自动化学报
ACTA AUTOMATICA SINICA

面向多无人机协同任务分配的多策略融合海鸥优化算法

王传云 邢佳庆 王田 高骞 王琳霖 郑会龙

Multi-strategy Fusion Seagull Optimization Algorithm for Multi-UAV Cooperative Task Allocation

WANG Chuan-Yun, XING Jia-Qing, WANG Tian, GAO Qian, WANG Lin-Lin, ZHENG Hui-Long

在线阅读 View online: https://doi.org/10.16383/j.aas.c250754

您可能感兴趣的其他文章

基于KnCMPSO算法的异构无人机协同多任务分配

A Knee Point Based Coevolution Multi-objective Particle Swarm Optimization Algorithm for Heterogeneous UAV Cooperative Multi-task Allocation

自动化学报. 2023, 49(2): 399−414 https://doi.org/10.16383/j.aas.c210696

无人飞行器集群自主控制: 基于联盟形成博弈的任务分配

Autonomous Control of Unmanned Aerial Vehicle Swarms: Task Allocation Based on Coalition Formation Game

自动化学报. 2025, 51(5): 942−959 https://doi.org/10.16383/j.aas.c240593

重大装备制造多机器人任务分配与运动规划技术研究综述

A Review of Task Allocation and Motion Planning for Multi-robot in Major Equipment Manufacturing

自动化学报. 2024, 50(1): 21−41 https://doi.org/10.16383/j.aas.c220957

基于势博弈的异构多智能体系统任务分配和重分配

Task Allocation and Reallocation for Heterogeneous Multiagent Systems Based on Potential Game

自动化学报. 2022, 48(10): 2416−2428 https://doi.org/10.16383/j.aas.c220003

基于 AC-DSDE 进化算法多 UAVs协同目标分配

Multi-UAV Cooperative Target Allocation Based on AC-DSDE Evolutionary Algorithm

自动化学报. 2021, 47(1): 173−184 https://doi.org/10.16383/j.aas.c190334

多障碍场景下基于多策略进化机制的无人机三维路径规划

Multi-Strategy Evolutionary Mechanism for UAV 3D Path Planning in Multi-Obstacle Environments

自动化学报. 2026, 52(2): 335−348 https://doi.org/10.16383/j.aas.c250319

面向多无人机协同任务分配的多策略融合海鸥优化算法

王传云[1] 邢佳庆[1] 王 田[2] 高 骞[1] 王琳霖[1] 郑会龙[3]

摘 要 针对多无人机在多约束下的协同任务分配问题, 提出一种面向多无人机协同任务分配的多策略融合海鸥优化算法 (MFSOA). 该算法由时间代价、能耗代价、负载均衡、任务时序及多约束条件构建多无人机协同任务分配目标优化模型. 为提升算法寻优效率, 采用 Tent 混沌映射增强种群多样性, 结合精英进化策略优化迭代过程中的种群质量; 通过设计多方向自适应迁徙策略增强算法全局寻优能力, 避免算法陷入局部最优; 构建基于精英个体的攻击策略以平衡算法的全局探索与局部开发能力, 提升算法的寻优稳定性. 实验结果表明, MFSOA 在多场景下均表现出优异的综合性能, 其寻优能力相较对比算法提升约 3% ~ 13%, 验证了该算法求解多无人机协同任务分配问题的有效性与可靠性.

关键词 多无人机协同; 任务分配; 海鸥优化算法; 多策略融合; 多约束

引用格式 王传云, 邢佳庆, 王田, 高骞, 王琳霖, 郑会龙. 面向多无人机协同任务分配的多策略融合海鸥优化算法. 自动化学报, 2026, **52**(10): 2200−2214

DOI 10.16383/j.aas.c250754 **CSTR** 32138.14.j.aas.c250754

Multi-strategy Fusion Seagull Optimization Algorithm for Multi-UAV Cooperative Task Allocation

WANG Chuan-Yun[1] XING Jia-Qing[1] WANG Tian[2] GAO Qian[1] WANG Lin-Lin[1] ZHENG Hui-Long[3]

Abstract To address the cooperative task allocation problem of multi-UAV under multiple constraints, this paper proposes a multi-strategy fusion seagull optimization algorithm (MFSOA) for multi-UAV cooperative task allocation. The algorithm constructs an objective optimization model for multi-UAV cooperative task allocation, considering time cost, energy consumption cost, load balancing, task sequencing, and multiple constraint conditions. To improve the optimization efficiency of the algorithm, Tent chaotic mapping is employed to enhance population diversity, combined with an elite evolutionary strategy to optimize population quality during iteration; A multi-directional adaptive migration strategy is designed to strengthen global optimization capability and prevent the algorithm from falling into local optima; And an elite individual-based attack strategy is developed to balance global exploration and local exploitation capabilities of the algorithm, thereby enhancing the optimization stability of the algorithm. Experimental results demonstrate that MFSOA exhibits excellent comprehensive performance across multiple scenes, with its optimization capability improving by approximately 3% to 13% compared with comparison algorithms, validating its effectiveness and reliability in solving the multi-UAV cooperative task allocation problem.

Keywords multi-UAV cooperation; task allocation; seagull optimization algorithm; multi-strategy fusion; multiple constraints

Citation Wang Chuan-Yun, Xing Jia-Qing, Wang Tian, Gao Qian, Wang Lin-Lin, Zheng Hui-Long. Multi-strategy fusion seagull optimization algorithm for multi-UAV cooperative task allocation. *Acta Automatica Sinica*, 2026, **52**(10): 2200−2214

近年来, 无人机 (unmanned aerial vehicle, UAV) 凭借操作简单、灵活性强、成本低等特点[1], 已广泛应用于侦察打击、灾害救援、数据采集等场景[2−3], 但任务场景的复杂性与任务需求的多样化对无人机系统的综合性能提出严苛挑战[4]. 单架无人机受限于载荷容量、计算处理能力的固有约束, 往往难以独立完成多目标、高时效、强约束的复杂任务[5]. 在此背景下, 多无人机集群通过协同作业模式实现功能互补与效能倍增[6−7], 已成为突破单无人机性能瓶颈的核心技术路径[8].

收稿日期 2025-12-30 录用日期 2026-03-04
Manuscript received December 30, 2025; accepted March 4, 2026
国家自然科学基金 (92467108, 61703287), 辽宁省自然科学基金 (2024-MS-137), 辽宁省教育厅项目 (LJ232510143006), 北京航空航天大学鲲鹏昇腾科教创新孵化中心资助
Supported by National Natural Science Foundation of China (92467108, 61703287), Liaoning Provincial Natural Science Foundation (2024-MS-137), Scientific Research Program of Liaoning Provincial Education Department (LJ232510143006), and BUAA Kunpeng & Ascend Center of Cultivation
本文责任编委 付俊杰
Recommended by Associate Editor FU Jun-Jie
1. 沈阳航空航天大学人工智能学院 沈阳 110136 2. 北京航空航天大学人工智能学院 北京 100191 3. 中国科学院工程热物理研究所 北京 100190
1. College of Artificial Intelligence, Shenyang Aerospace University, Shenyang 110136 2. Institute of Artificial Intelligence, Beihang University, Beijing 100191 3. Institute of Engineering Thermophysics, Chinese Academy of Sciences, Beijing 100190

协同任务分配 (cooperative task allocation, CTA) 作为无人机集群系统实现自主控制与协同作战的前提[9], 直接决定集群资源的合理配置与利用, 进而影响任务执行的效率[10]. 多无人机协同任务分配是对环境、任务需求和无人机资源的全局规划[11], 合理的多无人机协同任务分配方法将显著提高无人机系统的任务完成效率[12]. 因此, 构建科学有效的协同任务分配方案不仅是满足复杂场景任务需求的前提, 更是提升多无人机协同作战与执行能力的核心支撑[13].

多无人机协同任务分配问题 (multi-UAV cooperative task allocation problem, MCTAP) 本质上是一类典型的 NP-hard 问题[14], 其核心目标是在满足各类约束的前提下[15], 将任务合理分配给无人机以实现无人系统整体效能最优[16]. 随着任务和无人机规模的扩大, 问题解空间呈指数级增长, 导致求解复杂度显著增加. 面对该问题, 传统精确算法如混合整数线性规划 (mixed integer linear programming, MILP)[17] 通过穷举所有可能的分配方案来保证解的最优性. 这类方法虽能够达到较高的求解精度, 但计算代价高, 需要耗费大量的时间和计算资源. 相比之下, 结合随机搜索机制和元启发式策略的智能优化算法能够高效遍历解空间以生成可行的任务分配方案[18], 现已成为求解 MCTAP 的主流方法. 目前, 针对任务分配领域常用的算法包括遗传算法 (genetic algorithm, GA)[19]、粒子群优化 (particle swarm optimization, PSO)[20]、蜣螂优化 (dung beetle optimizer, DBO)[21] 和人工蜂群算法 (artificial bee colony algorithm, ABC)[22] 等. 这类算法通过模拟自然演化规律或群体行为, 展现出良好的鲁棒性与可扩展性, 在 MCTAP 研究中得到广泛应用[23]. 如 Wang 等[24] 提出一种仿生狼群方法, 构建包含任务分配的一体化系统框架, 同时结合改进匈牙利算法将任务分配转化为非平衡指派问题进行求解, 并通过重分配算法实现任务负载均衡, 以此解决复杂场景下无人机集群的动态任务分配问题. Wei 等[25] 通过在多元宇宙优化算法中引入自适应压缩因子以提升算法收敛速度, 并在虫洞移动阶段执行差分变异操作以增强算法的全局搜索能力, 最终有效解决了不同目标价值下的多无人机协同侦察任务分配问题. 肖鹏等[26] 以单亲遗传算法为基础, 基于无人机探测距离的聚类算法生成新航路点以降低计算量, 并使用 Dubins 曲线距离替代欧氏距离构建路径代价函数, 实现任务分配与路径规划的协同优化. Kurdi 等[27] 提出基于细菌觅食行为的多无人机任务分配算法, 通过翻滚、跳跃、游动、聚集的仿生策略与双阶段搜索逻辑, 解决了多无人机在探测与处理任务中任务分配的适应性与效率问题. 然而, 现有智能优化算法在实际工程应用中仍存在显著局限性. 部分算法如 PSO 虽具有收敛速度快等优势, 但迭代后期易陷入局部最优, 难以平衡寻优精度与求解效率[28]; GA 虽鲁棒性较强, 却需设计复杂的编码, 在应对无人机异构性、任务顺序约束等复杂场景时适配性不足, 进而导致生成的任务分配方案可行性降低[29].

海鸥优化算法 (seagull optimization algorithm, SOA)[30] 作为一种新型生物启发式智能优化算法, 通过模拟海鸥迁徙与捕食过程中的群体行为构建独特的搜索更新机制, 在收敛速度与算法稳定性方面表现出一定优势[31]. 近年来, 凭借其优异的寻优性能, 该算法已被广泛应用于路径规划[32]、特征选择[33] 以及工程设计[34] 等多个领域. 然而, 在处理高维、多约束的多无人机协同任务分配问题时, SOA 仍存在对初始种群依赖性较强、易陷入局部最优、探索与开发不平衡等缺陷, 难以适配复杂场景的求解需求[35].

为解决 SOA 在多无人机协同任务分配问题中的应用缺陷, 本文提出一种基于多策略融合海鸥优化算法 (multi-strategy fusion seagull optimization algorithm, MFSOA) 的任务分配方法, 旨在结合 SOA 的独特优势与应用潜力, 提升算法在应对复杂多约束任务分配问题时的鲁棒性与适应性. 本文主要工作总结如下:

1) 构建无人机协同任务分配模型, 该模型综合考虑任务执行、无人机性能等多类约束条件, 并结合多维度优化目标进行设计, 可有效适配多无人机复杂任务分配的实际需求.

2) 提出基于多策略融合海鸥优化算法的任务分配方法, 通过引入 Tent 混沌映射初始化策略提升种群多样性与分布均匀性, 结合精英进化策略的动态更新机制持续优化种群质量, 解决算法对初始解的依赖问题; 设计多方向自适应迁徙策略, 使个体在全局最优未确定阶段扩大搜索范围, 提高算法跳出局部最优的概率, 增强全局寻优能力; 在搜索阶段构建差异化的更新机制, 实现探索与开发行为的动态平衡, 使算法在迭代早期以较大范围开展全局探索, 在迭代后期转向精细的局部开发, 提升算法整体寻优效率与稳定性, 从而适配复杂多约束场景的求解需求.

3) 为验证所提算法的有效性, 本文基于任务密度与任务规模设计多组不同复杂度的仿真场景, 将 MFSOA 与 SOA 及多种主流任务分配算法进行实验对比, 从多个关键指标维度系统评估所提方法的性能表现. 实验结果与分析充分证明了 MFSOA 在解决多无人机协同任务分配问题中的有效性与稳定性.

1 问题描述

1.1 协同任务分配场景描述

多无人机协同任务分配问题旨在协调多架无人机高效完成一组任务. 由于无人机在性能与有效载荷方面存在差异, 系统具有显著的异构性. 如图 1 所示, 在典型无人机侦察任务场景中, 目标区域内随机分布各类障碍物与威胁源, M 项待侦察任务点需由 N 架无人机协同完成. 所有无人机均需参与任务执行, 且每架无人机至少承担一项任务. 无人机同步从基地起飞, 依次访问并执行所有分配到的任务, 最终返回起始位置. 由于不同任务点的执行时间存在差异, 无人机需在确保安全飞行的前提下尽可能依据任务优先级完成所有任务, 并遵循任务时序与能量限制等实际约束条件. 在此基础上, 寻求整体最优的任务分配方案, 以同时最大化任务执行效率与任务完成度.

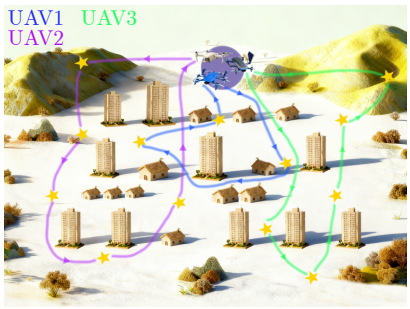


图 1 任务分配示例

Fig. 1 Example of task allocation

1.2 协同任务分配参数定义

表 1 展示了问题模型涉及的关键参数以及相应说明.

多无人机协同多任务分配问题中的各参数定义如下: 假设存在 N 架性能各异的无人机, 由 $UAV = \{U_1, U_2, \cdots, U_N\}$ 表示, 对于任意无人机 U_i ($U_i \in UAV$), 其核心属性包括起始位置坐标 $P_{U_i} = (x_{U_i}, y_{U_i})$、飞行速度 V_{U_i}, 其能量约束通过最大可用飞行时间 $FT_{\max,U_i}$ 量化表征. 结合无人机的有效载荷能力, 限定其最多可执行 $TN_{\max,U_i}$ 项任务, 以避免过载导致任务失败, 因此, 任意无人机 U_i 可表征为:

$$U_i = [P_{U_i}, V_{U_i}, FT_{\max,U_i}, TN_{\max,U_i}] \tag{1}$$

此外, 所有无人机需协同完成 M 项侦察任务, 任务集合定义为 $TASK = \{T_1, T_2, \cdots, T_M\}$, 任意任务 T_j 表征为:

$$T_j = [P_{T_j}, t_{T_j}, PL_j] \tag{2}$$

其中, $P_{T_j} = (x_{T_j}, y_{T_j})$ 为任务位置坐标; t_{T_j} 为无人机执行任务所需时间; PL_j 为任务优先级.

无人机 U_i 的任务分配结果以有序任务序列 Seq_{U_i} 表征, 即

$$Seq_{U_i} = \{T_{U_i,1}, T_{U_i,2}, \cdots, T_{U_i,n_{U_i}}\} \tag{3}$$

其中, n_{U_i} 表示分配给无人机 U_i 的任务数量.

1.3 约束条件

1) 任务唯一性约束

每项任务 T_j 需且仅需由一架无人机执行, 避免多架无人机重复分配至同一任务点造成资源冗余. 该约束表示为:

$$Seq_{U_a} \cap Seq_{U_b} = \emptyset, \quad a \neq b \tag{4}$$

其中, Seq_{U_a} 与 Seq_{U_b} 分别表示无人机 U_a 与 U_b 的任务序列, 交集为空集表明不同无人机之间不存在重复的任务分配.

2) 任务负载均衡约束

为避免无人机闲置导致的资源浪费, 同时实现多无人机任务负载均衡, 每架无人机需至少分配一项任务, 且执行的任务数量不超过其最大可执行任务数 $TN_{\max,U_i}$, 确保任务分配方案与无人机负载能力适配. 该约束的数学表达式为:

$$1 \le n_{U_i} \le TN_{\max,U_i}, \quad i \in \{1, 2, \cdots, N\} \tag{5}$$

3) 任务航程代价定义

无人机 U_i 从基地出发, 按照分配的任务序列依次执行任务, 待所有任务完成后均需返回初始位置, 其航程代价定义为该闭环路径的总长度, 表示为:

$$Path_{U_i} = d_1 + d_2 + d_3 \tag{6}$$

表 1 参数说明

Table 1 Parameter description

对象类型	参数	说明
无人机 U_i	N	无人机数量
	$P_{U_i} = (x_{U_i}, y_{U_i})$	起始位置坐标
	V_{U_i}	飞行速度
	$FT_{\max,U_i}$	最大飞行时间
	$TN_{\max,U_i}$	最大任务数量
任务 T_j	M	任务数量
	$P_{T_j} = (x_{T_j}, y_{T_j})$	任务位置坐标
	t_{T_j}	任务执行时间
	PL_j	任务优先级

$$d_1 = \text{Distance}\left(P_{U_i},\ P_{T_{U_i,\,1}}\right) \tag{7}$$

$$d_2 = \sum_{k=1}^{n_{U_i}-1} \text{Distance}\left(P_{T_{U_i,\,k}},\ P_{T_{U_i,\,k+1}}\right) \tag{8}$$

$$d_3 = \text{Distance}\left(P_{T_{U_i,\,n_{U_i}}},\ P_{U_i}\right) \tag{9}$$

其中, $P_{T_{U_i,\,k}}$ 表示无人机 U_i 的任务序列中第 k 项任务 $T_{U_i,\,k}$ 的位置坐标; Distance 表示两点间的欧氏距离.

4) 续航时间约束

任意任务 T_j 的执行时间为固定值 t_{T_j}, 无人机 U_i 执行所有分配任务的总时间为:

$$t_{U_i} = \sum_{T_j \in Seq_{U_i}} t_{T_j} \tag{10}$$

无人机在任务间的飞行时间由总航程 $Path_{U_i}$ 与飞行速度 V_{U_i} 决定, 即

$$t_{flight,\,U_i} = \frac{Path_{U_i}}{V_{U_i}} \tag{11}$$

为确保无人机续航能力满足任务需求, 总任务执行时间与总飞行时间之和需不超过其最大飞行时间 $FT_{\max,\,U_i}$, 该约束可表示为:

$$t_{U_i} + t_{flight,\,U_i} \le FT_{\max,\,U_i}, \quad i \in \{1,\ 2,\ \cdots,\ N\} \tag{12}$$

5) 任务顺序约束

不同任务之间可能存在不同的执行顺序, 为确保高优先级任务优先完成, 无人机 U_i 需按照前序任务优先级不低于后序任务优先级的原则顺序执行任务. 该约束的数学表达式为:

$$PL_{T_{U_i,\,k}} \ge PL_{T_{U_i,\,k+1}}, \quad k \in \{1,\ 2,\ \cdots,\ n_{U_i}-1\} \tag{13}$$

其中, $T_{U_i,\,k}$ 表示无人机 U_i 的任务序列 Seq_{U_i} 中的第 k 项任务, 对应原始任务集合 $TASK$ 中的特定任务 T_j, 且 $PL_{T_{U_i,\,k}} = PL_j$, 即为该任务的优先级.

1.4 目标函数

在满足上述约束条件的前提下, 通过多维度指标对任务分配方案进行综合评估, 以实现任务收益最大化与执行成本最小化, 同时提升整体执行效率.

1) 任务时间成本

任务时间成本的优化目标为最小化所有无人机完成任务的最长耗时, 以此提升整体任务执行效率. 分配方案的总耗时由最后一架返回基地的无人机决定, 该成本表示为:

$$f_1 = \frac{\max\left(\left\{t_{U_i} + \frac{Path_{U_i}}{V_{U_i}}\right\}_{i=1}^{N}\right)}{N} \tag{14}$$

其中, $\max(\cdot)$ 表示取所有无人机总耗时的最大值. 通过归一化处理减少无人机规模变化对目标函数量级的影响, 并保证不同规模场景下成本指标的可比性.

2) 任务能耗成本

通过最小化所有无人机的平均飞行时间以降低无人机系统的总体能量消耗水平, 该成本表示为:

$$f_2 = \frac{1}{N}\sum_{i=1}^{N}\frac{Path_{U_i}}{V_{U_i}} \tag{15}$$

该指标以无人机平均飞行时间作为能耗表征量, 用于衡量系统整体能量消耗水平, 其值越小表示能耗越低.

3) 任务负载均衡成本

任务负载均衡成本的优化目标为最小化无人机间的任务数量差异, 避免出现无人机部分过载、部分闲置的情况, 该成本表示为:

$$f_3 = \left(\max\left(\{n_{U_i}\}_{i=1}^{N}\right) - \min\left(\{n_{U_i}\}_{i=1}^{N}\right)\right) \times \bar{n} \tag{16}$$

$$\bar{n} = \frac{1}{N}\sum_{i=1}^{N} n_{U_i} \tag{17}$$

其中, $\max(\{n_{U_i}\}_{i=1}^{N})$ 与 $\min(\{n_{U_i}\}_{i=1}^{N})$ 分别表示无人机分配任务数量的最大值与最小值; $\max(\{n_{U_i}\}_{i=1}^{N}) - \min(\{n_{U_i}\}_{i=1}^{N})$ 表示无人机间任务数量的极差, 直接反映负载不均衡程度; $\bar{n}$ 表示所有无人机的平均任务数量, 用于加权放大负载差异的影响, 避免少量无人机任务数差异被忽略.

4) 全局任务时序成本

在保证所有任务被完成的前提下, 无人机应尽可能按照任务优先级顺序执行分配任务. 全局任务时序成本旨在最小化无人机执行任务过程中的优先级冲突, 通过量化违规次数作为惩罚, 引导算法生成满足优先级约束的任务执行方案, 从而提升任务调度的整体合理性与效率. 该成本可表示为:

$$f_4 = \left(\sum_{i=1}^{N} vil_{U_i}\right) \times \bar{n} \tag{18}$$

其中, vil_{U_i} 表示第 i 架无人机违反任务优先级的次数, 计算方式为:

$$vil_{U_i} = \sum_{k=1}^{n_{U_i}-1} \mathrm{I}\left(PL_{T_{U_i,\,k}} < PL_{T_{U_i,\,k+1}}\right) \tag{19}$$

$$\mathrm{I}\left(PL_{T_{U_i,\,k}} < PL_{T_{U_i,\,k+1}}\right) = \begin{cases} 1, & PL_{T_{U_i,\,k}} < PL_{T_{U_i,\,k+1}} \\ 0, & PL_{T_{U_i,\,k}} \geq PL_{T_{U_i,\,k+1}} \end{cases} \tag{20}$$

其中, I(·) 为指示函数, 条件成立时取 1, 否则取 0.

综合上述子目标函数构建加权求和形式的总目标函数, 该函数表示为:

$$F = \omega_1 \times f_1 + \omega_2 \times f_2 + \omega_3 \times f_3 + \omega_4 \times f_4 \tag{21}$$

其中, ω_1、ω_2、ω_3、ω_4 为权重系数, 满足 $\sum_{k=1}^{4} \omega_k = 1$ 且 $\omega_k > 0$.

权重系数的核心作用为平衡多无人机协同任务分配过程中不同优化目标的相对重要性. 由于该问题同时涉及任务时间成本、任务能耗成本、任务负载均衡成本与全局任务时序成本等多类指标, 各指标在量纲及作用侧重点上存在差异, 因此需通过权重进行综合协调. 基于上述考虑, 本文在权重设置时遵循以下原则: 首先, 对各子目标函数进行归一化处理以消除量纲影响; 其次, 在保证任务完成效率与能耗优化为主要目标的前提下, 兼顾任务负载均衡与任务时序合理性约束. 进一步结合多组预实验对不同权重组合进行对比分析, 最终采用 $\omega = [\omega_1, \omega_2, \omega_3, \omega_4] = [0.3, 0.3, 0.2, 0.2]$ 作为默认权重配置. 其中, ω_1 和 ω_2 主要侧重任务完成效率与能耗控制, ω_3 用于抑制任务分配不均衡现象, ω_4 用于强化任务优先级约束.

2 多策略融合海鸥优化算法

本文提出的 MFSOA, 主要通过设计 Tent 混沌映射初始化策略、精英进化策略、多方向自适应迁徙策略及精英驱动的差异化攻击策略, 协同提升算法求解多无人机协同任务分配问题的性能. 首先, 通过 Tent 混沌映射初始化策略生成均匀分布的初始种群, 并在迭代优化过程中结合精英进化策略提升种群整体质量, 为后续全局搜索奠定基础; 其次, 设计多方向自适应迁徙策略, 融合最差个体与精英个体的信息动态更新搜索方向, 在保障算法收敛性的前提下增强全局搜索能力, 加快寻优过程; 最后, 引入精英驱动的差异化更新机制, 可有效避免算法早熟收敛问题, 实现由多样性驱动的全局探索向高质量解引导的局部开发的平稳过渡. 算法完整流程步骤如下:

1) 初始化相关参数;

2) 基于 Tent 混沌映射策略生成初始海鸥种群, 每个个体对应一种多无人机任务分配方案;

3) 计算初始种群中每个个体的适应值并初始化全局最优个体与最差个体;

4) 选取适应值最优的前 N_E 个个体构建精英池;

5) 从精英池中随机选取两个精英个体, 通过精英进化策略生成新个体并动态更新精英池;

6) 对每个海鸥个体, 通过多方向自适应迁徙策略计算碰撞避免方向 C、精英引导方向 M_1 以及远离最差方向 M_2;

7) 基于精英驱动的差异化攻击策略更新个体位置, 精英个体按动态概率调整全局探索与局部开发行为, 非精英个体结合柯西变异算子实现位置更新;

8) 重新计算更新后所有个体的适应值, 更新全局最优个体与最差个体;

9) 判断迭代次数是否达到上限, 若达到, 则执行步骤 10), 否则, 执行步骤 4);

10) 输出全局最优个体对应的任务分配方案.

2.1 Tent 混沌映射初始化策略

种群多样性是决定算法全局性能优劣的核心因素之一. SOA 对初始种群分布较为敏感, 易导致个体分布不均、种群多样性不足. 初始种群质量较差可能导致算法在搜索初期即偏离优质解区域, 进而影响算法的搜索效率. 为解决这一问题, 本文提出一种结合 Tent 混沌映射的初始化策略. 相较于传统随机初始化方法, 该策略基于 Tent 混沌映射良好的遍历性与随机性, 使海鸥个体均匀分布于解空间中, 避免初始种群过于聚集. 该策略的数学表达式为:

$$X_{i,\,j} = LB_j + (UB_j - LB_j) \times x_n \tag{22}$$

式中, $X_{i,\,j}$ 表示第 i 个海鸥个体的第 j 维位置分量; UB_j 与 LB_j 分别表示第 j 维搜索空间的上界与下界; x_n 为 Tent 混沌映射系数, 由式 (23) 计算得出.

$$x_n = \begin{cases} 1.99 \times x_{n-1}, & 0 \leq x_{n-1} < 0.5 \\ 1.99 \times (1 - x_{n-1}), & 0.5 \leq x_{n-1} \leq 1 \end{cases} \tag{23}$$

其中, x_0 为区间 (0, 1) 内的随机初值.

2.2 精英进化策略

在 SOA 中, 海鸥个体的位置更新过度依赖当前最优个体, 而该最优个体可能并非全局最优, 从而限制了算法的全局搜索能力. 为进一步提升种群质量, 本文引入精英个体进化策略. 该策略通过构建精英池、对精英个体进行随机交叉重组, 并动态择优更新精英池, 实现精英基因的持续优化, 进而提升算法在解空间中的探索性能.

精英池依据个体适应值排序构建, 选取适应值最优的前 N_E 个个体组成精英池 E_{pool}, 其规模定

义为:

$$N_E = \lfloor N_{pop} \times 0.1 \rfloor \tag{24}$$

式中, N_E 为精英池 E_{pool} 规模; N_{pop} 为种群规模; $\lfloor\cdot\rfloor$ 表示向下取整运算. 精英进化策略的核心在于通过精英个体间的信息交互与基因重组生成潜在更优解, 结合新生成个体动态更新精英池, 在提升精英池质量的同时, 推动种群整体质量随迭代持续提升. 该生成规则为:

$$E_{new,\,j} = \begin{cases} E_{1,\,j}, & r_1 > r_2 \\ E_{2,\,j}, & r_1 \le r_2 \end{cases} \tag{25}$$

式中, E_1 与 E_2 分别表示从精英池 E_{pool} 中随机选取的两个精英个体, $E_{1,\,j}$ 与 $E_{2,\,j}$ 分别表示 E_1 与 E_2 的第 j 维; r_1 与 r_2 为独立的均匀分布随机数, 即 r_1、$r_2 \sim \mathrm{U}(0,\,1)$, 用于保持新精英的随机性与多样性. 动态调整规则为:

$$E_{worst} = \begin{cases} E_{new}, & f(E_{new}) < f(E_{worst}) \\ E_{worst}, & f(E_{new}) \ge f(E_{worst}) \end{cases} \tag{26}$$

式中, E_{worst} 为精英池 E_{pool} 中适应值最差的精英个体; $f(\cdot)$ 为适应值函数; $f(E_{worst})$ 与 $f(E_{new})$ 分别对应精英池中最差个体与新精英个体的适应值.

2.3　多方向自适应迁徙策略

SOA 的迁徙阶段主要用于计算搜索个体的移动方向, 其位置更新并未在此阶段直接完成. 这一机制导致搜索方向较为单一, 在全局最优尚未明确时, 易出现搜索范围受限与搜索灵活性不足的问题, 从而降低算法的全局寻优能力, 在复杂高维解空间中增加了陷入局部最优的风险. 为此, 本文设计多方向自适应迁徙策略, 通过引入最差个体与随机选取的精英个体信息, 对搜索方向进行动态、多维度的自适应调整, 使个体能够在多个潜在方向上开展探索. 该策略在保持算法收敛特性的前提下, 增强了搜索过程的灵活性与多样性, 进而提升其全局寻优能力. 该策略的数学表达式为:

$$D = |C + M_1 + M_2| \tag{27}$$

式中, C 表示当前搜索个体 $X_i(t)$ 为了避免与其他搜索个体发生碰撞而进行调整的搜索方向, 由式 (28) 计算得出; M_1 表示当前搜索个体 $X_i(t)$ 朝着随机精英个体移动的方向, 通过式 (30) 求解; M_2 表示当前搜索个体 $X_i(t)$ 远离最差个体移动的方向, 计算方式如式 (33) 所示.

$$C = A \times X_i(t) \tag{28}$$

式中, A 表示搜索个体在给定搜索空间内的移动行为衰减系数, 其计算方式为:

$$A = f_c - (t \times \frac{f_c}{T}) \tag{29}$$

式中, f_c 用于控制衰减系数 A 的使用频率; t 表示当前迭代次数; T 为最大迭代次数.

$$M_1 = K \times B \times (E_r - X_i(t)) \tag{30}$$

式中, K 为自适应方向依赖系数, 用于控制算法在不同迭代阶段对各移动方向的依赖性, 进而增强算法搜索灵活性, 通过式 (31) 计算得出;

$$K = \frac{t}{T} \tag{31}$$

E_r 表示从精英池 E_{pool} 中随机选取的精英个体; B 用于控制探索与开发之间的平滑过渡, 表示为:

$$B = 2 \times A^2 \times rd_1 \tag{32}$$

式中, rd_1 为区间 (0, 1) 内的随机数.

$$M_2 = (1 - K) \times (X_i(t) - X_w) \tag{33}$$

式中, X_w 表示当前迭代种群中适应值最差的个体.

2.4　精英驱动的差异化攻击策略

为了平衡算法全局搜索与局部开发的性能, 本文提出一种基于精英驱动的差异化更新策略, 以融合自适应调节与精英引导的核心特性. 该策略主要由两部分构成: 精英个体采用式 (34) 开展全局寻优, 非精英个体基于式 (35) 进行探索更新. 该设计使算法在迭代早期保持种群多样性并开展大范围全局探索, 在迭代后期逐步引导种群向高质量解所在的局部区域收敛, 实现由多样性驱动的全局探索向精英引导的局部开发的平稳过渡. 同时, 引入柯西变异算子对部分个体进行扰动更新, 利用其长尾分布特性增强搜索随机性并维持种群多样性, 从而抑制算法过早聚集于次优区域的趋势, 避免出现早熟收敛.

$$X_{i,\,j}(t+1) = \begin{cases} X_{i,\,j}(t) + r_3 \times \cos\theta \times X_{rand,\,j}, & P_e > P1 \\ X_{i,\,j}(t) + r_3 \times D_j + r_3 \times (X_{b,\,j} - E_{r,\,j}), & P_e \le P1 \end{cases} \tag{34}$$

$$X_{i,\,j}(t+1) = \begin{cases} X_{i,\,j}(t) + cauchy \times |X_{i,\,j}(t) - E_{r,\,j}|, & P_{ne} > P2 \\ E_{r,\,j} + cauchy \times D_j \times s, & P_{ne} \le P2 \end{cases} \tag{35}$$

式中, $E_{r,\,j}$ 是随机精英个体 E_r 的第 j 维; $P1$ 与 $P2$ 为均匀分布在区间 (0, 1) 内的随机数; $P_e=\sqrt{t/T}$ 是精英个体动态攻击概率系数, 随着迭代逐步增大, 使精英个体实现前期探索与后期开发的自适应调整, 提升算法的收敛效率; r_3 是区间 $(-1,\,1)$ 内的均匀分布随机数, 用于动态调整精英个体的搜索范围与方向; θ 表示探索角度, 通过式 (36) 计算得出; $\cos\theta$ 为方向调节余弦因子, 随迭代缓慢变化, 引导精英个体探索方向的自适应调整; X_{rand} 表示随机探索位置向量, 用于强化精英个体的全局探索能力, 通过式 (37) 生成, $X_{rand,\,j}$ 表示该位置向量的第 j 维; X_b 为全局最优个体, $X_{b,\,j}$ 是该个体的第 j 维; P_{ne} 是非精英个体固定攻击阈值, 用于划分螺旋式移动行为与差分探索的触发概率; $cauchy$ 表示柯西变异算子, 通过式 (38) 计算得出, 利用柯西分布的长尾特性产生扰动, 帮助非精英个体摆脱局部最优; s 表示螺旋轨迹因子, 用于模拟海鸥的飞行轨迹, 通过式 (39) 计算.

$$\theta=\frac{\pi\times t}{10\times T} \tag{36}$$

$$X_{rand}=LB+(UB-LB)\times rand \tag{37}$$

式中, $rand$ 为区间 (0, 1) 内的随机数向量.

$$cauchy=\tan\left(\pi\times\left(rd_2-\frac{1}{2}\right)\right) \tag{38}$$

式中, rd_2 为区间 (0, 1) 内的随机数.

$$s=R^3\times k\times\cos k\times\sin k \tag{39}$$

式中, R 表示螺旋转弯半径, 通过式 (40) 计算得出; k 是区间 $[0,\,2\pi]$ 内的随机数.

$$R=u\times \mathrm{e}^{kv} \tag{40}$$

式中, u 是定义螺旋形状的常数; v 是自适应螺旋因子, 通过式 (41) 计算得出, 用于随迭代进程动态调整螺旋半径大小, 使算法在前期以较大半径充分探索全局最优解的大致位置, 在后期以较小半径精准定位最优解的准确位置.

$$v=1-\frac{2t}{T} \tag{41}$$

2.5 时间复杂度分析

算法 1 展示了 MFSOA 的整体迭代过程, 其计算复杂度主要由初始化阶段与迭代优化阶段共同决定. 设种群规模为 N_{pop}, 最大迭代次数为 T, 问题维度为 Dim, 精英池规模为 N_E.

在初始化阶段, 基于 Tent 混沌映射策略初始化海鸥种群的复杂度为 $\mathrm{O}(N_{pop}\times Dim)$, 计算种群适应值的复杂度同为 $\mathrm{O}(N_{pop}\times Dim)$. 在迭代优化阶段, 每次迭代首先依据个体适应值对种群进行排序以构建精英池, 该操作的时间复杂度为 $\mathrm{O}(N_{pop}\times\log N_{pop})$. 随后执行精英进化策略, 该过程主要涉及精英个体的重组与替换, 时间复杂度为 $\mathrm{O}(N_E\times Dim)$. 在搜索过程中, 每个海鸥个体均需计算综合迁徙方向 D, 执行精英驱动的差异化攻击策略更新位置, 并重新计算适应值, 该部分的复杂度为 $\mathrm{O}(N_{pop}\times Dim)$.

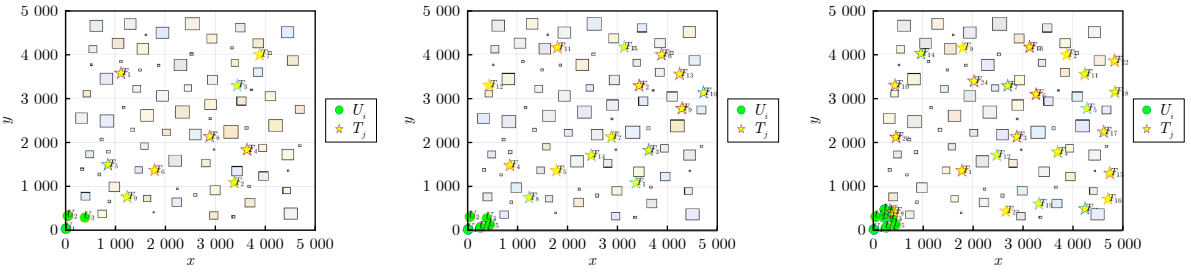
综上所述, MFSOA 在单次迭代中的总体时间复杂度为 $\mathrm{O}(N_{pop}\times\log N_{pop}+N_{pop}\times Dim)$. 在最大迭代次数为 T 时, 其总体时间复杂度为 $\mathrm{O}(T\times(N_{pop}\times\log N_{pop}+N_{pop}\times Dim))$.

算法 1. 多策略融合海鸥优化算法

输入. 种群规模 N_{pop}, 最大迭代次数 T, 无人机集合 UAV, 任务集合 $TASK$, 非精英个体固定攻击阈值 P_{ne}, 螺旋参数 u.

输出. 最优任务分配方案.

```
BEGIN
  根据式 (24) 计算精英池规模 N_E;
  根据式 (22) 初始化海鸥种群;
  计算种群适应值并初始化全局最优个体 X_b 与最差个体 X_w;
  for t = 1 to T
    根据个体适应值构建精英池 E_pool;
    由精英池 E_pool 中随机选取精英个体 E_1 和 E_2;
    根据式 (25) 生成新精英个体 E_new;
    根据式 (26) 更新精英池 E_pool;
    for i = 1 to N_pop
      根据式 (28) 计算碰撞避免方向 C;
      根据式 (30) 计算精英引导方向 M_1;
      根据式 (33) 计算远离最差方向 M_2;
      D ← |C + M_1 + M_2|
      P_e ← sqrt(t/T)
      if X_i(t) ∈ E_pool
        根据式 (34) 更新精英个体;
      else
        根据式 (35) 更新非精英个体.
      end if
    end for
    计算更新后个体的适应值并更新 X_b 与 X_w.
  end for
END
```



(a) 场景 1　(b) 场景 2　(c) 场景 3

(a) Scene 1　(b) Scene 2　(c) Scene 3

图 2　各场景任务分布

Fig. 2　Task distribution in various scenes

3　仿真实验

3.1　实验设置

为验证 MFSOA 在求解多无人机协同任务分配问题中的有效性, 本文根据任务密度与任务规模构建了三组不同复杂度的实验场景, 如图 2 所示. 任务位置在场景内随机生成, 以模拟实际应用中任务分布的不确定性. 各实验场景的具体配置如表 2 所示, 无人机性能参数设置如表 3 所列.

表 2　各实验场景设置

Table 2　Settings of each experimental scene

场景	无人机数量	任务点数量
场景 1	3	12
场景 2	5	15
场景 3	8	24

表 3　各 UAV 性能设置

Table 3　Performance settings of each UAV

U_i	P_{U_i}	V_{U_i} (km/h)	$FT_{\max,\,U_i}$ (h)	$TN_{\max,\,U_i}$
1	(23, 41)	68.72	1.81	3
2	(61, 331)	49.68	2.16	5
3	(398, 293)	64.73	1.59	5
4	(271, 87)	64.55	1.48	5
5	(454, 145)	41.08	1.30	2
6	(225, 311)	67.75	2.21	4
7	(362, 446)	62.32	1.28	5
8	(240, 489)	40.54	2.01	3

为综合评估 MFSOA 的鲁棒性与适应性, 本文选取当前在任务分配领域应用广泛的 5 种智能优化算法作为对比基准, 包括 PSO[20]、DBO[21]、ABC[22]、SOA[30] 以及基于 Tent-Lévy 策略的改进海鸥优化算法 (Tent-Lévy-based improved seagull optimization algorithm, TLISOA)[31]. 各算法的性能以最优值 (Best)、最差值 (Worst)、平均值 (Avg) 与标准差 (Std) 为量化评价指标, 并在三组不同复杂度场景下对各算法的求解性能进行对比分析. 为保证实验结果的可靠性, 各算法均独立运行 30 次, 单次运行的迭代次数设为 500 次, 以最大限度降低随机性对实验结果的影响. 各算法的主要参数配置汇总于表 4. 此外, 算法间性能差异的显著性分析采用 Wilcoxon 秩和检验, 以 P-Value 作为显著性判断依据, 显著性水平设为 0.05. 当 P-Value $<$ 0.05 时, 认为差异具有统计显著性, 否则认为差异不显著. 同时, 采用 $\approx$ 表示 MFSOA 与对比算法之间无显著性差异, ++ 表示 MFSOA 显著优于对比算法, -- 表示 MFSOA 显著劣于对比算法.

所有实验均在配备 AMD Ryzen 77840H 处理器、NVIDIA RTX 4060 显卡及 16 GB 内存的个人

表 4　各算法主要参数设置

Table 4　Main parameter settings of each algorithm

算法	参数	参数值
MFSOA	f_c	2
	u	1
	P_{ne}	0.35
SOA	f_c	2
	v	1
	u	1
TLISOA	f_c	2
	u	1
DBO	k	0.15
	b	0.3
	s	2
PSO	$\omega_{\max}$	0.9
	$\omega_{\min}$	0.3
	c_1	2
	c_2	2

计算机上, 基于 MATLAB R2022b 平台完成.

3.2 实验结果与分析

如图 3 ~ 图 5 所示, 给出了 MFSOA 在各个场景下的任务分配结果, 对应的任务分配方案结果汇总于表 5 中. 进一步地, 图 6 为各算法在三个实验场景下的最优适应值迭代收敛曲线. 从整体趋势来看, MFSOA 在所有场景中均表现出最快的收敛速度与最佳的收敛精度. 该性能优势主要得益于精英进化策略的引入, 该策略能够有效维持种群质量,

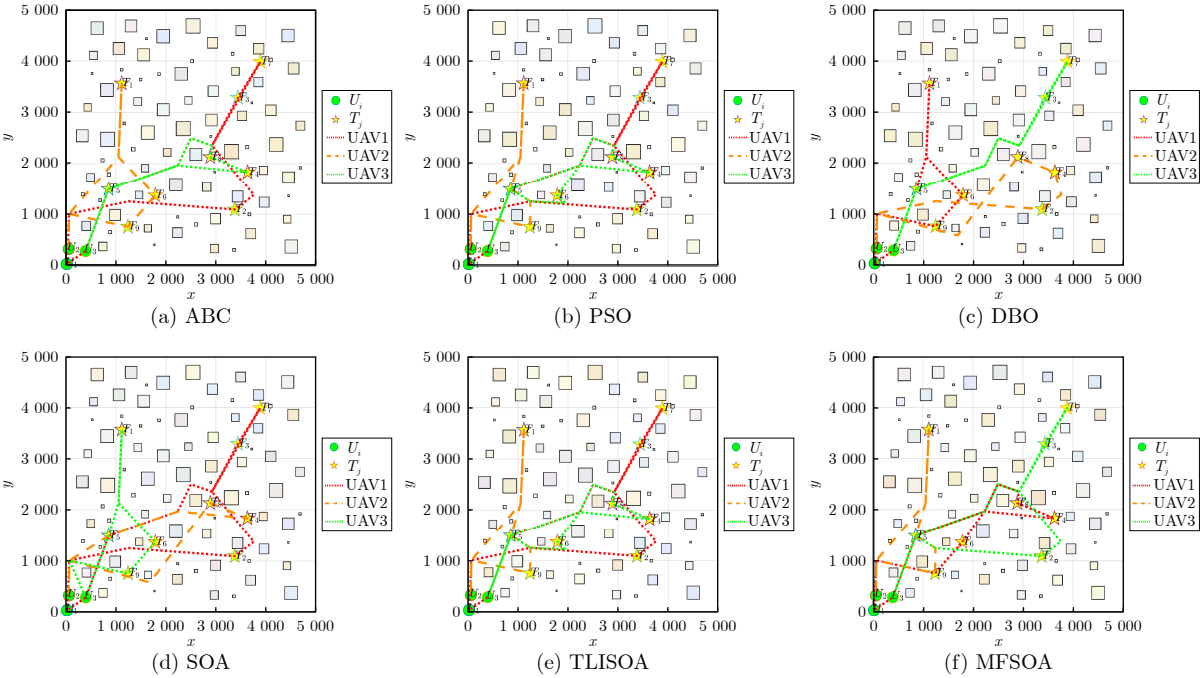


图 3 场景 1: 各算法任务分配结果

Fig. 3 Scene 1: Results of task allocation for each algorithm

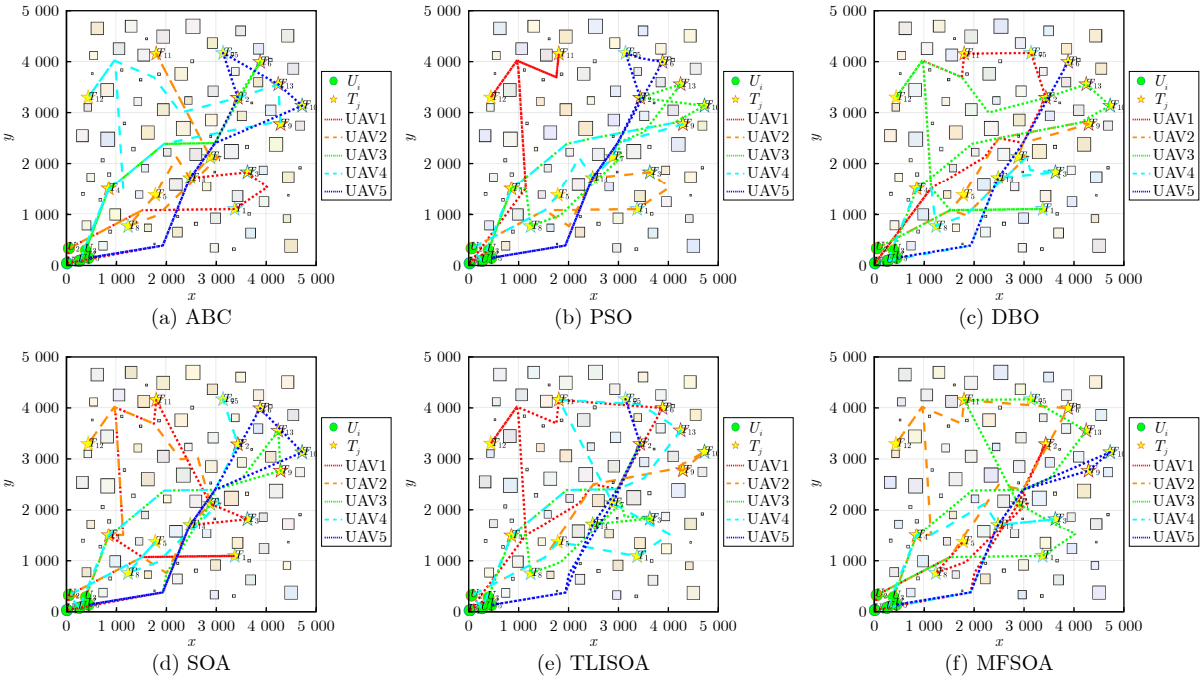


图 4 场景 2: 各算法任务分配结果

Fig. 4 Scene 2: Results of task allocation for each algorithm

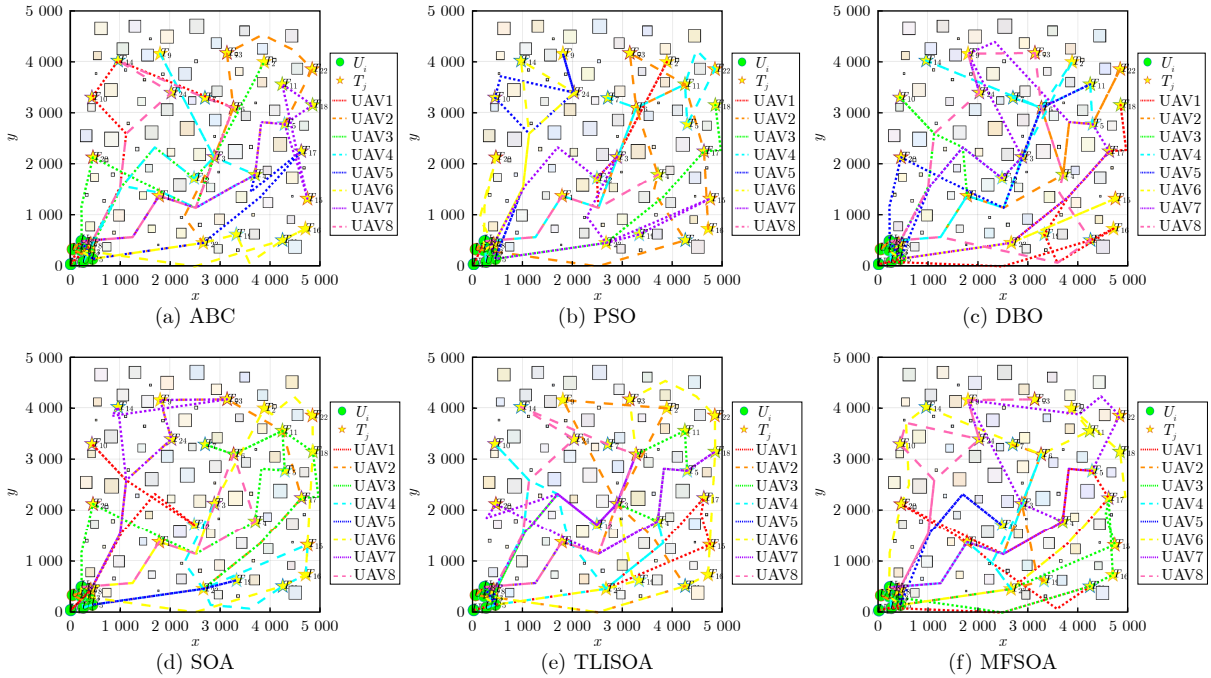


图 5　场景 3: 各算法任务分配结果

Fig. 5　Scene 3: Results of task allocation for each algorithm

从而加快算法的寻优过程. 同时, 多方向自适应迁徙策略增强了算法的全局搜索能力, 而自适应方向依赖系数 K 与衰减系数 A 的协同作用, 进一步提升了算法在不同阶段的搜索灵活性. 相比之下, ABC、DBO 和 PSO 等对比算法不仅收敛速度较慢, 且最终收敛精度也明显劣于 MFSOA. 结合图 7所示的平均适应值迭代收敛曲线可见, MFSOA 在各个场景中的收敛曲线均在约 200 次迭代后趋于稳定, 且其平均适应值均优于其他算法. 这一结果表明, MFSOA 在多无人机协同任务分配问题中具有更高的寻优效率, 同时可以保持最佳的收敛精度, 且在不同场景下均具备优异的性能表现.

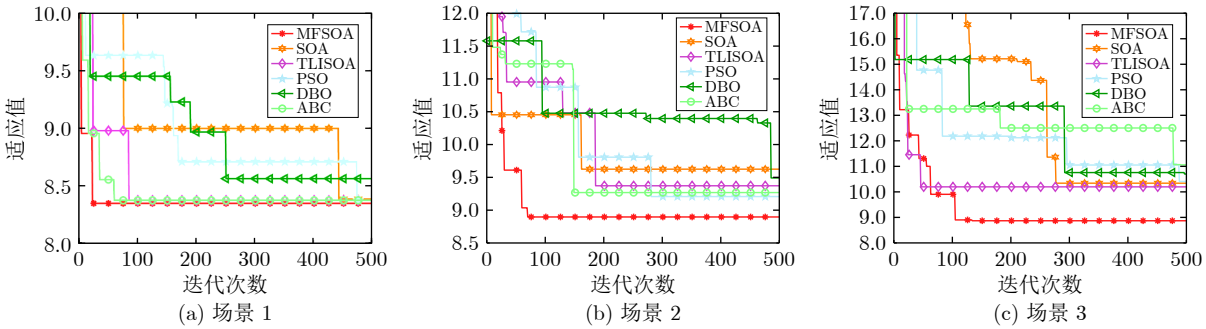
综合表 6 的量化结果可知, MFSOA 在所有测试场景中均表现出最优的综合性能. 其平均值在三类场景中均低于对比算法, 且随着任务规模的增加, 性能优势更为显著. 在场景 3 中, 其平均值较次优算法 TLISOA 降低了约 12.6%. 在最优值方面, MFSOA 在各场景中均取得最优结果, 尽管在场景 1 中优势微弱, 但在场景 2 和场景 3 中, 分别较次优算法 PSO 与 TLISOA 降低了约 3.4% 和 13.0%, 表现出更强的全局寻优能力. 相较之下, ABC 等算法仅在场景 1 中表现出一定竞争力, 但在复杂度增加的场景下性能则显著下降. 在算法稳定性方面, 标准差指标表明, 场景 1 中的 DBO 波动较小, 表现较为稳定, 但随着场景复杂度的增加, MFSOA 的稳定性优势逐渐显现. 在场景 3 中, 其标准差较次优算法 DBO 降低约 9.6%, 表现出最优的稳定性水平. 最差值指标则进一步验证了 MFSOA 的鲁棒性, 在场景 3 中, 其最差性能仍远优于 ABC、PSO 等算法, 性能差距接近 15.0%. 进一步采用 Wilcoxon 秩和检验对 MFSOA 与各对比算法的性能差异进行统计验证. 结果表明, 在三个不同复杂度场景中, MFSOA 与多数对比算法之间均存在统计显著性差异 (P-Value < 0.05), 说明其在多场景下获得的性能优势具有统计可靠性.

结合图 8 ~ 图 10 的箱线图结果可知, MFSOA 在多个测试场景中均展现出显著且稳定的性能优势. 首先, 在场景 1 中, MFSOA 的箱线整体位置处于所有对比算法中最优位置, 其中位数约为 8.7, 明显优于 SOA、TLISOA 与 DBO 等算法, 且箱体范围较窄, 无异常值出现, 而 SOA 与 DBO 等算法存在明显的上下异常值. 这反映出 MFSOA 在该场景下运行波动性较小、鲁棒性更高, 同时寻优结果的集中性更强. 其次, 在场景 2 中, MFSOA 的性能优势进一步延续, 其中位数约为 9.7, 尽管与 PSO 较为接近, 但 MFSOA 的箱体范围更窄, 未随场景复杂度增加出现明显扩张, 数据仍保持高度集中, 表明 MFSOA 在复杂度提升时的稳定性未发生衰减. 最后, 在场景 3 中, MFSOA 的优势尤为突出, 其中位数约为 9.9, 达到所有算法的最优水平, 且箱体范围整体处于所有对比算法的最优区间. 尽管 MFSOA 存在一个异常值, 但该异常值处于合理波

表 5 各算法任务分配方案

Table 5 Task allocation schemes for each algorithm

算法	场景 1	场景 2	场景 3
ABC	$U_1: T_2 \to T_7 \to T_3$ $U_2: T_1 \to T_6 \to T_9$ $U_3: T_5 \to T_4 \to T_8$	$U_1: T_1 \to T_3 \to T_{14}$ $U_2: T_5 \to T_{11} \to T_7 \to T_8$ $U_3: T_4 \to T_6 \to T_2$ $U_4: T_{12} \to T_{13} \to T_9$ $U_5: T_{15} \to T_{10}$	$U_1: T_{10} \to T_6 \to T_3$ $U_2: T_{22} \to T_{13} \to T_{23}$ $U_3: T_2 \to T_{20}$ $U_4: T_8 \to T_4 \to T_9 \to T_{12}$ $U_5: T_1 \to T_{17}$ $U_6: T_{19} \to T_{21} \to T_{16}$ $U_7: T_{18} \to T_{11} \to T_{15} \to T_5$ $U_8: T_{24} \to T_{14} \to T_7$
PSO	$U_1: T_2 \to T_7 \to T_3$ $U_2: T_1 \to T_5 \to T_9$ $U_3: T_6 \to T_4 \to T_8$	$U_1: T_4 \to T_{12} \to T_{11}$ $U_2: T_1 \to T_3 \to T_{14}$ $U_3: T_8 \to T_{13} \to T_2 \to T_{10}$ $U_4: T_5 \to T_7 \to T_9$ $U_5: T_6 \to T_{15}$	$U_1: T_{12} \to T_2$ $U_2: T_{21} \to T_{13} \to T_{16} \to T_{11}$ $U_3: T_{18} \to T_{17}$ $U_4: T_7 \to T_{22} \to T_5 \to T_6$ $U_5: T_{10} \to T_9$ $U_6: T_{20} \to T_8 \to T_{14} \to T_{24}$ $U_7: T_{15} \to T_{19} \to T_{23} \to T_3$ $U_8: T_4 \to T_1$
DBO	$U_1: T_1 \to T_6 \to T_9$ $U_2: T_2 \to T_4 \to T_8$ $U_3: T_5 \to T_7 \to T_3$	$U_1: T_{11} \to T_{15} \to T_2$ $U_2: T_5 \to T_9 \to T_7$ $U_3: T_1 \to T_{12} \to T_{13} \to T_{10}$ $U_4: T_4 \to T_8 \to T_3$ $U_5: T_6 \to T_{14}$	$U_1: T_{18} \to T_{19} \to T_{16}$ $U_2: T_{22} \to T_4 \to T_6 \to T_3$ $U_3: T_1 \to T_{10} \to T_8$ $U_4: T_2 \to T_{14} \to T_5 \to T_7$ $U_5: T_{20} \to T_{11}$ $U_6: T_{15} \to T_{23}$ $U_7: T_{17} \to T_{24} \to T_9 \to T_{12}$ $U_8: T_{13} \to T_{21}$
SOA	$U_1: T_2 \to T_7 \to T_3$ $U_2: T_5 \to T_4 \to T_8$ $U_3: T_1 \to T_6 \to T_9$	$U_1: T_1 \to T_4 \to T_{11} \to T_3$ $U_2: T_{12} \to T_{14}$ $U_3: T_{13} \to T_9 \to T_7$ $U_4: T_5 \to T_8 \to T_{15} \to T_2$ $U_5: T_6 \to T_{10}$	$U_1: T_{10} \to T_{12} \to T_8$ $U_2: T_{24} \to T_9 \to T_{11} \to T_{17}$ $U_3: T_{18} \to T_7 \to T_5 \to T_{20}$ $U_4: T_{15} \to T_{21} \to T_{23} \to T_3$ $U_5: T_{19}$ $U_6: T_1 \to T_2 \to T_{22} \to T_{16}$ $U_7: T_{13} \to T_{14}$ $U_8: T_4 \to T_6$
TLISOA	$U_1: T_2 \to T_7 \to T_3$ $U_2: T_1 \to T_5 \to T_9$ $U_3: T_6 \to T_4 \to T_8$	$U_1: T_4 \to T_{12} \to T_6$ $U_2: T_9 \to T_{10}$ $U_3: T_8 \to T_3 \to T_{14} \to T_2$ $U_4: T_5 \to T_1 \to T_{11} \to T_{13}$ $U_5: T_{15} \to T_7$	$U_1: T_{17} \to T_{15}$ $U_2: T_2 \to T_9 \to T_{21}$ $U_3: T_{11} \to T_5 \to T_3$ $U_4: T_4 \to T_{23} \to T_{10}$ $U_5: T_1 \to T_8$ $U_6: T_{19} \to T_{13} \to T_{22} \to T_{16}$ $U_7: T_{18} \to T_{20} \to T_{12} \to T_6$ $U_8: T_7 \to T_{14} \to T_{24}$
MFSOA	$U_1: T_6 \to T_4 \to T_8$ $U_2: T_1 \to T_5 \to T_9$ $U_3: T_2 \to T_7 \to T_3$	$U_1: T_5 \to T_8 \to T_2 \to T_7$ $U_2: T_{12} \to T_6$ $U_3: T_1 \to T_{11} \to T_{15} \to T_{13}$ $U_4: T_4 \to T_3 \to T_{14}$ $U_5: T_9 \to T_{10}$	$U_1: T_{21} \to T_{20} \to T_5$ $U_2: T_{19} \to T_3 \to T_7$ $U_3: T_{15} \to T_{17} \to T_{16}$ $U_4: T_1 \to T_{23} \to T_6$ $U_5: T_8 \to T_{12}$ $U_6: T_{18} \to T_2 \to T_{11} \to T_{14}$ $U_7: T_{22} \to T_{24} \to T_4$ $U_8: T_{10} \to T_9 \to T_{13}$

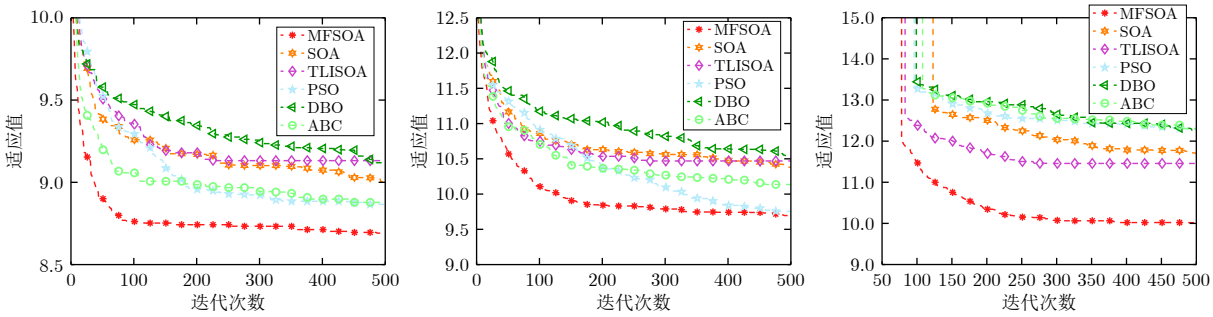


(a) 场景 1 (b) 场景 2 (c) 场景 3

(a) Scene 1 (b) Scene 2 (c) Scene 3

图 6 各算法最优适应值曲线

Fig. 6 Curves of optimal fitness values for each algorithm



(a) 场景 1　(b) 场景 2　(c) 场景 3

(a) Scene 1　(b) Scene 2　(c) Scene 3

图 7　各算法平均适应值曲线

Fig. 7　Curves of average fitness values for each algorithm

表 6　各算法性能对比

Table 6　Performance comparison for each algorithm

场景	算法	Best	Worst	Avg	Std	P-Value	显著性
场景 1	MFSOA	**8.3452**	**9.0674**	**8.6911**	0.2463	--	--
	SOA	8.3816	9.5707	8.9984	0.2561	1.07664e−5	++
	TLISOA	8.3709	9.5418	9.1318	0.2861	3.91382e−7	++
	PSO	8.3709	9.5327	8.8664	0.2744	0.028 069 678	++
	DBO	8.5597	9.5637	9.1149	**0.2158**	4.83916e−8	++
	ABC	8.3711	9.3997	8.8781	0.2460	0.022 309 836	++
场景 2	MFSOA	**8.8965**	10.5623	**9.6955**	0.4119	--	--
	SOA	9.6248	11.3297	10.3809	0.4504	8.84109e−7	++
	TLISOA	9.3718	11.1058	10.4698	0.4320	2.57212e−7	++
	PSO	9.2072	**10.4756**	9.7538	0.3782	0.706 171 488	≈
	DBO	9.4911	11.2327	10.5466	0.3966	1.20233e−8	++
	ABC	9.2683	10.6935	10.1362	**0.2712**	2.13273e−5	++
场景 3	MFSOA	**8.8685**	**11.5420**	**10.0170**	**0.5490**	--	--
	SOA	10.3406	13.0019	11.6999	0.6859	3.82016e−10	++
	TLISOA	10.1968	12.7229	11.4576	0.6565	1.41098e−9	++
	PSO	10.4081	13.5471	12.2842	0.6693	7.38908e−11	++
	DBO	10.6991	13.3464	12.1833	0.6072	6.06576e−11	++
	ABC	11.0582	13.5474	12.3074	0.6576	4.50432e−11	++

动范围内, 而 PSO、DBO 等对比算法存在较多离散异常值. 即使在场景复杂度增加的情况下, MFSOA 的整体稳定性仍显著优于其他对比算法, 表明该算法寻优结果波动最小、鲁棒性最佳.

箱线图呈现的分布特征与本文所提策略紧密对应. Tent 混沌映射初始化为算法提供了分布均匀、多样性充足的初始种群, 从源头上提升了搜索的稳健性. 精英驱动的差异化攻击策略在迭代过程中动态平衡探索与开发, 使算法在复杂场景下能够保持搜索方向的有效性与适应性. 二者的协同作用保障了 MFSOA 在多种复杂度场景中表现出集中、稳定且优越的分布性能.

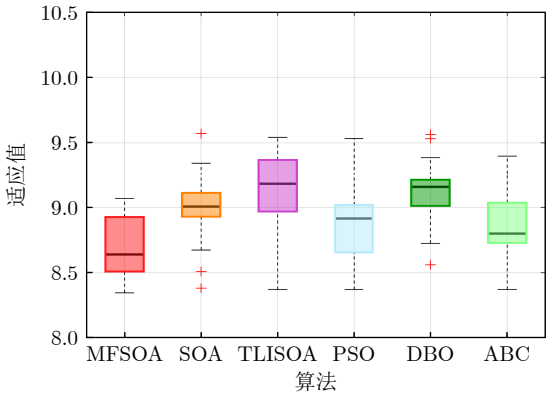


图 8　场景 1: 各算法箱线图

Fig. 8　Scene 1: Box plots for each algorithm

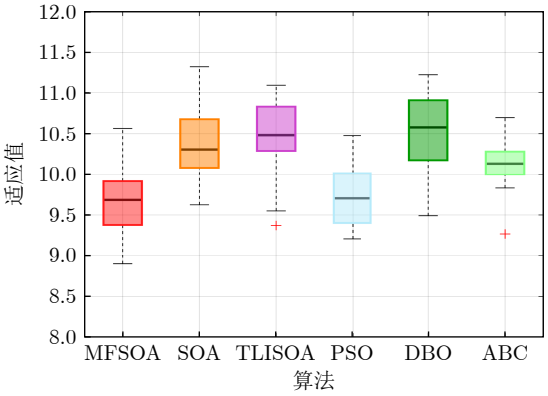


图 9 场景 2: 各算法箱线图

Fig. 9 Scene 2: Box plots for each algorithm

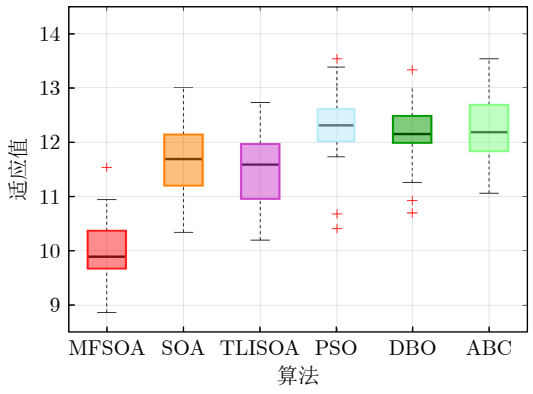


图 10 场景 3: 各算法箱线图

Fig. 10 Scene 3: Box plots for each algorithm

综上所述, 由收敛曲线、量化指标和数据分布特征的分析结果得出, MFSOA 通过多策略的有效融合, 在收敛速度、寻优精度、稳定性和适应性等方面展现出显著优势, 具有优异的综合性能.

4 结束语

本文针对多无人机协同任务分配问题, 构建了综合考虑无人机多约束条件的优化模型, 并提出一种融合多策略的海鸥优化算法. 该算法通过混沌映射初始化种群, 结合精英进化策略提升种群质量; 采用多方向探索与自适应攻击机制, 有效平衡了全局探索与局部开发能力, 避免了早熟收敛. 仿真实验表明, 在不同规模任务场景下, MFSOA 在收敛速度、求解精度和鲁棒性上均显著优于对比算法, 验证了其解决复杂任务分配问题的有效性和优越性, 能够满足多无人机协同作战的基本需求. 本研究为多无人机协同任务分配问题提供了高效的算法解决方案与改进思路. 未来工作将进一步探索动态不确定环境下的任务分配问题, 优化算法在不同架构下的部署策略, 以拓展算法的实际工程应用范围.

参考文献

1 Jia Z S, Xiao B, Qian H Y. Improved mixed discrete particle swarms based multi-task assignment for UAVs. In: Proceedings of the 12th Data Driven Control and Learning Systems Conference (DDCLS). Xiangtan, China: IEEE, 2023. 442−448

2 Jiang Bi-Tao, Wen Guang-Hui, Zhou Jia-Ling, Zheng De-Zhi. Cross-domain cooperative technology of intelligent unmanned swarm systems: Current status and prospects. *Strategic Study of CAE*, 2024, **26**(1): 117−126
(江碧涛, 温广辉, 周佳玲, 郑德智. 智能无人集群系统跨域协同技术研究现状与展望. 中国工程科学, 2024, **26**(1): 117−126)

3 Jiang Bin, Ma Ya-Jie, Xue Shu-Xin. Autonomous control of unmanned aerial vehicle swarms: Task allocation based on coalition formation game. *Acta Automatica Sinica*, 2025, **51**(5): 942−959
(姜斌, 马亚杰, 薛舒心. 无人飞行器集群自主控制: 基于联盟形成博弈的任务分配. 自动化学报, 2025, **51**(5): 942−959)

4 Ye F, Chen J, Tian Y, Jiang T. Cooperative task assignment of a heterogeneous multi-UAV system using an adaptive genetic algorithm. *Electronics*, 2020, **9**(4): Article No. 687

5 Xue Ya-Li, Li Han-Yan, Ouyang Quan, Cui Shan, Hong Jun. Multi-UAVs collaborative task allocation based on genetic slime mould algorithm in battlefield environment. *Journal of Zhejiang University* (*Engineering Science*), 2024, **58**(8): 1748−1756
(薛雅丽, 李寒雁, 欧阳权, 崔闪, 洪君. 战场环境下遗传黏菌算法的多机协同任务分配. 浙江大学学报 (工学版), 2024, **58**(8): 1748−1756)

6 Ju Kai, Mao Ze-Hui, Jiang Bin, Ma Ya-Jie. Task allocation and reallocation for heterogeneous multiagent systems based on potential game. *Acta Automatica Sinica*, 2022, **48**(10): 2416−2428
(鞠锴, 冒泽慧, 姜斌, 马亚杰. 基于势博弈的异构多智能体系统任务分配和重分配. 自动化学报, 2022, **48**(10): 2416−2428)

7 Wang Feng, Huang Zi-Lu, Han Meng-Chen, Xing Li-Ning, Wang Ling. A knee point based coevolution multi-objective particle swarm optimization algorithm for heterogeneous UAV cooperative multi-task allocation. *Acta Automatica Sinica*, 2023, **49**(2): 399−414
(王峰, 黄子路, 韩孟臣, 邢立宁, 王凌. 基于 KnCMPSO 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)

8 Yang W Z, Xin Y. Multi-UAV task assignment based on quantum genetic algorithm. *Journal of Physics: Conference Series*, 2021, **1824**: Article No. 012010

9 Qin B Y, Zhang D, Tang S, Wang M Y. Distributed grouping cooperative dynamic task assignment method of UAV swarm. *Applied Sciences*, 2022, **12**(6): Article No. 2865

10 Wen Guang-Hui, Zhou Jia-Ling, Lv Yue-Zu, Liu Zhao-Hui, Lv Jin-Hu. Distributed coordination control in multi-missile cooperative tasks. *Journal of Command and Control*, 2021, **7**(2): 137−145
(温广辉, 周佳玲, 吕跃祖, 刘照辉, 吕金虎. 多导弹协同作战中的分布式协调控制问题. 指挥与控制学报, 2021, **7**(2): 137−145)

11 Rao Ling-Feng, Geng Na, Zhang Yong, Guo Guang-Song, Xiao Lei. Population interactive particle swarm optimization algorithm for UAV task allocation in uncertain environments. *Acta Electronica Sinica*, 2025, **53**(8): 2678−2690
(饶凌风, 耿娜, 张勇, 郭广颂, 肖磊. 不确定环境下无人机任务分配的种群交互式粒子群算法. 电子学报, 2025, **53**(8): 2678−2690)

12 Zhang J, Xing J H. Cooperative task assignment of multi-UAV system. *Chinese Journal of Aeronautics*, 2020, **33**(11): 2825−2827

13 Wen G H, Yu W W, Chen M Z Q, Yu X H, Chen G R. Pinning a complex network to follow a target system with pre-

designed control inputs. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2020, **50**(6): 2293−2304

14 Yu X Y, Gao X H, Wang L, Wang X W, Ding Y, Lu C, et al. Cooperative multi-UAV task assignment in cross-regional joint operations considering ammunition inventory. *Drones*, 2022, **6**(3): Article No. 77

15 Seenu N, Kuppan C R M, Ramya M M, Janardhanan M N. Review on state-of-the-art dynamic task allocation strategies for multiple-robot systems. *Industrial Robot*, 2020, **47**(6): 929−942

16 Wang Wei, Xie Hui, Wei Zhong-Cheng, Zhao Ji-Jun, Peng Li. Two-stage robust optimization method for UAV task assignment under uncertain demand. *Acta Electronica Sinica*, 2024, **52**(10): 3552−3561
(王巍, 解慧, 魏忠诚, 赵继军, 彭力. 不确定需求下无人机任务分配的两阶段鲁棒优化方法. 电子学报, 2024, **52**(10): 3552−3561)

17 Lippi M, Marino A. A mixed-integer linear programming formulation for human multi-robot task allocation. In: Proceedings of the 30th IEEE International Conference on Robot & Human Interactive Communication (RO-MAN). Vancouver, Canada: IEEE, 2021. 1017−1023

18 Li J X, Yang X R, Yang Y J, Liu X L. Cooperative mapping task assignment of heterogeneous multi-UAV using an improved genetic algorithm. *Knowledge-Based Systems*, 2024, **296**: Article No. 111830

19 Yan F, Chu J, Hu J W, Zhu X P. Cooperative task allocation with simultaneous arrival and resource constraint for multi-UAV using a genetic algorithm. *Expert Systems With Applications*, 2024, **245**: Article No. 123023

20 Sun B, Zeng Y R, Zhu D Q. Dynamic task allocation in multi autonomous underwater vehicle confrontational games with multi-objective evaluation model and particle swarm optimization algorithm. *Applied Soft Computing*, 2024, **153**: Article No. 111295

21 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

22 Kaya E, Gorkemli B, Akay B, Karaboga D. A review on the studies employing artificial bee colony algorithm to solve combinatorial optimization problems. *Engineering Applications of Artificial Intelligence*, 2022, **115**: Article No. 105311

23 Hu Sheng-Rong, Wang Qiang, Qian Yue, Du Xiong-Zi, Zheng Wen-Tian. Multi-UAV cooperative strike task assignment and path planning algorithm for urban environments. *Acta Armamentarii*, 2026, **47**(1): 200−218
(胡晟荣, 王强, 钱玥, 杜雄梓, 郑文天. 面向城市环境的多无人机协同打击任务分配与路径规划算法. 兵工学报, 2026, **47**(1): 200−218)

24 Wang Z H, Zhang J L. A task allocation algorithm for a swarm of unmanned aerial vehicles based on bionic wolf pack method. *Knowledge-Based Systems*, 2022, **250**: Article No. 109072

25 Wei Z T, Zhao X L. Multi-UAVs cooperative reconnaissance task allocation under heterogeneous target values. *IEEE Access*, 2022, **10**: 70955−70963

26 Xiao Peng, Xie Feng, Ni Hai-Hong, Zhang Min, Tang Zhi-Li, Li Ni. Research on collaborative optimization method of multi-UAV task allocation and path planning. *Journal of System Simulation*, 2024, **36**(5): 1141−1151
(肖鹏, 谢锋, 倪海鸿, 张敏, 汤志荔, 李霓. 多机任务分配与路径规划协同优化法研究. 系统仿真学报, 2024, **36**(5): 1141−1151)

27 Kurdi H, AlDaood M F, Al-Megren S, Aloboud E, Aldawood A S, Youcef-Toumi K. Adaptive task allocation for multi-UAV systems based on bacteria foraging behaviour. *Applied Soft Computing*, 2019, **83**: Article No. 105643

28 Wang Yu, Ma Chun-Rong, Zhao Ming-Yue. Collaborative multi-task assignment of heterogeneous UAVs based on hybrid strategies based multi-objective particle swarm. *Journal of Zhejiang University* (*Engineering Science*), 2025, **59**(4): 821−831
(王昱, 马春荣, 赵明月. 基于混合策略多目标粒子群的异构无人机协同多任务分配. 浙江大学学报 (工学版), 2025, **59**(4): 821−831)

29 Wang Jun-Jie, Yan Dong-Yu, Hao Yong-Ping, Xu Jiu-Long. A cooperative task allocation method for multi-UAV in large-scale scenarios. *Acta Armamentarii*, 2026, **47**(1): 244−260
(王俊杰, 闫东宇, 郝永平, 徐九龙. 大规模任务场景下多无人机协同任务分配方法. 兵工学报, 2026, **47**(1): 244−260)

30 Dhiman G, Kumar V. Seagull optimization algorithm: Theory and its applications for large-scale industrial engineering problems. *Knowledge-Based Systems*, 2019, **165**: 169−196

31 Zhou Z, Liu H, Dai Y Q, Qin L J. A Tent-Lévy-based seagull optimization algorithm for the multi-UAV collaborative task allocation problem. *Applied Sciences*, 2024, **14**(13): Article No. 5398

32 Chen J, Chen X, Fu Z F. Improvement of the seagull optimization algorithm and its application in path planning. *Journal of Physics: Conference Series*, 2022, **2216**: Article No. 012076

33 Jia H M, Xing Z K, Song W L. A new hybrid seagull optimization algorithm for feature selection. *IEEE Access*, 2019, **7**: 49614−49631

34 Hou P J, Liu J, Ni F, Zhang L Y. Hybrid strategies based seagull optimization algorithm for solving engineering design problems. *International Journal of Computational Intelligence Systems*, 2024, **17**(1): Article No. 62

35 Pathak V K, Gangwar S, Dikshit M K. A comprehensive survey on seagull optimization algorithm and its variants. *Archives of Computational Methods in Engineering*, 2025, **32**(6): 3651−3685



王传云 沈阳航空航天大学人工智能学院副教授. 主要研究方向为模式识别.
E-mail: wangcy0301@sau.edu.cn
(**WANG Chuan-Yun** Associate professor at the College of Artificial Intelligence, Shenyang Aerospace University. His main research interest is pattern recognition.)



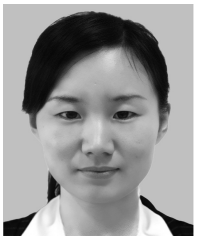
邢佳庆 沈阳航空航天大学人工智能学院硕士研究生. 主要研究方向为智能无人系统.
E-mail: xingjiaqing@stu.sau.edu.cn
(**XING Jia-Qing** Master student at the College of Artificial Intelligence, Shenyang Aerospace University. His main research interest is intelligent unmanned systems.)



王 田 北京航空航天大学人工智能学院教授. 主要研究方向为计算机视觉. 本文通信作者.
E-mail: wangtian@buaa.edu.cn
(**WANG Tian** Professor at the Institute of Artificial Intelligence, Beihang University. His main research interest is computer vision. Corresponding author of this paper.)



高 骞 沈阳航空航天大学人工智能学院讲师. 主要研究方向为虚拟现实与仿真.
E-mail: gaoqian@buaa.edu.cn
(**GAO Qian** Lecturer at the College of Artificial Intelligence, Shenyang Aerospace University. His research interests include virtual reality and simulation.)



王琳霖 沈阳航空航天大学人工智能学院教授. 主要研究方向为机器博弈.
E-mail: wanglinlin@sau.edu.cn
(**WANG Lin-Lin** Professor at the College of Artificial Intelligence, Shenyang Aerospace University. Her main research interest is machine game.)



郑会龙 中国科学院工程热物理研究所研究员. 主要研究方向为航空航天智能结构及制造.
E-mail: zhenghuilong@iet.cn
(**ZHENG Hui-Long** Researcher at the Institute of Engineering Thermophysics, Chinese Academy of Sciences. His research interests include aerospace intelligent structures and manufacturing.)