delta \text{change}(v, \omega_1, \omega_2)]。 \quad (25)$$

式中: δ 为线速度变化评价函数的权重系数。

4 仿真实验与结果分析

4.1 实验环境与参数设置

实验配置的操作环境是 Window10 专业版、Intel (R) Core(TM) i9-12900 的 CPU, 2.4GHz 的主频, 运行内存 32 G, 所有测试均在 MATLAB R2020a 环境下运行。为了评估本文提出的改进算法的有效性, 进一步利用该算法解决基于三维静态和动态环境下不同威胁场景的无人机路径规划问题, 以应对实际路径规划中多约束条件下算法计算效率低、难以高效生成高质量路径等挑战, 并将其与蝴蝶优化算法(BOA)、粒子群算法(PSO)等经典的智能优化算法以及 3 种改进版的蝴蝶优化算法 IBOA^[23]、HPSBA^[24]和 HPSOBOA^[25]等进行对比分析。6 种算法的主要参数是依据原文献设置如表 1 所示。

表 1 算法参数设置

Table 1 Algorithm parameter settings

算法	参数设置
PSO	$c_1 = c_2 = 2, v_{\text{max}} = 1, v_{\text{min}} = -1,$ $\omega_{\text{max}} = 0.9, \omega_{\text{min}} = 0.4$
BOA	$p = 0.6, a = 0.1, c(0) = 0.01$
IBOA	$p = 0.6, a = 0.1, c(0) = 0.01,$ $r(0) = 0.33, \mu = 0.4$
HPSOBOA	$p = 0.6, a_{\text{first}} = 0.1, a_{\text{final}} = 0.3, c(0) = 0.01,$ $x(0) = 0.315, \rho = 0.295, c_1 = c_2 = 0.5$
HPSBA	$p = 0.6, a = 0.1, c(0) = 0.35, \mu = 0.4,$ $c_1 = c_2 = 2$
IPSOBOA	$p = 0.6, a_{\text{min}} = 0.1, a_{\text{max}} = 0.9, c(0) = 0.1,$ $\omega_{\text{max}} = 0.9, \omega_{\text{min}} = 0.4, c_1 = c_2 = 0.5$

考虑到环境的复杂性和算法的运行时间, 运行次数设为 10, 种群大小 $N = 30$, 最大迭代次数 $T_{\text{max}} = 200$, 航迹节点数为 10。本文采用自制四旋翼无人机, 具体飞行应用场景为陆地边境巡防, 设置对应 4 种代价权重系数分别为 $b_1 = 10, b_2 = 18, b_3 = 1, b_4 = 5$, 并进行归一化处理, 无人机参数信息如表 2 所示。

表 2 无人机参数信息

Table 2 UAV parameter information

参数	取值
路径起点坐标/m	(200, 100, 150)
路径终点坐标/m	(800, 800, 150)
雷达中心坐标/m	(780, 350, 150)
禁飞区中心坐标/m	(230, 570, 150)
空域范围/m	[1000, 800, 400]
无人机速度范围/($\text{m} \cdot \text{s}^{-1}$)	[5, 20]
最大转弯角 $\phi_{\text{max}}/(\circ)$	45
最大爬升角 $\theta_{\text{max}}/(\circ)$	30

4.2 静态环境下基于 IPSOBOA 的单机路径规划仿真实验与结果分析

三维静态环境下基于 IPSOBOA 的单机路径规划主要是针对规划过程中计算效率低与路径碰撞冲突等问题。3 种不同场景中的威胁信息如表 3 所示。

表 3 3 种不同场景中的威胁信息

Table 3 Threat information in three different scenarios

场景	威胁源	中心坐标	威胁半径/m	威胁高度/m
1/2/3	禁飞区	(780, 350)	80	150
	雷达	(230, 570)	50	150
1	1	(450, 350)	80	150
	2	(650, 750)	80	150
	3	(600, 200)	70	150
2	1	(400, 500)	80	100
	2	(600, 200)	70	150
	3	(500, 350)	80	150
	4	(350, 200)	70	150
	5	(700, 550)	70	150
	6	(650, 750)	80	150
3	1	(380, 500)	75	100
	2	(600, 180)	70	150
	3	(520, 350)	80	150
	4	(350, 200)	70	150
	5	(700, 550)	70	150
	6	(600, 750)	80	150
	7	(310, 720)	70	150
	8	(200, 350)	60	150
	9	(810, 700)	60	150
	10	(930, 550)	60	150

由表 4 可知, 在 3 种不同的场景下, IPSOBOA 的最优适应度值均取得最小, 相较于 BOA 分别优化

1.8%、17% 和 44%, 路径长度分别优化 1.8%、42.4% 和 61.3%。这说明随着环境复杂度的提高, IPSOBOA 在路径规划问题中保持着更好的寻优性能, 在 3 种不同复杂度的场景中, IPSOBOA 所规划的路径和运行时间均最短, 飞行距离能耗最小, 表明改进后的算法能够快速收敛, 验证了其在复杂环境中的优越性。

由图 7 中 3 种不同场景下 6 种算法的适应度曲线可知, IPSOBOA 的平均收敛曲线收敛速度最快, 分别在第 12 代、第 93 代和第 108 代达到最优并最终稳定在较低的适应度值, 这意味着 IPSOBOA 较同样基于迭代的其他算法更快地设计出接近于应用全局最优解的可行解, 即生成的路径效果更优。

4.3 动态环境下基于 IPSOBOA-IDWA 的多机路径规划仿真实验与结果分析

以 4.2 节静态环境下的实验为基础, 针对三维动态环境下路径规划时环境信息动态变化导致计算量剧增、实时性差及多机协同应对策略复杂易冲突的问题, 设计了动态环境下基于融合算法 (IPSOBOA-IDWA) 的多机路径规划仿真实验。设置了 2 种不同的场景, 分别是多架多目标场景: 多架无人机从不同

表 4 静态环境下 3 种不同场景中 6 种算法的运行结果对比
Table 4 Comparison of the running results of six algorithms in three different scenarios in static conditions

场景	环境复杂度	算法	最优适应度值/m	最短路径长度/m	算法收敛时间/s
1	3 个障碍物、1 个雷达、1 个禁飞区	IPSOBOA	623.20	997.12	1.01
		BOA	634.40	1 014.57	1.72
		IBOA	642.10	1 022.38	1.28
		HPSBA	766.34	1 088.26	1.65
		HPSOBOA	747.81	1 008.28	2.03
2	6 个障碍物、1 个雷达、1 个禁飞区	IPSOBOA	751.06	970.55	1.17
		BOA	881.15	1 381.91	2.04
		IBOA	855.19	1 360.90	1.65
		HPSBA	1 267.44	1 763.38	1.96
		HPSOBOA	918.64	1 230.01	2.34
3	10 个障碍物、1 个雷达、1 个禁飞区	IPSOBOA	667.88	943.54	1.32
		BOA	960.88	1 522.02	2.38
		IBOA	764.67	1 219.24	1.96
		HPSBA	882.66	1 142.87	2.82
		HPSOBOA	718.39	951.30	2.70
		PSO	1 145.77	1 581.67	2.51




图 7 静态环境下 3 种不同场景中 6 种算法的适应度曲线

Figure 7 Fitness curve results of six algorithms in three different scenarios in static conditions

的起始点同时飞向不同的目标点; 多架同目标场景: 多架无人机从不同的起始点飞向同一目标点。

在动态环境中添加了不同数量的动态障碍物, 且动态障碍物的影响范围是半径为 20 m 的球体。2 种不同场景下添加的动态障碍物坐标如表 5 所示。动态障碍物从不同的位置匀速出发, 无人机的起始点和目标点位置以及动态障碍物的起始点位置已在地图上标注。

图 8 和图 9 是多架多目标和多架同目标场景下 6 种融合算法的路径规划结果。图中黄色虚线、橘色虚线、蓝色虚线分别是由 6 种优化算法预先规划出的全局航迹, 对应颜色的实线是利用 IDWA 由实时信息生成的实时航迹。观察这 6 种融合算法生成的航迹结果可知, 改进的融合算法 IPSOBOA-IDWA

表 5 2 种不同场景下动态障碍物的坐标设置

Table 5 Coordinate settings for dynamic obstacles in two different scenarios

场景	项目	起始点坐标	目标点坐标
多架多目标	动态障碍物 1	(500, 700, 250)	(1 000, 500, 250)
	动态障碍物 2	(800, 500, 250)	(200, 500, 250)
	动态障碍物 3	(200, 400, 250)	(600, 200, 250)
多架同目标	动态障碍物 4	(800, 500, 250)	(200, 500, 250)

在初始阶段就可以快速调整好姿态, 充分利用已知的全局路径信息, 沿着预先规划的全局航迹飞行, 且能够实时避开不同方向飞来的 3 个障碍物, 有效降低了无人机的转弯频率和飞行高度, 提高了其稳定性和实际可飞性, 生成了更加平滑的航迹。

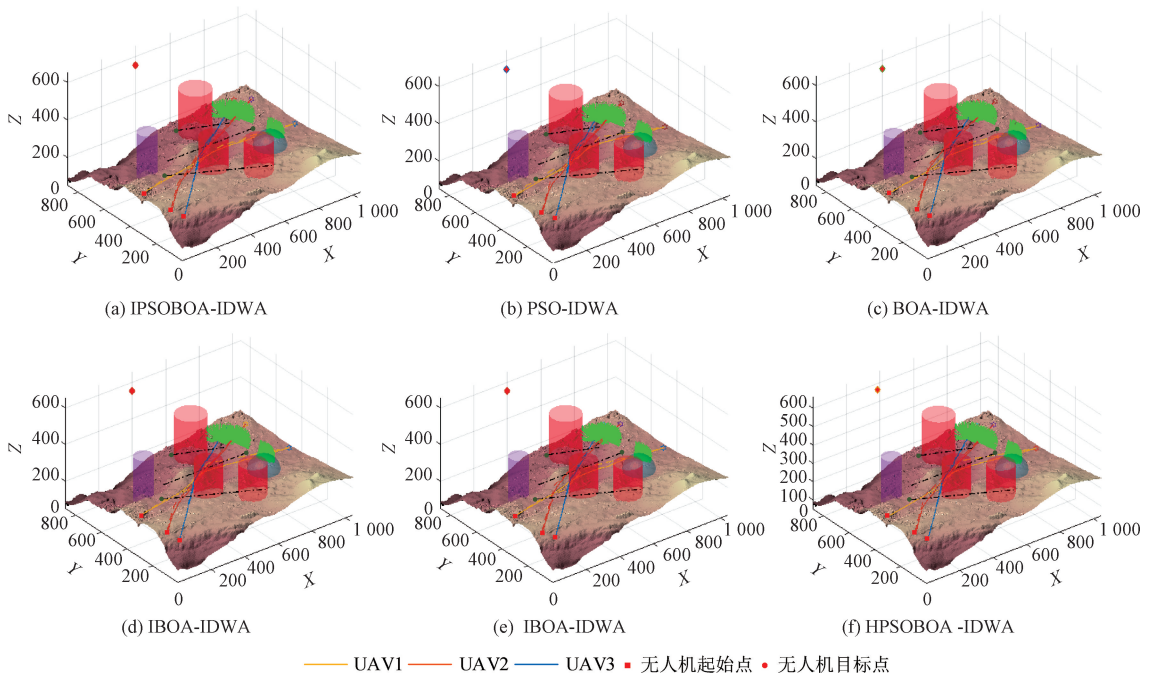


图 8 动态环境下多架多目标场景中 6 种算法的路径规划结果

Figure 8 Path planning results of six algorithms in multi-aircraft and multi-target scenarios in dynamic environments

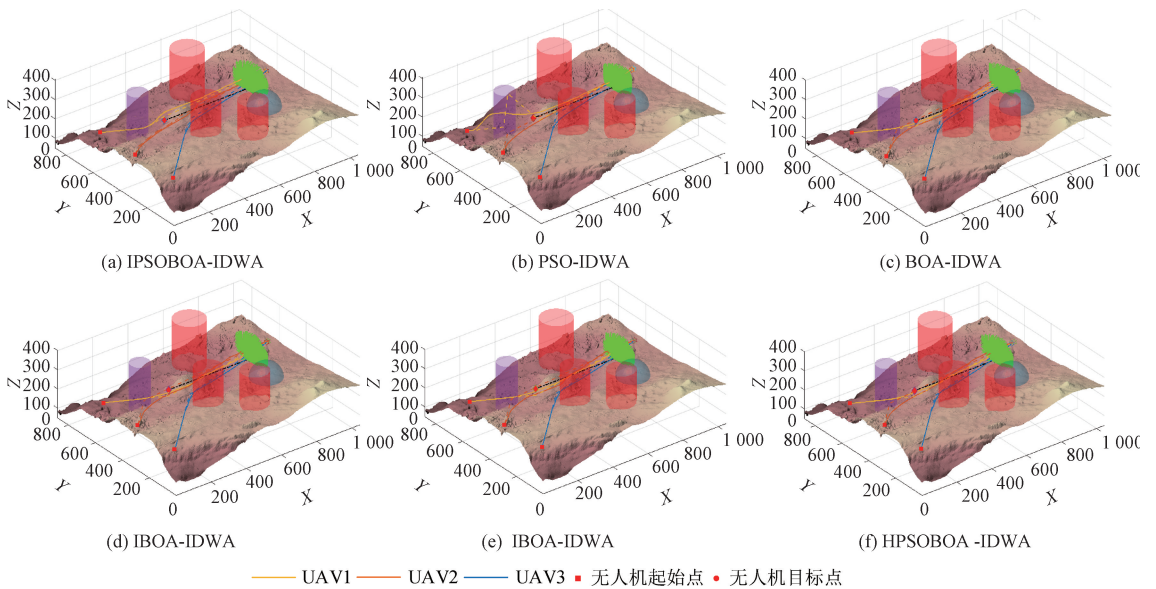


图 9 动态环境下多架同目标场景中 6 种算法的路径规划结果

Figure 9 Path planning results of six algorithms in a dynamic environment with multiple aircraft targeting the same scene

5 结论

本文提出了一种多策略融合的粒子群-蝴蝶优化改进算法 (IPSOBOA), 并将其用于求解基于四约束的无人机路径规划模型。通过三维静态和动态环境下不同的应用场景, 验证了本文算法改进策略的有效性和优越性。

(1) 采用 Tent 混沌映射结合反向学习策略进行种群的初始化, 能够有效提高种群的多样性; 采用非线性参数和动态转换概率等控制机制, 更好地平衡

算法的全局搜索和局部开发能力; 将 PSO 引入 BOA 中, 融入随机惯性权重, 并在全局搜索时考虑该个体的历史最优位置, 在局部开发阶段引入速度项, 设计了一个速度动态变化的位置更新方程, 以提高搜索效率。

(2) 为了验证 IPSOBOA 的有效性, 将其与 BOA 及其他 6 种算法分别应用于三维静态和动态环境下验证分析。结果表明: 在静态环境下, IPSOBOA 相较于 BOA, 最优适应度值分别优化 1.8%、17% 和 44%, 路径长度分别优化 1.8%、42.4% 和 61.3%; 在

动态环境下,本文改进的融合算法(IPSBOA-ID-WA)具有更好的表现效果,不仅能够沿着预先规划的全局航迹飞行,而且能够实时避障,有效减少拐角数量,生成更加平滑的路径,为多约束条件下的无人机路径规划提供更优的解决方案。

参考文献:

- [1] LIU X Y, LI G Q, YANG H Y, et al. Agricultural UAV trajectory planning by incorporating multi-mechanism improved grey wolf optimization algorithm[J]. *Expert Systems with Applications*, 2023, 233: 120946.
- [2] WU Y, NIE M T, MA X L, et al. Co-evolutionary algorithm-based multi-unmanned aerial vehicle cooperative path planning[J]. *Drones*, 2023, 7(10): 606.
- [3] YANG L M, ZHANG X Y, LI Z P, et al. A LODBO algorithm for multi-UAV search and rescue path planning in disaster areas[J]. *Chinese Journal of Aeronautics*, 2025, 38(2): 103301.
- [4] LI D Y, QIANG Y Z, MOTT J H. Hazard analysis of large cargo delivery UAVs under the Chinese air traffic control system[C]//2021 Systems and Information Engineering Design Symposium (SIEDS). Piscataway:IEEE, 2021: 1-6.
- [5] 高岳林,武少华. 基于自适应粒子群算法的机器人路径规划[J]. *郑州大学学报(工学版)*, 2020, 41(4): 46-51.
- GAO Y L, WU S H. Robot path planning based on adaptive particle swarm optimization[J]. *Journal of Zhengzhou University (Engineering Science)*, 2020, 41(4): 46-51.
- [6] 虞馥泽,潘大志. 改进萤火虫算法求解多机器人路径规划[J]. *计算机应用研究*, 2023, 40(3): 800-804.
- YU F Z, PAN D Z. Improved firefly algorithm for multi-robot path planning[J]. *Application Research of Computers*, 2023, 40(3): 800-804.
- [7] YU X B, JIANG N J, WANG X M, et al. A hybrid algorithm based on grey wolf optimizer and differential evolution for UAV path planning[J]. *Expert Systems with Applications*, 2023, 215: 119327.
- [8] XU J H, YAN X F, NIU Y B. An improved butterfly optimization algorithm for UAV path planning in complex environment[C]//2022 IEEE Smartworld, Ubiquitous Intelligence & Computing, Scalable Computing & Communications, Digital Twin, Privacy Computing, Metaverse, Autonomous & Trusted Vehicles (SmartWorld/UIC/ScalCom/DigitalTwin/PriComp/Meta). Piscataway: IEEE, 2022: 1044-1050.
- [9] 尚俊娜,罗照旺. 基于改进蝴蝶搜索算法的DGPS整周模糊度快速解算[J]. *中国惯性技术学报*, 2024, 32(2): 139-145.
- SHANG J N, LUO Z W. Fast resolution of DGPS integer ambiguity based on improved butterfly optimization algorithm[J]. *Journal of Chinese Inertial Technology*, 2024, 32(2): 139-145.
- [10] LI Y, YU X M, LIU J S. An opposition-based butterfly optimization algorithm with adaptive elite mutation in solving complex high-dimensional optimization problems[J]. *Mathematics and Computers in Simulation*, 2023, 204: 498-528.
- [11] ZHOU H Y, ZHANG G C, WANG X J, et al. Structural identification using improved butterfly optimization algorithm with adaptive sampling test and search space reduction method[J]. *Structures*, 2021, 33: 2121-2139.
- [12] LONG W, JIAO J J, LIANG X M, et al. Pinhole-imagining-based learning butterfly optimization algorithm for global optimization and feature selection[J]. *Applied Soft Computing*, 2021, 103: 107146.
- [13] PENG M S, WEI X X, HUANG H J. A chaotic adaptive butterfly optimization algorithm[J]. *Evolutionary Intelligence*, 2024, 17(1): 493-511.
- [14] LYU L X, YANG F. MMPA: a modified marine predator algorithm for 3D UAV path planning in complex environments with multiple threats[J]. *Expert Systems with Applications*, 2024, 257: 124955.
- [15] ARORA S, SINGH S. Butterfly optimization algorithm: a novel approach for global optimization[J]. *Soft Computing*, 2019, 23(3): 715-734.
- [16] 胡廷银. 面向复杂环境的无人机航迹规划研究[D]. 西安:西安电子科技大学, 2022.
- HU T Y. Research on UAV path planning for complex environment[D]. Xi'an: Xidian University, 2022.
- [17] 刘苗苗,张玉莹,郭景峰,等. 融合多策略改进的自适应狮群优化算法[J]. *北京邮电大学学报*, 2024, 47(1): 85-93.
- LIU M M, ZHANG Y Y, GUO J F, et al. Improved adaptive lion swarm optimization algorithm based on multi-strategy[J]. *Journal of Beijing University of Posts and Telecommunications*, 2024, 47(1): 85-93.
- [18] 王依柔,张达敏. 融合正弦余弦和无限折叠迭代混沌映射的蝴蝶优化算法[J]. *模式识别与人工智能*, 2020, 33(7): 660-669.
- WANG Y R, ZHANG D M. Butterfly optimization algorithm combining sine cosine and iterative chaotic map with infinite collapses[J]. *Pattern Recognition and Artificial Intelligence*, 2020, 33(7): 660-669.
- [19] KENNEDY J, EBERHART R. Particle swarm optimization [C]//Proceedings of ICNN'95-International Conference on Neural Networks. Piscataway:IEEE, 1995: 1942-1948.

- [20] 丁元明, 夏清雨, 张然, 等. 蝴蝶优化算法研究综述[J]. 科学技术与工程, 2023, 23(7): 2705-2716.
DING Y M, XIA Q Y, ZHANG R, et al. Review of literature survey of butterfly optimization algorithm[J]. Science Technology and Engineering, 2023, 23(7): 2705-2716.
- [21] FOX D, BURGARD W, THRUN S. The dynamic window approach to collision avoidance[J]. IEEE Robotics & Automation Magazine, 1997, 4(1): 23-33.
- [22] 王海群, 宋国章, 晁帅, 等. 基于蜣螂算法和DWA算法的机器人动态路径规划[J]. 制造技术与机床, 2024(12): 21-29.
WANG H Q, SONG G Z, CHAO S, et al. Dynamic path planning of robot based on dung beetle algorithm and DWA algorithm [J]. Manufacturing Technology and Machine Tools, 2024(12): 21-29.
- [23] 孟广双, 高德东. 改进蝴蝶优化算法及其在冗余机械臂逆运动学求解中的应用[J]. 制造技术与机床, 2022(8): 91-96.
MENG G S, GAO D D. Improved butterfly optimization algorithm and its application in solving inverse kinematics problem of redundant manipulators [J]. Manufacturing Technology & Machine Tool, 2022(8): 91-96.
- [24] 张孟健, 汪敏, 王霄, 等. 混合粒子群-蝴蝶算法的WSN节点部署研究[J]. 计算机工程与科学, 2022, 44(6): 1013-1022.
ZHANG M J, WANG M, WANG X, et al. A hybrid particle swarm-butterfly algorithm for WSN node deployment [J]. Computer Engineering & Science, 2022, 44(6): 1013-1022.
- [25] ZHANG M J, LONG D Y, QIN T, et al. A chaotic hybrid butterfly optimization algorithm with particle swarm optimization for high-dimensional optimization problems [J]. Symmetry, 2020, 12(11): 1800.

Based on Butterfly Optimization Improvement Algorithm for UAVs 3D Path Planning

WANG Guoguo^{1,2}, BAI Yijie², CHAI Mengjuan², YU Daojie², WANG Yicheng²

(1. School of Cyberspace Security, Zhengzhou University, Zhengzhou 450001, China; 2. School of Information System Engineering, Information Engineering University, Zhengzhou 450001, China)

Abstract: Aiming at the problem of high complexity of path planning and difficulty in generating high-quality paths in effective time for UAVs in complex threat environments, a multi-strategy fusion particle swarm-butterfly optimization improvement algorithm (IPSOBOA) was proposed. The initial population was optimized through tent chaotic mapping combined with inverse learning strategy to enhance the diversity of the population; nonlinear parameter adjustment and dynamic conversion probability mechanism were introduced to balance the global search and local exploitation; combined with the particle swarm algorithm, the velocity term was introduced in the local search phase, and the position update equation with dynamic change of velocity was proposed to improve the search efficiency. Based on four benchmark test functions and three different threat scenarios respectively, IPSOBOA was compared with the butterfly optimization algorithm and various other optimization algorithms. The experimental results showed that, compared with the butterfly optimization algorithm in three scenarios of the static environment, IPSOBOA optimized the optimal fitness value by 1.8%, 17%, and 44% respectively, and optimized the path length by 1.8%, 42.4%, and 61.3% respectively; in the dynamic environment, it combined global path tracking and real-time obstacle avoidance to generate smoother and safer paths.

Keywords: butterfly optimization algorithm; dynamic window approach; tent chaotic mapping; inverse learning; path planning