

DOI:10.13232/j.cnki.jnju.2026.01.011

## 基于秃鹰-天鹰混合群智能优化的无人机任务分配方法

吴超凡<sup>1,2</sup>, 黄鹤<sup>1,2\*</sup>, 温夏露<sup>3</sup>, 杨澜<sup>4</sup>, 王会峰<sup>1</sup>

(1. 长安大学电子与控制工程学院, 西安, 710064; 2. 西安市智慧高速公路信息融合与控制重点实验室, 西安, 710064;  
3. 西安比亚迪汽车有限公司, 西安, 710118; 4. 长安大学信息工程学院, 西安, 710064)

**摘要:**针对现有多无人机任务分配模型以线性距离为度量, 忽略地形、威胁源等环境约束, 以及传统秃鹰优化算法存在种群多样性不足、易陷局部最优等缺陷, 提出一种基于秃鹰-天鹰混合优化(Hybrid Bald Eagle-Aquila Optimization, HBAO)的多无人机任务分配方法. 首先, 构建融合三维地形、威胁源及无人机物理约束的多旅行商任务分配模型, 通过代价函数实现任务分配与航迹规划的紧耦合; 然后, 设计任务分配编码, 改进优化策略, 将天鹰优化算法的扩展-缩小搜索策略融入秃鹰算法的全局搜索阶段以提升探索效率, 并引入折射反向学习机制增强种群多样性, 有效平衡算法开发与探索能力; 最后, 设计双模型实验来验证算法效能. 结果表明, 提出的HBAO算法在复杂战场环境下求解精度和收敛速度较高, 其综合性能优于五种对比算法, 并且全局代价显著降低, 能生成低能耗、高适应性的任务分配方案.

**关键词:** 无人机, 任务分配, 路径规划, 混合群体智能优化算法

中图分类号: TP301.6

文献标志码: A

## UAV task allocation method based on hybrid bald eagle-aquila optimization

Wu Chaofan<sup>1,2</sup>, Huang He<sup>1,2\*</sup>, Wen Xialu<sup>3</sup>, Yang Lan<sup>4</sup>, Wang Huifeng<sup>1</sup>

(1. School of Electronic and Control Engineering, Chang'an University, Xi'an, 710064, China; 2. Key Laboratory of Intelligent Expressway Information Fusion and Control, Xi'an, 710064, China; 3. Xi'an BYD Auto Co., Ltd, Xi'an, 710118, China;  
4. School of Information Engineering, Chang'an University, Xi'an, 710064, China)

**Abstract:** To address the shortcomings of existing multi-UAV task allocation models, which use linear distance as a metric and ignore environmental constraints such as terrain and threat sources, and to solve the problem of the traditional Bald Eagle optimization algorithm, which suffers from insufficient population diversity and proneness to local optima, a multi-UAV task allocation method based on Hybrid Bald Eagle-Aquila Optimization (HBAO) is proposed. First, a multi-traveling salesman task allocation model is constructed that integrates three-dimensional terrain, threat sources, and UAV physical constraints. Task allocation and trajectory planning are tightly coupled via a cost function. Then, a task allocation encoding is designed and the optimization strategy is improved. The expand-contract search strategy of the Aquila optimization algorithm is integrated into the global search phase of the Bald Eagle algorithm to improve exploration efficiency. A refractive back-learning mechanism is introduced to enhance population diversity, effectively balancing algorithm development and exploration capabilities. Finally, dual-model experiments are designed to validate the algorithm's performance. Results show that the proposed HBAO algorithm achieves high solution accuracy and convergence speed in complex battlefield environments. Its overall performance outperforms five competing algorithms, with significantly reduced global cost, while generating low-energy, highly adaptable task allocation solutions.

基金项目: 国家自然科学基金(52472446), 中央高校基本科研业务费资助项目(300102325501), 中国交通教育研究会教育科研课题(JT2024YB444)

收稿日期: 2025-11-13

\* 通信联系人, E-mail: huanghe@chd.edu.cn

**Keywords:** UAV, task allocation, path planning, hybrid swarm intelligence optimization algorithm

近年来,无人机技术凭借其高效、灵活和低成本的优势,在输电线路巡检、军事侦察等领域展现出重要应用价值<sup>[1-2]</sup>. 多无人机协同任务分配作为其核心技术,需在复杂环境的约束下实现资源优化配置,其本质属于多维离散组合优化的 NP-hard 问题.

当前研究主要围绕任务分配模型的构建与求解算法优化展开. 在模型构建方面,宋育武等<sup>[3]</sup>采用整数线性规划建立了任务优化分配模型,并通过引入遗传算法及创新编码方案,有效降低了模型求解时的复杂度. Jeon et al<sup>[4]</sup>将任务分配问题描述为混合整数线性规划模型,并利用混合整数线性编程和遗传算法在含障碍的多目标、多任务环境中进行了数值模拟,旨在比较不同方法在最优性和求解效率上的表现. 然而,随着问题规模的扩大,该方法的计算开销急剧上升,且在面对复杂约束条件时表现出较大局限性,限制了其在实际复杂任务场景中的应用. 针对这一问题,部分学者开始探索群体智能方法. Schwarzrock et al<sup>[5]</sup>通过抽象提取群体智能方法的特征,提出了三种算法变体——分配循环、排序和分配循环以及限制和分配环路,这些方法在无人机任务动态分配方面取得了良好效果. 王树朋等<sup>[6]</sup>提出一种自适应遗传算法,在算法运行过程中实时动态调整交叉率和变异率,以克服标准遗传算法易陷入局部最优的缺点,无人机飞行航程的均衡性更好. Jia et al<sup>[7]</sup>设计了一种多层编码遗传算法,兼具全局搜索和并行处理能力,适用于异构多无人机任务分配问题,以提升协同任务分配效果. 然而,单一群体智能算法在处理高维、强约束的复杂任务分配问题时,常面临以下挑战:(1)种群多样性不足使算法容易陷入局部最优;(2)全局探索与局部开发能力难以有效平衡,导致收敛速度和解的质量受限;(3)对问题结构及约束的适应性不足,鲁棒性有待提高. Tang et al<sup>[8]</sup>进一步研究了群体智能算法在多无人机协同任务分配及路径规划中的应用,结果表明该方法具有较强的适应性和前景,但其将任务分配与航迹规划分阶段求解的方式忽

略了两者之间的紧密耦合,往往导致搜索空间受限,影响全局最优性.

针对上述问题,研究者逐步转向混合优化策略,以突破单一算法在种群多样性、全局搜索能力等方面的局限. Zhang et al<sup>[9]</sup>融合引力搜索与遗传算法构建混合模型,在复杂场景中展现出更强的适应性;彭滋滔等<sup>[10]</sup>针对无人机任务分配问题,设计了一种融合遗传算法和狼群优化算法的位置更新策略,能有效解决无人机任务分配问题,且在收敛速度、跳出局部最优解能力、解的优越性等方面优于其他类型的改进算法. 这类混合策略通过整合不同算法的搜索特性,弥补单一算法的固有限制,在提升搜索效率、收敛精度及解的稳定性方面展现出显著优势.

秃鹰搜索(Bald Eagle Search, BES)<sup>[11]</sup>算法通过模拟秃鹰选择、搜索和俯冲捕食三阶段的行为,兼具快速收敛与强全局探索能力. 其独特的螺旋搜索机制和动态权重调整策略,可有效平衡开发与探索过程. 然而,传统 BES 算法在处理高维离散问题时仍存在种群多样性不足、易陷局部最优等缺陷,需结合场景特性进行改进. 基于以上背景,本研究提出了一种基于秃鹰-天鹰混合优化算法的多无人机任务分配方法. 该方法旨在充分利用秃鹰搜索算法的快速收敛特性和天鹰算法的全局搜索优势,通过算法混合优化,有效解决传统方法在大规模、复杂约束条件下的不足,为多无人机协同任务分配提供一种更为高效、鲁棒的解决方案.

## 1 任务分配模型

在已知空域执行攻击任务时,多架无人机的任务分配需依据目标函数计算任务代价和其他评价指标,以获取最优执行方案. 将任务分配问题转化为多旅行商问题(Multiple Traveling Salesman Problem, MTSP)进行求解,在满足各项约束条件下,获取多无人机整体代价最低的任务序列. 假设在战场环境任务执行中,无人机数量为  $N$ , 任务数量为  $P$ , 任务点集合

$T=[T_1, T_2, \dots, T_p]$ , 无人机集合  $U=[U_1, U_2, \dots, U_N]$ . 设置所有无人机从固定点出发, 考虑到侦察、攻击等任务的单次有效性, 并且为了避免资源浪费与任务冗余, 本研究遵循 MTSP 经典假设, 即每个任务点只能由一架无人机执行一次, 并被分配至唯一的任务序列中, 每架无人机按照其任务序列完成所有分配的任务。

在大多数任务分配模型中, 通常采用欧氏距离来衡量无人机与目标之间的距离。然而, 在实战场景下, 由于地形起伏、威胁源分布等复杂因素, 无人机难以始终沿直线飞行, 将欧氏距离作为飞行距离会与实际情况存在较大偏差。为了更接近实际, 针对全局静态环境, 将无人机自身物理约束和威胁源等因素纳入考量, 构建出适用于多无人机任务分配的综合代价函数模型。该模型融合路径规划的相关约束, 实现了任务分配与后续路径规划的紧耦合, 以确保任务执行的合理性和可行性。

**1.1 地形约束** 建模时地形约束分为两种, 分别是地势低平的平原和地势较高的山丘<sup>[12-13]</sup>。其中, 山丘影响较大。针对山丘进行三维建模如下:

$$H(x, y) = h \cdot e^{\left\{ \frac{(x-x_0)^2}{\omega_1} + \frac{(y-y_0)^2}{\omega_2} \right\}} \quad (1)$$

其中,  $(x, y)$  为三维空间点的坐标,  $(x_0, y_0)$  为三维空间中山丘的中心坐标,  $h$  为山丘的高度参数,  $\omega_1$  和  $\omega_2$  是山丘陡峭度参数。无人机飞行安全的最低高度要求为 0.1 km。

航迹点地形威胁代价函数如下:

$$f_{H,j}^i = \begin{cases} K_{H1}, h_j^i - H_j^i \leq 0 \\ K_{H2}, 0 < h_j^i - H_j^i \leq 0.1 \\ 0, h_j^i - H_j^i > 0.1 \end{cases} \quad (2)$$

其中,  $f_{H,j}^i, h_j^i, H_j^i$  分别为第  $i$  架无人机在第  $j$  个航迹点处对应的地形代价、飞行高度和地形高度。  $K_{H1}, K_{H2}$  分别为不同高度下的两个相异的地形威胁系数。根据地形条件对无人机的飞行边界进行限制, 规定其水平飞行范围和最大飞行高度, 以确保飞行的可控性。

**1.2 威胁模型约束** 在对无人机突防进行建模时, 雷达、防空火炮、地空导弹和禁飞区等视作主要风险因素。为了简化建模过程, 依据各威胁特

性能确定其影响范围和空间分布, 并以等效地形进行替换<sup>[14]</sup>。绝大多数战场威胁源(如雷达、防空导弹、高炮)的探测概率和作用效能, 都随着目标距离的增加而单调递减, 因此假设威胁源的风险值与无人机到威胁源中心的距离成反比。将上述威胁源等效为数学模型, 定义航迹点在威胁区域内的计算代价如下:

$$f_{P,j}^{m,i} = \begin{cases} 0, \|(x,y)_j^i - C_n^m\|_2 \geq R_{\max}^m \\ K_{\text{thr}}^m \left\| R_{\max}^m - \|(x,y)_j^i - C_n^m\|_2 \right\|, \text{else} \end{cases} \quad (3)$$

其中,  $(x, y)_j^i$  为第  $i$  架无人机在第  $j$  个航迹点的笛卡尔坐标,  $f_{P,j}^{m,i}$  为第  $i$  架无人机第  $j$  个航迹点对应的第  $m$  类威胁源的代价,  $K_{\text{thr}}^m$  为第  $m$  类威胁源的校正系数,  $C_n^m$  和  $R_{\max}^m$  分别为第  $m$  类的第  $n$  个威胁源中心及其最大作用半径。

**1.3 单无人机约束** 本研究模型针对中小型固定翼无人机或具备类似运动特性的无人机平台进行构建, 该类平台是战场侦察与打击任务中的典型载体。单无人机在飞行过程中, 其运动受到物理特性的制约, 主要包括拐弯角  $\alpha$ 、俯仰角  $\beta$  和续航时间  $T$  约束<sup>[15]</sup>, 表达式如下:

$$J_{\alpha, \text{angle}, j}^i = \begin{cases} 0, & \alpha_j^i \leq \alpha_{\max} \\ K_{\alpha}, & \alpha_j^i > \alpha_{\max} \end{cases} \quad (4)$$

$$J_{\beta, \text{angle}, j}^i = \begin{cases} 0, & \beta_j^i \leq \beta_{\max} \\ K_{\beta}, & \beta_j^i > \beta_{\max} \end{cases} \quad (5)$$

$$J_{T, \text{time}, j}^i = \begin{cases} 0, & T^i \leq T_{\max} \\ K_T, & T^i > T_{\max} \end{cases} \quad (6)$$

其中,  $K_{\alpha}, K_{\beta}, K_T$  分别为拐弯角、俯仰角和续航时间的威胁系数。  $\alpha_j^i, \beta_j^i, T^i$  分别为第  $i$  架无人机在第  $j$  个航迹点处对应的拐弯角、俯仰角和续航时间。  $\alpha_{\max}, \beta_{\max}, T_{\max}$  分别为无人机对应的最大拐弯角、最大俯仰角和最长时间。  $J_{\alpha, \text{angle}, j}^i, J_{\beta, \text{angle}, j}^i, J_{T, \text{time}, j}^i$  分别为第  $i$  架无人机在第  $j$  个航迹点处对应拐弯角、俯仰角和续航时间的代价函数。无人机的自身约束代价函数为:

$$f_{J,j}^i = J_{\alpha, \text{angle}, j}^i + J_{\beta, \text{angle}, j}^i + J_{T, \text{time}, j}^i \quad (7)$$

其中,  $f_{J,j}^i$  为无人机在第  $j$  个航迹点自身约束代价函数。

**1.4 航迹规划建模** 在三维空间环境下的无人机航迹规划中, 相邻点之间存在高度和方位的变

化. 因此, 当无人机从当前航迹点移动到下一个航迹点时, 必须考虑偏航角和爬升角的影响. 由机身机械限制决定的物理约束对这些角度参数施加了严格的界限, 以防止过度机动命令带来的失

$$d_{j,j+1} = \sqrt{(x_j - x_{j+1})^2 + (y_j - y_{j+1})^2 + (z_j - z_{j+1})^2} \quad (8)$$

$$\alpha_j = \arccos \frac{(x_j - x_{j-1})(x_{j+1} - x_j) + (y_j - y_{j-1})(y_{j+1} - y_j)}{\sqrt{(x_j - x_{j-1})^2 + (y_j - y_{j-1})^2} \sqrt{(x_{j+1} - x_j)^2 + (y_{j+1} - y_j)^2}} \quad (9)$$

$$\beta_j = \arctan \frac{|z_j - z_{j-1}|}{\sqrt{(x_j - x_{j-1})^2 + (y_j - y_{j-1})^2}} \quad (10)$$

其中,  $d_{j,j+1}$  表示航迹点  $j$  和  $j+1$  之间的航迹长度,  $\alpha_j$  表示第  $j$  个航迹点对应航迹段的拐弯角,  $\beta_j$  表示该航迹段的俯仰角.

**1.5 非均匀三次 B 样条平滑路径算法** 由于无人机的初始航迹可能存在航向突变、曲率过大等问题, 无法直接满足无人机的飞行性能要求, 增加无人机飞行风险. 因此, 需要对无人机初始航迹进行平滑处理. B 样条曲线是一种基于 B 样条基

$$\begin{cases} B_{p,0}(x) = \begin{cases} 1, & t_p \leq x \leq t_{p+1} \\ 0, & \text{else} \end{cases} \\ B_{p,u}(x) = \frac{x - t_p}{t_{p+u} - t_p} B_{p,u-1}(x) + \frac{t_{p+u+1} - x}{t_{p+u+1} - t_{p+1}} B_{p+1,u-1}(x), & u > 0 \end{cases} \quad (11)$$

函数的曲线表示方法, 具有良好的局部可控性和光滑性. 非均匀三次 B 样条曲线是 B 样条曲线的一种特殊形式, 其节点矢量是非均匀分布的, 能更好地适应无人机航迹点参数分布不均匀的情况, 表达式如式(11)所示:

稳风险. 令无人机的当前位置表示为  $(x_j, y_j, z_j)$ , 由前后相邻航迹点组成的航迹段定义为第  $j$  个航迹点对应的航迹段, 则当前的航迹长度、拐弯角和俯仰角计算式如式(8)~(10)所示:

函数的曲线表示方法, 具有良好的局部可控性和光滑性. 非均匀三次 B 样条曲线是 B 样条曲线的一种特殊形式, 其节点矢量是非均匀分布的, 能更好地适应无人机航迹点参数分布不均匀的情况, 表达式如式(11)所示:

如式(15)所示:

$$F_i = (w_1 f_{u_i}^i + w_2 f_{v_i}^{m,i} + w_3 f_{z_i}^i) + w_4 L_{\text{length}} + w_5 L_{\text{height}} \quad (15)$$

其中,  $F_i$  为第  $i$  架无人机航迹的总代价,  $w_i$  ( $i = 1, 2, \dots, 5$ ) 分别为各约束条件对应的权重系数.

综上, 代价函数量化了任务分配方案在飞行安全性、任务可行性、飞行效率等方面的综合代价, 实现了任务分配和航迹可行性评估的紧耦合优化.

## 2 秃鹰优化算法

BES 算法模拟了秃鹰捕食猎物的行为, 捕食过程由选择区域、搜索和俯冲捕获三个阶段构成协同序列, 数学模型如下.

**2.1 选择搜索空间** 在选择区域阶段, 秃鹰会挑选猎物聚集数量最多的区域当作区域空间, 该阶段秃鹰行为的数学描述如下:

$$p_{i,\text{new}} = p_{\text{best}} + a \cdot \text{rand}(p_{\text{mean}} - p_i) \quad (16)$$

**1.6 任务分配约束** 在无人机任务分配过程中, 目标是优化飞行路径, 缩短飞行距离, 并保持飞行过程高度的稳定性, 减少剧烈升降. 因此, 定义航迹段长度约束  $L_{\text{length}}$  和高度约束  $L_{\text{height}}$  如式(12)和式(13)所示:

$$L_{\text{length}} = \sum_{i=1}^N \sum_{j=1}^P \sum_{k=1}^P d_{P_{jk}} A_{U_i, P_{jk}} \quad (12)$$

$$L_{\text{height}} = \sum_{i=1}^N \sum_{l=1}^{N_{P_{jk}}} \sqrt{\left( \frac{A_{U_i, P_{jk}}(z_l - z_{l+1})}{2} \right)^2} \quad (13)$$

$$A_{U_i, P_{jk}} = \begin{cases} 1, & \text{任务 } j \text{ 和 } k \text{ 在第 } i \text{ 架无人机的任务序列中} \\ 0, & \text{else} \end{cases} \quad (14)$$

其中,  $P_{jk}$  为任务  $j$  到任务  $k$  的航迹段,  $d_{P_{jk}}$  为任务  $j$  到任务  $k$  的航迹段长度,  $U_i$  为第  $i$  架无人机,  $N_{P_{jk}}$  为航迹段  $P_{jk}$  中的航迹点数,  $z_l$  和  $z_{l+1}$  为相邻航迹点的  $z$  轴坐标,  $A_{U_i, P_{jk}}$  为根据任务序列的判断因子.

定义任务分配中的无人机航迹总代价计算式

其中,  $a$  为秃鹰位置变化控制参数, 取值为  $(1.5, 2)$ ,  $\text{rand}$  为介于  $(0, 1)$  的随机权重系数,  $p_{\text{best}}$  为秃鹰个体历史最优坐标,  $p_{\text{mean}}$  为综合先后两次秃鹰更新位置的平均值,  $p_i$  为种群中第  $i$  只秃鹰在解空间中的坐标,  $p_{i,\text{new}}$  为位置更新后该秃鹰的新位置.

**2.2 搜索空间猎物** 秃鹰在选定的搜索空间内搜索猎物, 沿螺旋轨迹在空间飞行, 同时通过随机改变飞行方向以加快搜索进程. 该阶段秃鹰行为的数学描述如下:

$$\theta(i) = A \cdot \pi \cdot \text{rand} \quad (17)$$

$$r(i) = \theta(i) + R \cdot \text{rand} \quad (18)$$

$$x_r(i) = r(i) \cdot \sin(\theta(i)), y_r(i) = r(i) \cdot \cos(\theta(i)) \quad (19)$$

$$x(i) = x_r(i) / \max(|x_r|), y(i) = y_r(i) / \max(|y_r|) \quad (20)$$

其中,  $A$  和  $R$  为控制搜索螺旋轨迹的参数, 变化范围分别为  $(0, 5)$  和  $(0.5, 2)$ ,  $\theta(i)$  为个体运动方向角,  $r(i)$  为运动半径参数,  $x(i)$  与  $y(i)$  为秃鹰在极坐标系中的位置坐标, 取值均为  $(-1, 1)$ . 此阶段秃鹰位置的更新式如式(21)所示:

$$p_{i,\text{new}} = p_i + x(i) \cdot (p_i - p_{\text{mean}}) + y(i) \cdot (p_i - p_{i+1}) \quad (21)$$

**2.3 俯冲捕获猎物** 秃鹰在搜索空间锁定目标猎物后, 迅速地飞向猎物, 对猎物进行俯冲捕获, 同时所有的秃鹰个体也向最佳位置飞行, 该阶段秃鹰行为的数学描述如下:

$$\theta(i) = A \cdot \pi \cdot \text{rand}, r(i) = \theta(i) \quad (22)$$

$$x_r(i) = r(i) \cdot \sinh(\theta(i)), y_r(i) = r(i) \cdot \cosh(\theta(i)) \quad (23)$$

$$x_1(i) = x_r(i) / \max(|x_r|), y_1(i) = y_r(i) / \max(|y_r|) \quad (24)$$

$$\begin{cases} \delta_x = x_1(i) \cdot (p_i - c_1 \cdot p_{\text{mean}}) \\ \delta_y = y_1(i) \cdot (p_i - c_2 \cdot p_{\text{mean}}) \end{cases} \quad (25)$$

$$p_{i,\text{new}} = \text{rand} \cdot p_{\text{best}} + \delta_x + \delta_y \quad (26)$$

其中,  $\delta_x$  和  $\delta_y$  分别表示秃鹰在  $x$  与  $y$  方向上产生的位置增量,  $c_1$  与  $c_2$  表示秃鹰朝向最优位置运动时的惯性参数, 取值均为  $(1, 2)$ .

### 3 基于秃鹰-天鹰混合优化的任务分配

**3.1 任务分配编码** 将多无人机任务分配问题建模为带顺序约束的多旅行商问题, 采用随机键编码表示解方案, 在算法初始化阶段初始化秃鹰

种群, 计算式如式(27)所示:

$$X = \begin{bmatrix} x_{1,1} & x_{1,2} & \cdots & \cdots & x_{1,p} \\ x_{2,1} & x_{2,2} & \cdots & \cdots & x_{2,p} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{i,1} & x_{i,2} & \cdots & \cdots & x_{i,p} \end{bmatrix} \quad (27)$$

将秃鹰位置向量定义为连续变量  $X_i = (x_{i,1}, x_{i,2}, \dots, x_{i,p})$ , 其中,  $x_{i,p} \in [-100, 100]$ ,  $i$  为秃鹰数目,  $p$  为求解问题的维度. 将  $i$  映射为算法的种群数量,  $p$  映射为目标任务点的数目. 初始化及迭代过程中通过饱和策略约束值域, 计算式如下:

$$x_{i,p} = \begin{cases} -100, & \text{if } x_{i,p} < -100 \\ 100, & \text{if } x_{i,p} > 100 \\ x_{i,p}, & \text{otherwise} \end{cases} \quad (28)$$

对向量  $X_i$  中的元素进行升序排序, 得到的索引序列即全局任务执行顺序, 将有序任务序列均匀分割至  $N$  架无人机. 通过排序操作将连续变量转化为离散的任务序列, 确保算法在连续空间更新时仍处理离散问题, 最终解同时包含任务执行者与任务执行顺序.

**3.2 折射反向学习策略** 由于任务分配问题的复杂性, 要求算法具备强大的搜索能力和良好的种群多样性, 以提高多无人机任务分配的精度和效率.

折射反向学习 (Refracted Opposition-Based Learning, ROBL) 是一种新型的算法优化策略, 基于反向学习<sup>[16]</sup>框架, 通过引入光的折射定律来探索更优的候选解. 近年来, 该策略被应用于群智能算法的改进<sup>[17]</sup>, 并被证明可以有效提升基础算法的性能. 因此, 在秃鹰算法的基础上引入折射反向学习策略, 以进一步优化搜索过程. 该策略能有效增强种群的多样性, 使算法在更广泛的搜索空间内寻找更优解. 在初始化得到秃鹰种群的原始矩阵后, 通过 ROBL 方法, 随机选取一半种群并更新其位置. 在此过程中, 依据光的折射定律, 计算每个秃鹰个体的折射反向解, 并与原解进行比较, 选择适应度较小的个体作为新的种群位置, 以提升全局搜索能力和算法收敛精度. 更新式如下:

$$X(i+1) = (L_{\text{ubj}} + L_{\text{lbj}}) / 2 + (L_{\text{ubj}} + L_{\text{lbj}}) / 2k - X(i) / k \quad (29)$$

$$k = v/v' \tag{30}$$

其中,  $L_{ubj}$  和  $L_{lbj}$  为第  $j$  维的上边界和下边界,  $X(i+1)$  为更新后的秃鹰位置,  $X(i)$  为当前秃鹰位置,  $k$  为透镜的缩放系数,  $v$  为入射光线的长度,  $v'$  为折射光线的长度.

**3.3 混合秃鹰-天鹰优化** 多无人机任务分配不仅受地形、威胁源约束等复杂因素的影响,还要求算法能同时处理大范围的全局信息和局部区域的具体任务特征. 针对 BES 算法前期全局搜索能力不足的缺陷, 提出一种融合多群智能优化算法的创新性改进方案. 天鹰优化算法(Aquila Optimizer, AO)于 2021 年被提出<sup>[18]</sup>, 大量文献已证明其在全局优化任务中表现优异. 通过模拟天鹰捕食地面猎物的行为, 解决复杂的全局优化问题. 将

$$X(i+1) = \begin{cases} X_{best}(i) \cdot \left(1 - \frac{i}{T}\right) + (X_M(i) - X_{best}(i)) \cdot \text{rand}, & q < 0.5 \\ X_{best}(i) \cdot \text{Levy}(D) + X_R(i) + (y - x) \cdot \text{rand}, & q \geq 0.5 \end{cases} \tag{31}$$

$$X_M(i) = \frac{1}{N} \sum_{j=1}^N X(j), \forall j = 1, 2, \dots, D \tag{32}$$

其中,  $T$  为最大迭代次数,  $X_{best}(i)$  为当前全局最优解坐标,  $X_M(i)$  为当前迭代中所有秃鹰位置的平均值,  $X_R(i)$  为秃鹰的随机位置,  $\text{Levy}(D)$  为莱维飞行函数,  $D$  为问题维度,  $y$  和  $x$  为搜索中的螺旋形状.

**3.4 HBAO 算法流程** 秃鹰-天鹰混合优化(Hybrid Bald Eagle-Aquila Optimization, HBAO)算法在 BES 算法的基础上, 进行了两项核心改进, 其具体执行流程如图 1 所示.

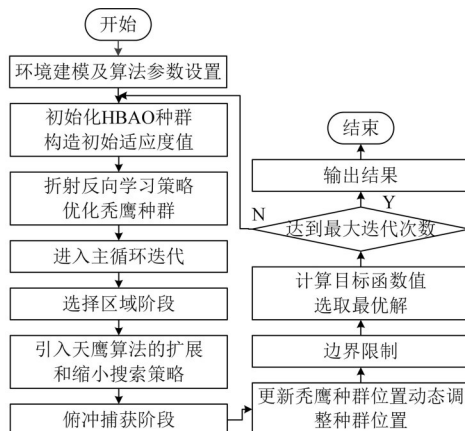


图 1 HBAO 算法流程图

Fig. 1 HBAO algorithm flow chart

传统的秃鹰算法搜索猎物的初始策略, 设计为天鹰优化算法的扩展和缩小搜索策略, 实现 BES 算法在全局和局部搜索之间的动态平衡, 更有效地探索解空间, 提高优化性能.

这一改进方案的核心在于混合秃鹰-天鹰优化的搜索策略. 其中, 扩展搜索策略使算法能在更广阔的搜索区域内寻找潜在的任务分配方案, 显著增强了全局寻优能力, 避免了在复杂地形和多约束环境中陷入局部最优解, 而缩小搜索策略有助于在已知较优解的局部区域内进行精细调整, 提升了局部搜索的效率和精度, 确保多无人机任务的分配更加合理和高效. 更新过程具体如下:

### 4 仿真实验与分析

**4.1 性能测试** 实验硬件仿真平台处理器为 12th Gen Intel (R) Core (TM) i7-12700H 2.30 GHz, 软件平台为 Matlab R2020a. 本文利用 CEC2020 单目标测试函数<sup>[19]</sup>验证算法来求解复杂函数的性能, 选取该测试函数集中不同类型的六个测试函数, 具体描述如表 1 所示. 对 HBAO 算法与 BES 算法、黑翅鸢优化算法<sup>[20]</sup>(Black-winged Kite Algorithm, BKA)、麻雀优化算法<sup>[21]</sup>(Spar-

表 1 测试函数描述

Table 1 Test function description

ID	函数名称	函数类型	最优值
$F_1$	Shifted and Rotated Bent Cigar Function	单峰函数	100
$F_2$	Shifted and Rotated Schwefel's Function	简单多峰函数	1100
$F_3$	Shifted and Rotated Lunacek Bi-Rastrigin Function	简单多峰函数	700
$F_4$	Expanded Rosenbrock's plus Griewangk's Function	简单多峰函数	1900
$F_6$	Hybrid Function 2 ( $N=4$ )	混合函数	1600
$F_8$	Composition Function 1 ( $N=3$ )	组合函数	2200

row Search Algorithm, SSA)、鹈鹕优化算法<sup>[22]</sup> (Pelican Optimization Algorithm, POA)以及蜣螂优化算法<sup>[23]</sup> (Dung Beetle Optimizer, DBO)进行性能验证比较.

算法维度设置为15,最大迭代次数设置为500,各算法独立运行30次.各测试函数的三维参数空间及算法收敛曲线如图2所示,其中,横轴 $t$ 为迭代次数,纵轴 $f$ 为最优适应度值.各测试函数下算法的平均最优适应度值与排名结果如表2所示.由图2和表2的性能评估结果可以看出,

HBAO算法在各类型的测试函数中均展现出最优的综合性能.在单峰函数 $F_1$ 中,HBAO算法以极低的最优适应度值远超其他算法,表明其具备快速收敛至最优解的能力.在多模态函数 $F_4$ 中,各算法以较快的收敛速度找到最优值,而HBAO算法具有更高的寻优精度,适应度值最优,验证了该算法能实现全局搜索与局部开发的高效平衡.此外,HBAO算法的最优适应度值普遍比次优算法低一个数量级,进一步凸显其精度和稳定性.因此,HBAO算法凭借单峰函数中的快速收敛能力、混合场景下的鲁棒性及显著低于其他算法的

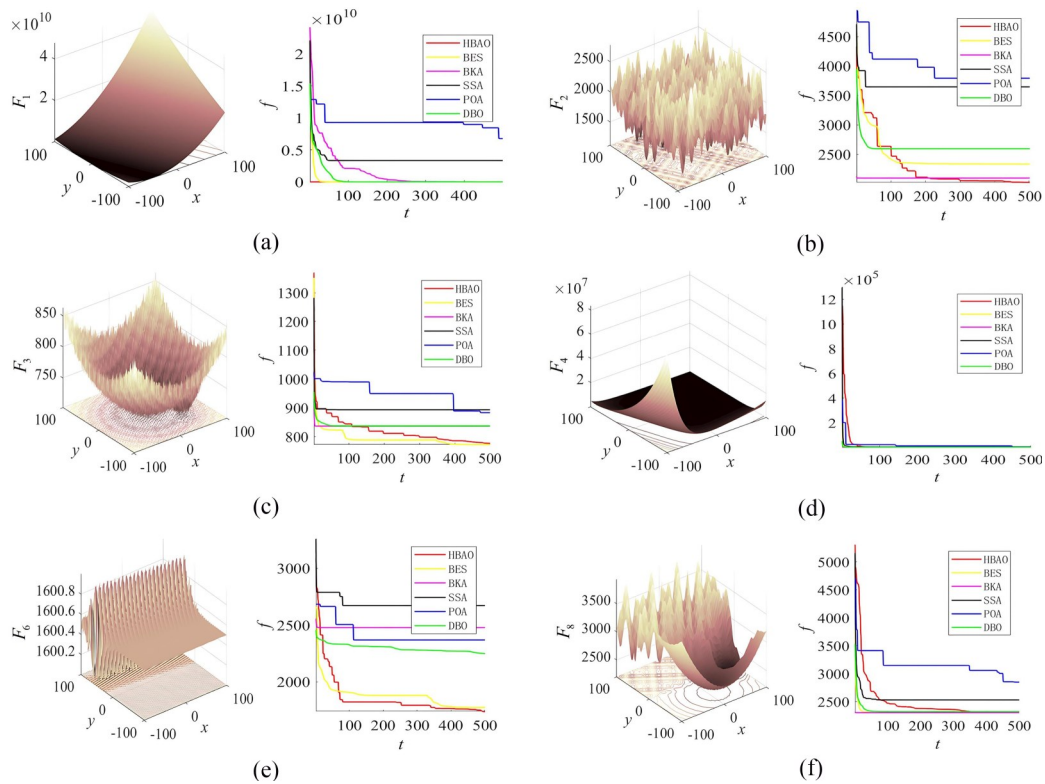


图2 各测试函数三维参数空间及算法收敛曲线

Fig. 2 Three-dimensional parameter space of each test function and algorithm convergence curve

表2 各测试函数下算法的平均最优适应度值

Table 2 The average optimal fitness value of the algorithm under each test function

算法	$F_1$	$F_2$	$F_3$	$F_4$	$F_6$	$F_8$
BES	1.06E+03	2.34E+03	7.71E+02	1.91E+03	1.77E+03	2.31E+03
BKA	4.22E+06	2.02E+03	7.76E+02	1.91E+03	2.48E+03	2.33E+03
SSA	3.34E+09	3.65E+03	8.93E+02	4.10E+04	2.67E+03	2.52E+03
POA	6.76E+05	3.79E+03	8.70E+02	5.23E+04	2.37E+03	2.85E+03
DBO	1.54E+03	2.60E+03	8.37E+02	1.93E+03	2.25E+03	2.32E+03
HBAO	1.24E+02	1.96E+03	7.42E+02	1.90E+03	1.74E+03	2.30E+03

优化误差,其综合性能最优,适用于复杂优化场景.

4.2 参数敏感性分析 代价函数中权重系数  $w_i$  的设定对任务分配结果具有直接影响. 为了系统性地探究其影响并确定最优配置,本文首先设定总权重满足  $\sum_{i=1}^5 w_i = 1$  的约束条件. 在此基础上,将地形约束的权重系数  $w_1$ 、威胁约束的权重系数  $w_2$  和单无人机约束的权重系数  $w_3$  视为固定

值,均设为 0.1,以保障航迹的基础安全性与可行性. 研究的核心在于权衡航迹段长度与飞行平稳性两个指标,因此,设  $w_4 + w_5 = 0.7$ ,选取 HBAO 和 BES 算法在不同的取值组合下进行测试,不同权重分配的迭代曲线如图 3 所示.

由图 3 可见,当  $w_4 = 0.4, w_5 = 0.3$  时, HBAO 和 BES 算法的收敛效果最优,并且 HBAO 算法在最优配置下的收敛速度与精度比 BES 算法更优.




图 3 不同权重分配的迭代曲线

Fig. 3 Iteration curves with different weight distribution

4.3 任务分配算法性能测试 本实验设置种群规模为 100,迭代次数为 500,任务点数量设置为 30,无人机数量设置为 3,各算法分别运行 10 次,与 4.1 中提及的五种优化算法进行对比,实验主要参数设置如表 3 所示.

为了提高算法的可信度,设计了两个具有差异化特征的仿真模型. 其中,模型 1 模拟开阔、威胁密集的区域,强调路径选择与威胁规避的协调能力;模型 2 模拟狭小、威胁分散、禁飞区较多的复杂地形环境,主要考察任务分配的均衡性与路径平滑性. 为了全面评估算法在不同环境条件下的任务分配效果,选取五项指标进行对比分析,分别是平均路径长度、最短路径长度、平均适应度、最优适应度、各无人机的平均路径长度.

(1)模型 1. 测试地形区域大小为 100 km × 100 km,测试限高为 3 km. 综合威胁体系由敌方雷达、地空导弹及火炮构成,威胁源中心分别为 (30, 80)(89, 50)(40, 11). 该威胁区域呈现平坦

表 3 实验主要参数设置

Table 3 Main experimental parameter settings

参数	符号	参数值
地形威胁系数 1	$K_{H1}$	100
地形威胁系数 2	$K_{H2}$	10
转弯角威胁系数	$K_a$	10
俯仰角威胁系数	$K_\beta$	10
种群规模	$i$	100
最大迭代次数	$i_{max}$	500
UAV 最大拐弯角	$\alpha_{max}$	$30^\circ$
UAV 最大俯仰角	$\beta_{max}$	$\pm 20^\circ$

开阔的无遮蔽地形特征,具备全方位探测打击能力,威胁覆盖半径扩展至 10 km. 飞行管制区域设置一个禁飞区,坐标为 (60, 88),管控半径为 15 km. 选取三架 UAV 进行仿真实验,起点位置设置为 (40, 54, 2),各算法任务分配求解结果如图 4 和表 4 所示,迭代曲线如图 5 所示,性能指标对比如表 5 所示.

由图4可见,与DBO,SSA,POA和BKA算法相比,HBAO算法生成的飞行路径展现出更高的平滑度,并有效规避了地形障碍与威胁源,避免了显著的碰撞风险.具体而言,DBO和SSA算法生成的路径中存在较多非必要的路径折返,导致飞行距离显著增加;POA和BKA算法表现出明显的地形碰撞现象.

结合表5的性能指标分析可知,HBAO算法

在任务分配均匀性和路径优化性能方面均有显著优势,能有效综合规避威胁源及复杂地形环境的影响,消除路径折返现象,以显著提升路径质量.在最短路径长度优化目标上,HBAO算法也表现出更高的收敛精度.此外,图5所示的各算法迭代收敛曲线进一步表明,HBAO算法在全局优化能力方面优势明显,其最优适应度值和平均适应度值均显著低于对比算法.

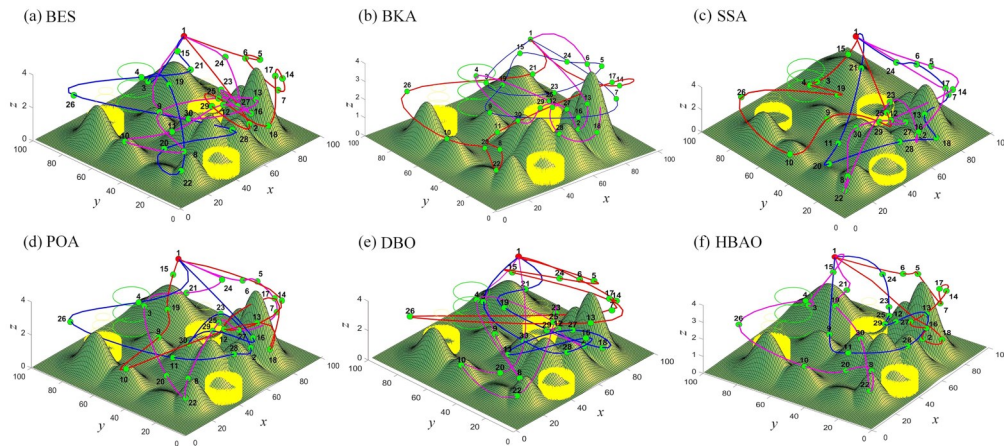


图4 模型1:各算法任务分配求解结果

Fig. 4 Model 1: Algorithm task allocation solution results

表4 模型1:三维战场环境下多无人机协同任务分配结果

Table 4 Model 1: Results of multi-UAV collaborative task allocation in a three-dimensional battlefield environment

算法	最优任务序列
BES	无人机1序列:1->5->6->7->14->17->18->25->29->2->1
	无人机2序列:1->3->19->22->20->28->26->4->21->15->1
	无人机3序列:1->30->13->9->8->10->11->12->16->23->27->24->1
BKA	无人机1序列:1->14->17->11->8->22->20->10->26->21->1
	无人机2序列:1->7->16->9->19->15->24->5->23->3->1
	无人机3序列:1->6->18->28->12->25->4->30->29->27->2->13->1
SSA	无人机1序列:1->12->14->29->23->2->18->13->16->27->1
	无人机2序列:1->15->3->4->19->26->10->9->29->25->1
	无人机3序列:1->21->11->20->28->18->13->7->6->24->1
POA	无人机1序列:1->5->14->12->27->30->8->22->23->2->16->17->1
	无人机2序列:1->15->19->9->10->13->18->17->12->14->1
	无人机3序列:1->4->26->11->28->2->23->30->29->16->1
DBO	无人机1序列:1->6->5->7->27->25->8->22->20->3->21->24->1
	无人机2序列:1->6->14->17->13->26->7->15->24->5->1
	无人机3序列:1->20->10->22->23->12->2->29->25->4->8->9->1
HBAO	无人机1序列:1->4->9->19->11->28->2->26->13->15->1
	无人机2序列:1->5->7->16->8->23->20->10->29->22->1
	无人机3序列:1->21->24->25->17->12->3->18->27->30->14->6->1

表 5 模型 1:三维战场环境下多无人机任务分配各算法性能结果

Table 5 Model 1: Performance results of various algorithms for multi-UAV task allocation in a 3D battlefield environment

算法	平均路径长度(km)	最短路径长度(km)	平均适应度值	最优适应度值	各无人机平均路径长度(km)
BES	1146.49	1004.84	598.15	585.06	[290.01,391.11,465.37]
BKA	1107.23	985.48	568.81	545.04	[391.07,382.71,333.45]
SSA	1055.14	897.46	559.72	523.46	[342.94,281.61,430.59]
POA	1133.09	946.17	568.49	538.93	[389.20,390.53,353.36]
DBO	1373.52	1013.48	690.78	660.96	[471.23,343.66,558.63]
HBAO	821.81	797.14	424.31	408.03	[239.74,254.97,327.10]




图 5 模型 1:各算法的迭代曲线

Fig. 5 Model 1: Iteration curves of each algorithm

(2)模型 2. 建立一个  $1000\text{ m} \times 1000\text{ m} \times 500\text{ m}$  的模拟地形区域,并且设置雷达威胁、禁飞区、防空火炮、地空导弹威胁各一个. 其作用中心分别为  $(350, 500)$   $(350, 200)$   $(650, 750)$  和  $(500, 600)$ ,作用半径分别为 60,70,80 和 50 m. 选取三

架 UAV 进行仿真实验,起点位置设为  $(751, 710, 261)$ ,各算法任务分配求解结果如图 6 和表 6 所示,迭代曲线如图 7 所示,性能指标对比如表 7 所示. 如图 6 所示, HBAO 算法在任务分配方面表现出优异的均衡性,其生成的飞行路径平滑度高、路径结构直接,有效规避了不必要的折返与绕行现象,显著降低了航程代价,结合图 7 的收敛曲线分析, HBAO 算法在收敛速度和最优解探索能力方面表现突出,能快速、稳定地收敛至高质量解. 在综合性能方面,如表 7 所示, HBAO 算法的平均路径长度显著低于 DBO, POA 和 SSA 等对比算法,充分证明了其在路径优化方面具备显著优势,可以有效减少路径冗余和无效飞行距离. 同时, HBAO 算法的平均适应度值和最优适应度值均显著优于对比算法,体现了其优越的优化性能.

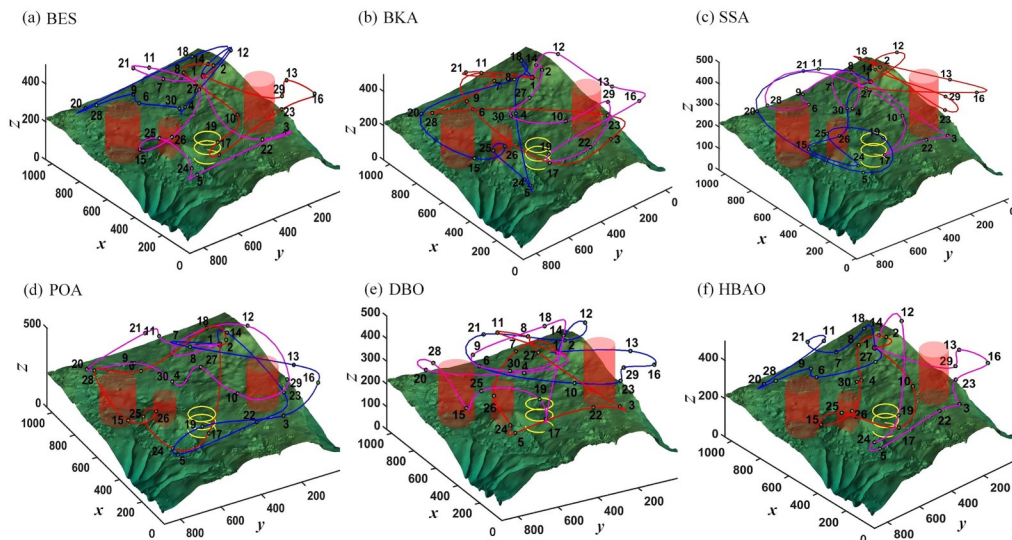


图 6 模型 2:各算法任务分配求解结果

Fig. 6 Model 2: Algorithm task allocation solution results

表6 模型2:三维战场环境下多无人机协同任务分配结果

Table 6 Model 2: Results of multi-UAV collaborative task allocation in a 3D battlefield environment

算法	最优任务序列
BES	无人机1序列:1->29->13->16->23->17->19->10->8->2->1
	无人机2序列:1->18->20->28->9->6->30->4->12->14->1
	无人机3序列:1->7->21->11->27->26->15->25->24->5->3->22->1
BKA	无人机1序列:1->21->7->28->6->23->3->17->9->11->1
	无人机2序列:1->4->5->24->25->26->15->20->8->18->1
	无人机3序列:1->2->27->30->10->29->22->19->16->13->12->14->1
SSA	无人机1序列:1->12->14->29->23->2->18->13->16->27->1
	无人机2序列:1->30->26->15->24->25->19->5->20->11->1
	无人机3序列:1->7->4->8->9->6->28->21->10->17->22->3->1
POA	无人机1序列:1->17->24->25->26->15->28->6->18->2->1
	无人机2序列:1->8->13->16->3->19->5->22->23->14->1
	无人机3序列:1->7->12->29->10->27->4->30->9->20->21->11->1
DBO	无人机1序列:1->7->26->24->5->22->3->27->8->11->1
	无人机2序列:1->12->14->21->6->10->23->29->16->13->1
	无人机3序列:1->4->20->28->15->25->19->17->2->18->9->30->1
HBAO	无人机1序列:1->2->8->4->30->26->15->25->17->10->1
	无人机2序列:1->18->7->21->11->20->28->9->6->27->1
	无人机3序列:1->29->13->16->23->3->22->5->24->19->12->14->1




图7 模型2:各算法的迭代曲线

Fig. 7 Model 2: Iteration curves of each algorithm

综上所述,HBAO算法具有较强的全局优化能力,能在广泛的搜索空间中定位近最优解,进一步提升多无人机任务分配的整体效率和可靠性.

### 5 结论

本研究提出一种基于秃鹰-天鹰混合优化的多无人机任务分配方法,以解决复杂战场环境下的任务分配问题.首先,将任务分配问题转化为多旅行商模型,并构建了包含地形约束、无人机物理约束和威胁源约束等代价函数模型,使任务分配与航迹规划实现紧耦合.其次,在优化策略上,

表7 模型2:三维战场环境下多无人机任务分配各算法性能结果

Table 7 Model 2: Performance results of various algorithms for multi-UAV task allocation in a 3D battlefield environment

算法	平均路径长度(m)	最短路径长度(m)	平均适应度值	最优适应度值	各无人机平均路径长度(m)
BES	8743.29	8345.74	4543.64	4193.60	[2868.30,2449.01,3425.98]
BKA	10323.24	9739.65	5642.23	4850.12	[3859.79,3108.98,3354.47]
SSA	11453.97	9941.36	5915.58	5414.06	[3877.13,3666.09,3910.75]
POA	9648.33	8826.21	4959.78	4595.05	[2975.05,3618.55,3054.73]
DBO	10627.95	9028.95	5576.56	5044.74	[3341.25,3003.77,4282.93]
HBAO	8234.24	8013.04	4359.79	3945.58	[2588.27,2434.99,3210.98]

针对多无人机任务分配问题具有解空间广阔、局部极值多的特点,以及 BES 算法在初始全局搜索阶段效率不足的问题,将秃鹰算法的全局搜索阶段转换为天鹰优化算法的扩展与缩小搜索策略,以提升算法的全局搜索能力,同时引入折射学习机制,增强种群多样性,提高了任务分配的精度和效率。最后,设计双模型实验验证算法的任务分配效能。实验结果表明,提出的算法可以高效、低成本地完成多无人机任务分配,并在复杂环境中展现出较强的适应性和优化。

#### 参考文献

- [1] Liu J, et al. A novel unsupervised change detection method with structure consistency and GFLICM based on UAV images. *Journal of Geodesy and Geoinformation Science*, 2022, 5(1): 91–102.
- [2] 王峰, 黄子路, 韩孟臣, 等. 基于 KnCMP SO 算法的异构无人机协同多任务分配. *自动化学报*, 2023, 49(2): 399–414.
- [3] 宋育武, 贾林通, 李娟, 等. 异构型无人机群体并行任务分配算法. *科学技术与工程*, 2020, 20(4): 1492–1497.
- [4] Jeon H M, Lim J W, Ryoo C. Task assignment for multiple multi-purpose unmanned aerial vehicles using greedy algorithm. *International Journal of Aeronautical and Space Sciences*, 2024, 25(4): 1380–1394.
- [5] Schwarzrock J, Zacarias I, Bazzan A L C, et al. Solving task allocation problem in multi unmanned aerial vehicles systems using swarm intelligence. *Engineering Applications of Artificial Intelligence*, 2018, 72: 10–20.
- [6] 王树朋, 徐旺, 刘湘德, 等. 基于自适应遗传算法的多无人机协同任务分配. *电子信息对抗技术*, 2021, 36(1): 59–64.
- [7] Jia G W, Wang J F, Wang P, et al. Using multi-layer coding genetic algorithm to solve time-critical task assignment of heterogeneous UAV teaming//2019 International Conference on Control, Automation and Diagnosis (ICCAD). Grenoble: IEEE, 2019: 1–5.
- [8] Tang J, Duan H B, Lao S Y. Swarm intelligence algorithms for multiple unmanned aerial vehicles collaboration: A comprehensive review. *Artificial Intelligence Review*, 2023, 56(5): 4295–4327.
- [9] Zhang Y Z, Hu B, Li J W, et al. Heterogeneous multi-UAVs cooperative task assignment based on GSA-GA//2016 IEEE International Conference on Aircraft Utility Systems (AUS). Beijing: IEEE, 2016: 423–426.
- [10] 彭泓漓, 张娟, 李辉, 等. 基于改进狼群算法的无人机协同任务规划. *计算机工程*, 2024, 50(10): 69–79.
- [11] Alsattar H A, Zaidan A A, Zaidan B B. Novel meta-heuristic bald eagle search optimisation algorithm. *Artificial Intelligence Review*, 2020, 53(3): 2237–2264.
- [12] Yang C H, Tsai M H, Kang S C, et al. UAV path planning method for digital terrain model reconstruction-a debris fan example. *Automation in Construction*, 2018, 93: 214–230.
- [13] Radmanesh M, Kumar M, Guentert P H, et al. Overview of path-planning and obstacle avoidance algorithms for UAVs: A comparative study. *Unmanned Systems*, 2018, 6(2): 95–118.
- [14] Wahab S H A, Chekima A, Saad N, et al. Path planning of UAV based on fluid computing via accelerated method. *International Journal of Engineering Trends and Technology*, 2020, 1: 76–80.
- [15] 黄鹤, 李文龙, 吴琨, 等. 基于 ALCE-SSA 优化的三维无人机低空突防. *南京大学学报(自然科学)*, 2022, 58(3): 448–459.
- [16] Tizhoosh H R. Opposition-based learning: A new scheme for machine intelligence//International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA - IAWTIC'06). Vienna: IEEE, 2005: 695–701.
- [17] Leng Y F, Cui C L, Jiang Z C. Enhanced crayfish optimization algorithm: orthogonal refracted opposition-based learning for robotic arm trajectory planning. *PLoS One*, 2025, 20(2): e0318203.
- [18] Abualigah L, Yousri D, Abd Elaziz M, et al. Aquila optimizer: A novel meta-heuristic optimization algorithm. *Computers & Industrial Engineering*, 2021, 157: 107250.

- [19] Akbari M A, Zare M, Azizipanah-Abarghooee R, et al. The cheetah optimizer: A nature - inspired metaheuristic algorithm for large - scale optimization problems. *Scientific Reports*, 2022, 12(1):10953.
- [20] Wang J, Wang W C, Hu X X, et al. Black-winged kite algorithm: A nature-inspired meta-heuristic for solving benchmark functions and engineering problems. *Artificial Intelligence Review*, 2024, 57(4):98.
- [21] Xue J K, Shen B. A novel swarm intelligence optimization approach: Sparrow search algorithm. *Systems Science & Control Engineering*, 2020, 8(1): 22—34.
- [22] Trojovský P, Dehghani M. Pelican optimization algorithm: A novel nature - inspired algorithm for engineering applications. *Sensors*, 2022, 22(3):855.
- [23] Xue J K, Shen B. Dung beetle optimizer: A new meta-heuristic algorithm for global optimization. *The Journal of Supercomputing*, 2023, 79(7):7305—7336.

(责任编辑 高善露)