

基于超启发式算法的无人机自组网多目标拓扑优化控制

徐智豪, 张柯[†], 邢卓琳, 姜斌, 叶准元

(南京航空航天大学 自动化学院, 南京 211106)

摘要: 针对无人机自组网在复杂任务场景下拓扑控制存在的优化目标单一、多目标优先级模糊及传统算法快速寻优能力不足等问题, 提出基于超启发式算法的多目标拓扑优化控制方案. 首先, 建立涵盖网络连通度、总吞吐量、端到端平均时延及通信总能耗的多目标联合优化模型, 为网络拓扑全局性能评估提供多目标协同标准; 然后, 采用博弈论纳什均衡结合的主客观融合权重标定法, 协调主观经验与客观数据, 增强方案对不同场景的指标赋权准确性; 最后, 设计基于灰狼优化及改进模拟退火的超启发式算法, 依托灰狼算法全局搜索定位优质解区域, 结合改进模拟退火动态退温策略接受次优解, 实现次数下的全局最优与寻优精度提升. 仿真验证表明, 该方案可适配不同任务场景, 且较其他先进启发式算法, 其收敛速度与全局寻优能力均展现显著优势.

关键词: 无人机自组网; 多目标优化; 主客观组合赋权; 超启发式算法; 拓扑控制; 拓扑优化

中图分类号: TP273; TP393.04; TN929.52 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.1197

引用格式: 徐智豪, 张柯, 邢卓琳, 等. 基于超启发式算法的无人机自组网多目标拓扑优化控制 [J]. 控制与决策.

Multi-objective topology optimization and control for UAV ad hoc network based on hyper-heuristic algorithm

XU Zhi-hao, ZHANG Ke[†], XING Zhuo-lin, JIANG Bin, YE Zhun-yuan

(College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: In this paper, a multi-objective topology optimization and control scheme based on hyper-heuristic algorithms is proposed to tackle the problems of UAV ad hoc network topology control under complex task scenarios, namely single optimization objective, ambiguous multi-objective priorities, and inadequate fast optimization ability of traditional algorithms. Firstly, a multi-objective joint optimization model covering network connectivity, total throughput, average end-to-end delay, and total communication energy consumption is established, offering a multi-objective collaborative criterion for global network topology performance evaluation. Secondly, a subjective-objective integrated weight calibration method combined with game-theoretic Nash equilibrium is proposed to balance subjective experience and objective data, improving index weighting accuracy across different scenarios. Finally, a hyper-heuristic algorithm integrating grey wolf optimizer (GWO) and improved simulated annealing algorithm (ISAA) is designed: GWO conducts global search to locate high-quality solution regions, while ISAA's dynamic cooling strategy accepts suboptimal solutions, realizing global optimality and higher optimization accuracy with fewer iterations. Simulation validations show that the scheme adapts well to different task scenarios and outperforms other advanced heuristic algorithms in convergence speed and global optimization capability.

Keywords: UAV ad hoc networks; multi-objective optimization; integrated subjective-objective weighting; hyper-heuristic algorithm; topology control; topology optimization

0 引言

近年来, 无人机凭借部署灵活快速、成本可控、可重复利用、扩展性强及具备视距链路支持能力等核心优势^[1], 在军事侦察、民用服务等领域的应用深度与广度得到持续拓展. 随着军民用技术快速迭代

及低空经济加速崛起, 无人机所承担的任务正逐步向复杂化、精确化方向演进. 面对大规模测绘、物资投送等复杂任务, 单架无人机存在效率低、任务承载量有限的短板; 而无人机集群具备部署效率高、抗干扰能力强、协同效能突出等优势, 成为突破单无人机

收稿日期: 2025-11-19; 录用日期: 2026-03-04.

基金项目: 国家自然科学基金项目 (U25A20453, 62173180); 江苏省自然科学基金项目 (BZ2024037).

[†]通信作者. E-mail: kezhang@nuaa.edu.cn.

作业能力局限、提升复杂任务完成效能的最有效解决方案^[2-5]。在此背景下,无人机集群技术顺势应运而生,成为突破单无人机能力瓶颈的核心技术方向^[6]。目前,无人机集群系统已成为应急救援、物流配送、环境监测、城市安防及军事作战关键领域的核心技术支撑^[7],而其组网架构的可靠性则直接决定了任务执行效能^[8]。

在多无人机系统的组网架构中,无人机自组网相较于以地面基站为核心的集中式组网,因具备移动范围广、节点能耗低、部署场景约束少等显著优势,已成为主流组网模式^[9]。然而,无人机自组网存在节点密度低、移动性强、链路易受环境干扰中断的固有特性,这对网络连通性的持续维持提出了更高挑战^[10];同时,不同应用场景对网络性能的需求存在显著差异:例如,灾后救援场景要求无人机将灾情信息实时回传至地面终端,需网络具备低通信时延^[11];数据收集场景则需通过高吞吐量加快数据汇聚效率^[12]。因此,研发兼具快速响应能力、高鲁棒性与强适应性的无人机自组网拓扑优化控制方案,已成为提升多无人机系统任务效能的核心需求。

现有无人机自组网拓扑控制研究中,文献[8-9, 13-15]系统梳理了该领域的研究进展,深入分析了无人机自组网的网络架构分类与典型拓扑控制方法,但现有综述所覆盖的研究多聚焦于非动态场景,且常以网络连通性为单一算法目标,对网络吞吐量、通信能耗等核心性能指标间的协同优化问题关注不足。具体研究方面,文献[16]设计了基于联盟图博弈的自适应拓扑控制算法,虽能解决地下灾害场景下无人机应急通信网络因拓扑快速变化导致的连通性频繁失效问题,但该算法在应对更复杂动态拓扑时的适应性仍显不足;文献[17]提出基于单位圆盘图的虚拟节点拓扑控制算法,有效突破了无人机空间激光通信自组网的节点度上限瓶颈,但该算法未纳入激光通信场景特有的能耗均衡、激光链路传输时延等优化目标,导致其在复杂动态任务场景以及大规模网络中的适用性方面存在缺陷;文献[18]针对无人机集群规模扩大后的拓扑控制需求,在模糊C聚类算法基础上提出改进方案,但该算法缺乏动态场景下的策略适配能力,难以应对网络拓扑结构的实时变化;文献[19-20]虽综合考虑了节点剩余能量、网络时延及负载均衡度等性能指标,但在多目标优化函数的权重计算中完全依赖主观经验,权重设置的客观性与场景适应性不足,难以适配精度高、场景多样化的任务需求。文献[21]提出一种基于改进灰狼算法的分簇优化方法,解决了无人机集群网络结

构不稳定以及网络生命周期短的问题,但算法全局搜索能力不足,难以应对快速时变的自组网拓扑高性能需求。

值得注意的是,近年来随着人工智能技术的发展,深度强化学习(DRL)^[22]及图神经网络(GNN)^[23]等方法被频繁应用于无人机自组网拓扑优化控制领域: DRL方法通过环境交互训练策略网络,具备较强的动态场景适配能力,但需大量标注样本与训练时间,实时性难以满足无人机自组网的快速拓扑变化需求; GNN虽然擅长挖掘拓扑结构的深层特征,但其计算复杂度随网络规模呈指数增长,在大规模无人机集群中扩展性不足,且对节点移动导致的拓扑突变鲁棒性较弱。

针对上述研究现状存在的问题,本文提出一种基于超启发式算法的无人机自组网多目标联合优化拓扑控制方案,其主要工作内容与优越性如下:

1) 针对文献[16-18]中拓扑控制方案因优化目标单一导致的资源浪费及复杂场景适应性差的问题,构建了多目标联合评估的无人机自组网数学模型,将网络连通度、总吞吐量、端到端平均时延及通信总能耗纳入统一优化框架,实现多性能指标的协同考量。

2) 针对文献[19-20]中指标权重计算依赖单一主观/客观方法的局限性,设计了基于博弈论的主客观融合权重标定法(analytic network process and criteria importance through intercriteria correlation, ANP-CRITIC)。通过纳什均衡机制寻找最优权重组合,实现主观经验与客观数据的有机结合,有效化解多目标间的权重冲突,提升权重设置的科学性与场景适配性。

3) 针对文献[21]中算法收敛性以及全局寻优能力不足的缺陷,同时弥补文献[22-23]深度强化学习(DRL)、图神经网络(GNN)等新兴方法在实时性、扩展性上的短板,提出基于灰狼优化及改进模拟退火的超启发式算法(Hyper-heuristic Algorithm Based on Grey Wolves Optimizer and Improved Simulated Annealing Algorithm, HGWO-ISAA)。该算法既继承了传统启发式无需离线训练、实时响应快、计算复杂度低的核心优势,又通过动态策略调度突破常规混合启发式的僵化局限,有效提升了算法的收敛速度与全局寻优精度,精准适用于高动态、任务场景及集群规模多样的无人机自组网拓扑优化控制问题。

1 系统建模与问题描述

本章聚焦无人机自组网相关模型与问题的构建,

首先完成无人机自组网模型的建立与网络核心评估指标的定义, 其次构建多目标联合优化模型, 并最终完成无人机拓扑优化控制问题的规范化数学描述.

1.1 无人机自组网模型

在所考虑的场景中, 无人机以编队形式在空间内飞行, 其构成的自组网包含若干无人机通信节点, 记节点集合为 $\mathbb{N} = \{1, 2, \dots, N\}$. 每架无人机配备计算能力一致的运算单元, 且所有无人机的通信半径统一设定为 r . 对于任意无人机 $i (i \in \mathbb{N})$, 其空间坐标定义为 $p_i = (x_i, y_i, z_i)$; 仅当无人机 i 与无人机 $j (j \in \mathbb{N}, j \neq i)$ 的间距 d_{ij} 满足 $d_{ij} \leq r$ (即两机处于彼此通信覆盖范围内) 时, 方可建立直接通信链路. 进一步定义无人机 i 的邻居节点 (一跳邻居节点) 集合为 J_i , 即所有可与无人机 i 建立直接通信连接的节点构成的集合, 满足 $J_i = \{j \in \mathbb{N} \mid d_{ij} \leq r, j \neq i\}$.

为明确拓扑结构的核心构成, 定义以下三类集合:

1. 通信链路集合 \mathbb{L} : 表示无人机编队中所有实际可建立的可用通信链路构成的集合, 即 $\mathbb{L} = \{(i, j) \mid i \in \mathbb{N}, j \in J_i\}$;

2. 通信拓扑集合 \mathbb{L}_c : 作为 \mathbb{L} 的子集, 代表无人机集群当前实际选用的通信链路构成的集合, 直接决定当前网络拓扑结构;

3. 冗余拓扑集合 \mathbb{L}_r : 为 \mathbb{L}_c 在 \mathbb{L} 中的补集 (即 $\mathbb{L}_r = \mathbb{L} \setminus \mathbb{L}_c$), 对应无人机节点间可建立但未选用的通信链路集合.

本文主要考虑无人机自组网通信参数的优化, 而对于无人机位置集合则交由航迹规划层决定^[24], 因此无人机自组网拓扑优化控制问题的核心优化参数包括: 无人机自组网的通信拓扑集合 \mathbb{L}_c , 以及每架无人机 $i (i \in \mathbb{N})$ 的可调节电台参数包括发射功率 $P_{tx,i}$ 、接收功率 $P_{rx,i}$ 与工作带宽 B_i .

1.2 多目标联合优化模型

为提高无人机自组网的拓扑抗毁性、网络传输性能以及网络续航能力, 本文选取无人机自组网的网络连通度、网络总吞吐量、节点端到端平均时延以及网络通信总能耗作为核心优化指标. 具体指标定义如下:

1) 网络连通度

网络连通度 (点连通度) 是保障无人机自组网协同作业的核心前提, 表征网络维持节点连接的最小“抗破坏能力”. 其图论定义为: 设无人机自组网拓扑图为 $G = (\mathbb{N}, \mathbb{L}_c)$ (\mathbb{N} 为节点集合, \mathbb{L}_c 为通信拓扑

集合), 连通度 K 是使 G 变为非连通图所需移除的最小节点数, 其数学表达式为:

$$K = \begin{cases} 0, & \text{网络不连通} \\ N - 1, & \text{网络是完全图} \\ \min |S|, & \text{非完全连通图} \end{cases} \quad (1)$$

其中 $S \subseteq \mathbb{N}$ 为 G 的顶点割集 (移除 S 后 G 非连通); $\min |S|$ 表示所有顶点割集中的最小基数.

2) 网络总吞吐量

网络总平均吞吐量指在单位时间内, 网络所有节点成功接收或传输的数据量, 它直接反映无人机自组网中数据传输的整体承载能力与效率^[25], 能够衡量集群能否高效支撑多节点协同侦察、实时数据回传、任务指令分发等数据密集型任务——其数值高低直接关系到集群任务执行的实时性与数据完整性, 因此将网络总吞吐量作为衡量无人机自组网传输性能的核心指标之一. 网络总吞吐量定义为^[25]:

$$C = \sum_{i \in \mathbb{N}} \sum_{j \in J_i} B_i \log_2 \left(1 + \frac{P_{tx,i} \frac{\rho_0}{d_{ij}^2}}{\sum_{k \in \mathcal{I}(i,j)} h_{kj} P_{tx,k} + n_0 B_i} \right) \quad (2)$$

其中 $\mathcal{I}(i, j)$ 表示当前除了无人机 i 以外, 其他正在发送数据到无人机 j 的无人机集合; n_0 、 ρ_0 分别表示噪声功率谱密度以及单位距离信道增益系数.

3) 节点端到端平均时延

节点端到端平均时延指网络中所有节点两两之间传输数据所消耗时间的平均值, 它能够直观反映无人机自组网中数据传输的整体及时性与可靠性^[8], 是衡量网络能否为任务协同、态势共享等集群应用提供高效、低延迟通信支撑的核心指标, 直接影响集群任务执行的同步性与决策效率. 由于数据在无障碍空气介质中的传播时延可近似忽略, 节点端到端平均时延定义为:

$$T_{\text{avd}} = \frac{\tau \sum_{i \in \mathbb{N}} \sum_{j \in \mathbb{N}, j \neq i} h_{ij}}{N(N-1)}. \quad (3)$$

其中 h_{ij} 表示无人机 i 到无人机 j 之间的最少跳数路径的跳数; τ 表示无人机自组网单跳时延, 本文采用无人机自组网中主流的 TDMA (时分多址) 协议进行设定, 该协议通过时隙划分避免通信冲突, 具体构成如下^[26]:

$$\tau = \tau_{\text{sync}} + \tau_{\text{slot}} + \tau_{\text{proc}}. \quad (4)$$

其中 τ_{sync} 表示无人机自组网中节点同步时延, TDMA 协议中各节点需基于全局时钟校准时隙同步, 结合无人机自组网的动态拓扑特性进行设定; τ_{slot} 表示无

人机自组网中节点时隙占用时延,由网络数据包大小所决定; τ_{proc} 表示无人机自组网中节点数据处理时延,由无人机机载通信模块的计算能力所决定.

4) 网络通信总能耗

网络通信总能耗指无人机自组网中所有节点在网络活跃时间内消耗的能量总和,它直接反映无人机自组网中能量利用效率,是衡量集群能否高效支撑多节点协同侦察、实时数据回传、任务指令分发等数据密集型任务的核心指标之一.网络通信总能耗定义为^[27]:

$$E = \sum_{i \in \mathbb{N}} P_c T_{\text{act}} + \frac{D_{\text{load}} T_{\text{act}}}{C_l} \sum_{l \in \mathbb{L}_c} (P_{\text{tx},il} + P_{\text{rx},jl}). \quad (5)$$

其中 P_c 表示无人机通信模块电路功率; T_{act} 表示网络活跃时间; D_{load} 表示链路数据负载; C_l 表示链路 l 的吞吐量; $P_{\text{tx},il}$ 、 $P_{\text{rx},jl}$ 分别表示链路 l 的源节点 i 的发射功率和目的节点 j 的接收功率.

上述核心优化指标的量纲与数值量级差异显著,若直接融合计算,数值量级更大的指标会主导性能评估,量级较小的指标贡献被大幅弱化,最终导致评估结果失真,无法体现各指标的真实影响.因此,需采用标准化方法对所有指标进行无量纲化处理,以保障多目标优化的公平性.

本文采用离差标准化作为核心标准化手段,其优势在于能将指标值直接映射至 $[0, 1]$ 区间,直观反映指标相对优劣程度.

假设某一指标的原始数据集合为 $\Theta = \{\theta_1, \theta_2, \dots, \theta_n\}$ (n 为数据样本数); 集合中最大指标值为 $\max(\Theta)$, 最小指标值为 $\min(\Theta)$.

对于正向指标(网络连通度、网络总吞吐量,数值越大性能越优),标准化后的数据 $\theta_{\text{nor},k}$ 计算公式为:

$$\theta_{\text{nor},k} = \frac{\theta_k - \min(\Theta)}{\max(\Theta) - \min(\Theta)} \quad (k = 1, 2, \dots, n). \quad (6)$$

对于负向指标(节点端到端平均时延、网络通信总能耗,数值越小性能越优),需进行负向归一化,计算公式为:

$$\theta_{\text{nor},k} = \frac{\max(\Theta) - \theta_k}{\max(\Theta) - \min(\Theta)} \quad (k = 1, 2, \dots, n). \quad (7)$$

值得注意的是,为避免分母为 0 的无意义场景,补充约定:若指标集合中所有样本数据一致,则该指标所有标准化后的值统一取 1.

将上述核心优化指标进行标准化方法处理后得到无量纲化的标准指标值,分别记为 K_{nor} 、 C_{nor} 、 T_{nor} 、 E_{nor} . 融合上述四个标准核心指标,多目标联合优化效用函数定义为:

$$\Phi = \Gamma(w_1 K_{\text{nor}} + w_2 C_{\text{nor}} + w_3 T_{\text{nor}} + w_4 E_{\text{nor}}). \quad (8)$$

其中 w_i ($i = 1, 2, 3, 4$) 为优化指标对应的权重系数,且 $\sum_{i=1}^4 w_i = 1$. 此外,因为网络连通为自组网的基本要求,所以网络连通性参数 Γ 为乘项因子且当网络不连通时为 0,网络连通时为 1.

1.3 无人机自组网拓扑优化控制问题描述

无人机自组网拓扑优化控制的目标是:通过调整无人机通信链路集合与节点通信模块参数,在保障网络连通性的基础上,最大化综合多目标联合优化效用函数.定义无人机集群的发射功率集合为 $\mathbb{P}_{\text{tx}} = \{P_{\text{tx},1}, P_{\text{tx},2}, \dots, P_{\text{tx},N}\}$,接收功率集合为 $\mathbb{P}_{\text{rx}} = \{P_{\text{rx},1}, P_{\text{rx},2}, \dots, P_{\text{rx},N}\}$,通信带宽集合为 $\mathbb{B} = \{B_1, B_2, \dots, B_N\}$. 该优化问题可描述为:

$$\max \Phi(\mathbb{P}_{\text{tx}}, \mathbb{P}_{\text{rx}}, \mathbb{B}, \mathbb{L}_c). \quad (9)$$

s. t.

$$\Gamma = 1 \quad (9a)$$

$$P_{\text{tx},\min} \leq P_{\text{tx},i} \leq P_{\text{tx},\max} \quad (\forall i = 1, 2, \dots, N), \quad (9b)$$

$$P_{\text{rx},\min} \leq P_{\text{rx},i} \leq P_{\text{rx},\max} \quad (\forall i = 1, 2, \dots, N), \quad (9c)$$

$$B_{\min} \leq B_i \leq B_{\max} \quad (\forall i = 1, 2, \dots, N), \quad (9d)$$

$$\mathbb{L}_c \subseteq \mathbb{L}. \quad (9e)$$

约束条件 (9a) 表示在构建拓扑过程中,无人机编队必须保持连通性;约束条件 (9b)、(9c) 和 (9d) 分别表示无人机编队中各无人机通信模块的功率和带宽在构建网络拓扑过程中需在可行范围内调整;约束条件 (9e) 表示无人机自组网生成与调节的链路必须在通信链路集合之内.

多目标联合优化效用函数 (8) 呈现出显著的复杂特性,其本质由指标属性、关联关系及约束条件共同决定:

函数的非线性特征核心源于指标的数学表达与变量属性.网络总吞吐量 C 包含对数项,通信总能耗 E 与链路吞吐量 C_l 呈反比例关系,二者均构成非线性映射;链路集合 \mathbb{L}_c 作为离散变量,其选择变化会导致指标值阶跃式波动,进一步强化非线性特性,使得函数无法通过线性规划等传统方法直接求解,需依赖启发式算法.

指标间存在强耦合权衡关系.网络连通度 K 与端到端平均时延 T_{avd} 呈负相关, K 提升易推高 T_{avd} ;网络总吞吐量 C 与通信总能耗 E 呈正相关, C 提升必然增加 E ,单一指标最优无法等同于全局最优,需通过科学权重协调实现多目标协同.

这些特性与约束条件深度绑定,网络连通性硬

约束 $\Gamma = 1$ 直接决定函数有效值, 非连通状态下 $\Phi = 0$; 功率、带宽的边界限制使可行域呈非连续闭集, 最终导致函数存在多个局部最优解, 形成非凸性优化空间, 对后续算法的全局搜索与局部寻优能力提出更高要求。

2 基于 ANP-CRITIC 的主客观综合指标权重计算

在多目标联合优化效用函数 (8) 中, 权重系数 w_1, w_2, w_3, w_4 直接决定各指标对整体性能的影响程度。传统主观赋权法难以刻画指标间的相互作用, 客观赋权法又易忽视专家经验。因此, 本文采用主观赋权网络分析法 (ANP) 与客观赋权 (CRITIC) 法相融合的方式, 实现“主观-客观”协同的权重标定。

2.1 基于 ANP 法的指标主观权重计算

ANP 作为一种能适应非独立递阶层次结构的决策方法, 可精准刻画无人机集群指标间的相互依赖与反馈关系, 通过构造判别矩阵明确各因素的关联机制, 最终计算出更贴合实际任务场景的主观权重, 为后续系统优化、资源分配及任务优先级排序提供可靠依据^[28]。基于 ANP 法的改进步骤设计如下:

第一步, 设无人机自组网网络评估有 n 个核心指标, 核心指标集合为 $\Gamma = \{Y_1, Y_2, \dots, Y_n\}$ 。根据 Thomas L. Satty 给出的重要性定理^[29] 对核心指标进行缩放, 用 scale 值表示指标之间的相对重要级别, 反之用其倒数表示, 则从 1-9 的 scale 值与指标相对重要级别的对应关系如表 1 所示。

表1 Satty 标度表

Scale值	指标比较意义
1	同等重要
3	稍微重要
5	相当重要
7	非常重要
9	极端重要
2、4、6、8	相邻判断折中

根据任务场景中指标的相互依赖关系 (如“总吞吐量对网络性能的影响比平均时延更重要”), 将 Y_i 相对 Y_j 的重要性标度值 a_{ij} 填入矩阵, 构建判别矩阵 A 如下:

$$A = \begin{bmatrix} 1 & a_{12} & \dots & a_{1n} \\ a_{21} = 1/a_{12} & 1 & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} = 1/a_{1n} & a_{n2} = 1/a_{2n} & \dots & 1 \end{bmatrix}. \quad (10)$$

第二步, 为避免主观判断的逻辑矛盾 (如“ Y_1 比 Y_2 重要, Y_2 比 Y_3 重要, 但 Y_3 比 Y_1 重要”), 需进行一致性检验。

性检验。

对判别矩阵进行数据归一化, 得到每个元素占对应列元素和比例, 归一化矩阵 B 及相应位置元素 b_{ij} 为:

$$\begin{cases} b_{ij} = \frac{a_{ij}}{\sum_{k=1}^n a_{kj}} (i \leq n, j \leq n) \\ B = \begin{pmatrix} b_{11} & \dots & b_{1n} \\ \vdots & \ddots & \vdots \\ b_{n1} & \dots & b_{nn} \end{pmatrix} \end{cases} \quad (11)$$

再对 B 的每行求和, 得到特征向量 $\xi = [\xi_1, \xi_2, \dots, \xi_n]^T$ 。可得到判别矩阵的最大特征值为

$$\lambda_{\max} = \frac{1}{n} \sum_{i=1}^n \frac{(A\xi)_i}{\xi_i}. \quad (12)$$

其中 $(A\xi)_i$ 为 $A\xi$ 的第 i 个元素。

则一致性比率 CR 计算为:

$$CR = \frac{\lambda_{\max} - n}{(n-1)RI}. \quad (13)$$

其中 ANP 法中的九阶平均随机一致性系数 RI 对应关系如表 2 所示。

表2 九阶平均随机一致性系数

n	1	2	3	4	5	6	7	8	9
RI	0	0	0.52	0.89	1.11	1.25	1.35	1.4	1.45

当 $CR \leq 0.1$ 时, 判别矩阵的一致性可接受; 否则需调整标度值 a_{ij} , 并重新校验一致性指标, 直至 $CR \leq 0.1$ 。

最后将所有特征向量矩阵构造为未加权超矩阵, 进行加权处理获得极限超矩阵。极限超矩阵的每一列元素均相同, 该列向量即为各网络核心指标的主观权重向量 $w_1 = [w_{11}, w_{12}, w_{13}, w_{14}]^T$ 。

2.2 基于 CRITIC 法的指标客观权重计算

CRITIC 法作为典型的客观赋权方法, 其权重确定的核心优势在于不依赖主观经验, 而是完全基于指标数据的客观特征综合计算: 既通过数据波动特征 (如标准差) 衡量指标的对比强度, 以刻画指标对评价对象差异的区分能力; 又通过指标间关联效应 (如相关系数) 评估指标冲突性, 以量化指标间的信息冗余程度; 同时将指标信息含量与数据离散特性纳入统一考量, 最终实现对各指标客观重要性的精准度量, 有效规避主观赋权的经验偏差与单一数据特征赋权的片面性。基于 CRITIC 法的指标计算步骤如下

第一步, 计算指标间的对比强度如下

$$Q_j = \frac{\sigma_j}{\mu_j} (j = 1, 2, \dots, n) \quad (14)$$

其中 Q_j 表示第 j 项指标的标准差系数; σ_j 表示第 j 项指标的标准差; μ_j 表示第 j 项指标在 m 个样本中的平均值。

第二步,求解相关系数和冲突性量化指标值,第 i 项指标与第 j 项指标间的相关系数 l_{ij} 计算如下:

$$\begin{cases} \text{Cov}(i, j) = \sum_{k=1}^m (\mu_{ki} - \bar{\mu}_i)(\mu_{kj} - \bar{\mu}_j) \\ \text{Var}[i] = \sum_{k=1}^m (\mu_{ki} - \bar{\mu}_i)^2, \text{Var}[j] = \sum_{k=1}^m (\mu_{kj} - \bar{\mu}_j)^2 \\ l_{ij} = \frac{\text{Cov}(i, j)}{\sqrt{\text{Var}[i]\text{Var}[j]}} \end{cases} \quad (15)$$

其中 μ_{ki} 、 μ_{kj} 分别表示第 k 个样本中,第 i 、 j 个核心指标的原始数据值; $\text{Cov}(i, j)$ 表示核心指标 i 与核心指标 j 的协方差; $\text{Var}[i]$ 、 $\text{Var}[j]$ 分别表示核心指标 i 与 j 的方差。

则第 j 个核心指标冲突性量化指标值 R_j 可计算为:

$$R_j = \sum_{i=1, i \neq j}^n (1 - l_{ij}) (j = 1, 2, \dots, n). \quad (16)$$

第三步,再计算指标信息量和归一化权重,各指标的客观权重是根据对比强度和冲突性来综合衡量的。第 j 个指标的信息量 I_j 可以表示为:

$$I_j = Q_j R_j (j = 1, 2, \dots, n). \quad (17)$$

其中 Q_j 表示第 j 个指标与其他指标间的标准差; I_j 越大表示第 j 个指标所包含的信息量越大,即指标的相对重要程度越高,权重也越大。

最后,第 j 个指标的客观权重 w_{2j} 为:

$$w_{2j} = \frac{I_j}{\sum_{k=1}^n I_k} (j = 1, 2, \dots, n). \quad (18)$$

客观权重不需要考虑无人机节点在特定环境下的主观影响,网络中的所有节点都使用统一标准去计算客观权重,得到各网络核心指标的客观权重向量为 $\mathbf{w}_2 = [w_{21}, w_{22}, w_{23}, w_{24}]^T$ 。

2.3 基于博弈论融合的综合权重

ANP法与CRITIC法在求解阶段均充分考虑指标间的关联特性与相互影响程度,能有效提升不同任务场景下网络综合性能评估的准确性。然而主客观赋权法各有短板:主观赋权依赖主观判断,易受经验偏差干扰;客观赋权则完全依赖数据本身的相关性,难以适配实际应用场景。为克服此问题,简单叠加二者会产生逻辑冲突,故本文引入博弈论思想修

正权重组合系数,并以达成纳什均衡作为协调主客观权重的优化方向^[30]。该方向可使主客观权重精准达到均衡点,将修正后组合权重与基础权重的偏差最小化,最终得到核心指标的最优综合权重。具体步骤如下:

首先,设网络核心指标的综合权重向量为 $\mathbf{W} = [W_1, W_2, W_3, W_4]^T$,则其线性组合可表示为:

$$\mathbf{W} = \delta_1 \mathbf{w}_1 + \delta_2 \mathbf{w}_2. \quad (19)$$

其中, δ_1, δ_2 为线性组合系数,满足 $\delta_1, \delta_2 > 0$ 且 $\delta_1 + \delta_2 = 1$; $\mathbf{w}_1, \mathbf{w}_2$ 分别为网络核心指标主观、客观权重向量。

引用博弈论聚合模型原理,以“综合权重 \mathbf{W} 与各基础权重 $\mathbf{w}_z (z = 1, 2)$ 的偏差最小”为目标,求解最佳线性组合系数 δ_1^*, δ_2^* 。目标函数 Ω 定义为:

$$\Omega = \min_{\delta_1, \delta_2} \left\| \sum_{z=1}^2 (\mathbf{W} - \mathbf{w}_z) \right\|_2. \quad (20)$$

之后,根据矩阵微分性质,目标函数 Ω 取最小值时,满足以下一阶最优条件方程:

$$\begin{bmatrix} \mathbf{w}_1^T \mathbf{w}_1 & \mathbf{w}_1^T \mathbf{w}_2 \\ \mathbf{w}_2^T \mathbf{w}_1 & \mathbf{w}_2^T \mathbf{w}_2 \end{bmatrix} \begin{bmatrix} \delta_1 \\ \delta_2 \end{bmatrix} = \begin{bmatrix} \mathbf{w}_1^T \mathbf{W} \\ \mathbf{w}_2^T \mathbf{W} \end{bmatrix}. \quad (21)$$

对式(21)求解得到优化后的最佳线性组合系数 δ_1^*, δ_2^* ,对其进行归一化处理:

$$\delta_{\text{nor},z}^* = \frac{|\delta_z^*|}{|\delta_1^*| + |\delta_2^*|} (z = 1, 2). \quad (22)$$

最终,最佳综合权重向量为:

$$\mathbf{W}^* = \delta_{\text{nor},1}^* \mathbf{w}_1 + \delta_{\text{nor},2}^* \mathbf{w}_2. \quad (23)$$

将综合权重系数代入式(8),得到基于ANP-CRITIC权重融合的无人机通信网络多目标联合优化拓扑控制效用函数:

$$\Phi = \Gamma(W_1^* K_{\text{nor}} + W_2^* C_{\text{nor}} + W_3^* T_{\text{nor}} + W_4^* E_{\text{nor}}). \quad (24)$$

3 无人机自组网拓扑优化控制方案

在第一节中,本文将无人机自组网拓扑优化控制问题抽象成了一个含约束条件的非线性最优化问题。由于该问题难以获取其绝对精确的解析解,且无人机自组网天然具有高速动态的特性^[12],因此优化算法必须具备高收敛性和全局寻优能力。现有常规混合启发式算法采用全局与局部算子的固定组合模式,无法根据迭代状态动态调整权重与切换时机,易出现全局探索不足或局部精炼冗余的问题,难以适配无人机自组网的动态拓扑需求。为突破这一局限,本文提出超启发式算法HGWO-ISAA,其核心设计并非简单叠加不同算子功能,而是构建全局探索与局部精炼的动态协同架构。算法以灰狼优化算法

(Grey Wolf Optimizer, GWO) 为全局搜索核心, 以改进模拟退火算法 (Improved Simulated Annealing Algorithm, ISAA) 为局部精炼支撑, 关键创新在于增设自适应策略调度模块. 该模块实时感知种群多样性、适应度改进率等迭代状态, 动态分配两类算子的执行权重, 精准平衡局部微调的精细度与广域寻优的覆盖度, 最终保障算法在高动态场景下的高收敛性与全局寻优能力.

3.1 算法设计原理

在优化问题 (9) 中, 优化参数分别为无人机集群的链路集合 L_c , 通信参数 P 、 B , 则无人机网络拓扑优化控制问题的优化参数的选取空间为数据集 $\mathbb{D} = \{P_{tx}, P_{rx}, B, L_c\}$ 在约束条件内的参数空间. 本文为了平衡算法优化过程中的“局部微调”与“广域寻优”, 同时适配迭代不同阶段的需求, 在优化过程中区分“局部”与“全局”来确定下一代周期的点, 最终提升优化效率与解的质量.

在第 t 次迭代过程中, 引入 SA 的局部扰动思想, 作为 HGWO-ISAA 的局部搜索算子, 局部参数空间选取值 $\vec{U}(t)$ 的具体选取依据如下:

$$\vec{U}(t) = \vec{X}(t) + \varepsilon \Delta(t). \quad (25)$$

其中 $\vec{X}(t)$ 表示第 t 次迭代过程中的当下参数空间坐标; ε 表示扰动幅度系数; $\Delta(t)$ 表示随机扰动因子并服从均匀分布.

全局参数空间选取采用 GWO 作为核心算子, 其结构简单、初始搜索空间大, 且收敛速度随搜索空间缩小而提升, 是算法高效全局寻优的关键.

在 GWO 执行过程中, 仅需要调整 \vec{A} 、 \vec{C} 两个参数, 其具体表达式如下:

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a}, \quad (26)$$

$$\vec{C} = 2\vec{r}_2. \quad (27)$$

其中 \vec{a} 表示收敛因子, 随着迭代次数 t 的增加从 2 线性衰减至 0; \vec{r}_1 、 \vec{r}_2 表示随机数, 取值范围为 $[0, 1]$.

$\vec{G}(t)$ 表示第 t 次迭代的全局参数空间选取点, 其更新流程为:

$$\begin{cases} l\vec{G}_1 = \vec{G}_\alpha - \vec{A}_1 \cdot |\vec{C} \cdot \vec{G}_\alpha - \vec{X}(t)| \\ \vec{G}_2 = \vec{G}_\beta - \vec{A}_2 \cdot |\vec{C} \cdot \vec{G}_\beta - \vec{X}(t)| \\ \vec{G}_3 = \vec{G}_\delta - \vec{A}_3 \cdot |\vec{C} \cdot \vec{G}_\delta - \vec{X}(t)| \end{cases}, \quad (28)$$

$$\vec{G}(t) = \frac{\vec{G}_1 + \vec{G}_2 + \vec{G}_3}{3}. \quad (29)$$

其中 \vec{G}_α 、 \vec{G}_β 、 \vec{G}_δ 分别表示当前迭代中按多目标联合效用函数值从高到低依次排名的 3 个全局参数空间选取点, 称 α 、 β 、 δ 为 3 个首领.

随后在每个迭代周期中, 将全局参数空间选取值的多目标联合效用函数值 $\Phi(\vec{G}(t))$ 与局部参数空间选取值的多目标联合效用函数值 $\Phi(\vec{U}(t))$ 进行比较, 本文提出的 HGWO-ISAA 算法为了避免陷入局部最优, 融入并改进了 SA 的核心思想. 这意味着对于次优解, 算法并非直接舍弃, 而是以一定概率接受. HGWO-ISAA 的概率更新公式如下:

$$P_{acc}(G(t)) = \begin{cases} 1 & \Delta\Phi_t > 0 \\ e^{-\frac{\Delta\Phi_t}{T_{temp}(t)}} & \Delta\Phi_t \leq 0 \end{cases} \quad (30)$$

其中 $P_{acc}(G(t))$ 表示在第 t 个周期中优化算法选择全局参数空间选取值 $\vec{G}(t)$ 的概率; $\Delta\Phi_t = \Phi(\vec{G}(t)) - \Phi(\vec{U}(t))$ 代表第 t 个周期中全局参数空间选取值与局部参数空间选取值的多目标联合效用函数值之差; $T_{temp}(t)$ 为第 t 个周期中 SA 的温度, 该变量值直接决定了当前周期算法接受次优解的可能性.

在 SA 中, 温度 T_{temp} 的初值和减小步长较难确定. 如果 T_{temp} 的初值选择较大, 减小步长太小, 虽然最终能得到较好的解, 但算法收敛速度太慢; 如果 T_{temp} 的初值选择较小, 减小步长过大, 很可能得不到全局最优解. 因此, 本文将第 t 个迭代周期中第 p 个等温周期内新解的接受率 $c_p(t)$ 纳入冷却公式中以提升算法迭代的适应性. 当新解接受率较高时, 表明在该温度下算法有利于生成更优解, 因此应适当降低冷却速率; 反之, 若算法已迭代至最优解区间内, 则需提高冷却速率以加速收敛.

HGWO-ISAA 算法的温度冷却公式如下:

$$T_{temp}(t+1) = \frac{T_{temp}(t)}{\gamma^{1-c_p(t)}}. \quad (31)$$

其中 γ ($\gamma > 1$) 是算法预设退温参数, γ 越大算法整体退温速度越快.

综合上述设计原理, 具体的无人机自组网拓扑优化控制 HGWO-ISAA 算法流程步骤如算法 1 所示:

算法 1 输入参数: 控制站通过态势感知获得无人机集群坐标, 任务环境参数等信息并根据基于博弈论的 ANP-CRITIC 法对指标赋权.

算法参数 按实际需求, 设置 HGWO-ISAA 算法参数.

循环开始: 步骤 1 设置迭代次数 $t = 1$ 并开始外部循环.

步骤 2 随机生成 ζ 个搜索代理的选取值; 判断生成的搜索代理的通信拓扑图是否连通, 否则重新生成; 判断电台参数是否在限制条件内, 否则调整至限制范围内.

步骤3 设置迭代次数 $\eta = 1$ 并开始内部等温区间循环迭代.

步骤4 搜索全局参数选取位置: 分别计算所有搜索因子的综合性能值, 选取效用函数最大的3个搜索因子标记为3个首领 α 、 β 、 δ , 根据式(28)和式(29)计算全局参数选取值.

步骤5 生成局部参数选取值位置并计算其综合性能值.

步骤6 比较全局与局部参数选取值的综合性能值, 根据式(30)的概率选择一个作为该周期最终选取的参数值.

步骤7 记录当前等温周期内最高的综合性能值及其参数解 $X^*(t)$; 记录等温周期接受新解的比例.

步骤8 根据式(26)和式(27)调整 \vec{A} 、 \vec{C} 这2个参数; 依据式(28)更新搜索代理的位置.

步骤9 调整等温周期迭代次数, 令 $\eta = \eta + 1$, 并判断等温周期迭代次数 η 是否达到最大; 若是, 调整参数选取值 $X(t+1) = X^*(t)$ 并按照式(31)进行退温; 否则返回步骤4.

步骤10 判断算法温度 T_{temp} 是否小于预设最低温度限制; 若是, 返回步骤3; 否则调整外层迭代次数, 令 $t = t + 1$.

步骤11 判断迭代次数 t 是否达到最大迭代次数, 若是, 则记录最优综合性能值以及最优参数解; 否则返回步骤2.

步骤12 算法计算结束, 控制站发布无人机集群最优参数集合指令数据包至无人机节点.

3.2 算法收敛性分析

算法收敛性是评估拓扑优化效果的核心指标, HGWO-ISAA 的收敛性源于 GWO 全局探索、ISAA 局部精炼与自适应调度的协同作用, 并非单一依赖 GWO 算子, 其收敛特性可通过有限齐次马尔可夫链遍历性定理推导证明.

定义 HGWO-ISAA 的迭代状态为种群中所有个体的多目标效用值集合, 由于种群规模 ζ 、解空间维度 D 均为有限值, 算法的状态空间为有限集; 同时, 种群的状态转移仅依赖于当前迭代的算子权重与适应度值, 与迭代次数无关, 因此 HGWO-ISAA 的迭代过程可视为有限齐次马尔可夫链.

该马尔可夫链的核心状态转移特性由 GWO 算子、ISAA 算子与自适应调度机制协同保障: GWO 算子的层级引导机制保障了状态遍历性, 迭代初期收敛因子 \bar{a} 较大使得参数 \vec{A} 绝对值大于 1, 种群可实

现全解空间大范围遍历以覆盖优质解区域, 迭代后期 \bar{a} 衰减则驱动种群向最优解区域收敛; ISAA 算子的概率接受机制能够打破迭代后期的状态停滞, 即使种群陷入局部最优, 仍可通过概率接受次优解避免状态锁定, 满足无周期性转移的遍历性条件; 而自适应调度的动态权重调整则进一步优化了状态转移效率, 通过平衡 GWO 全局探索与 ISAA 局部精炼的执行权重, 让算法在迭代前期快速扩大状态覆盖范围, 后期加速向最优解状态收敛.

根据马尔可夫链遍历性定理, 若算法的状态转移矩阵满足遍历性条件 (任意状态均可从其他状态到达, 且不存在周期性转移), 则算法将以概率 1 收敛至全局最优解区域.

3.3 算法时间复杂度分析

算法时间复杂度是评估算法工程实用性的核心指标, 直接决定算法在无人机自组网高动态场景中的响应速度与适配能力, 其核心影响因子包含算法种群规模 ζ 、最大迭代次数 T_{max} 及解空间维度 D , 其中解空间维度 D 与无人机节点数 N 强相关, 对应拓扑优化的链路选择、发射功率、接收功率、工作带宽四类核心变量, 满足:

$$D = \frac{N(N-1)}{2} + 3N. \quad (32)$$

其中 $\frac{N(N-1)}{2}$ 项为链路选择变量维度, $3N$ 为单节点三类通信参数维度;

针对本文提出的 HGWO-ISAA 算法, 其执行流程可拆解为种群初始化、GWO 全局搜索算子、ISAA 局部精炼算子及自适应策略调度四大模块, 各模块时间复杂度依次为 $O(\zeta \cdot D)$ 、 $O(T_{\text{max}} \cdot \zeta^2 \cdot D)$ 、 $O(T_{\text{max}} \cdot \zeta^2 \cdot D)$ 、 $O(T_{\text{max}} \cdot k \cdot D)$ ($k \ll \zeta$, 为 GWO 输出的优质解数量) 以及 $O(T_{\text{max}} \cdot \zeta)$, 由于后两项复杂度远低于 GWO 全局搜索算子的复杂度, 因此 HGWO-ISAA 的总时间复杂度可简化为:

$$O_{\text{HGWO-ISAA}} = O(T_{\text{max}} \cdot \zeta^2 \cdot D). \quad (33)$$

现有先进启发式算法中, GWO 与星鸦算法 (Nutcracker Optimization Algorithm, NOA) 算法以高效性能被广泛应用于各类优化问题. 为了对本文提出的 HGWO-ISAA 算法的计算效率进行客观评估, 有必要将其与这两个代表性算法的时间复杂度进行对比分析. GWO 算法无局部精炼与自适应调度环节, 核心操作仅为种群初始化与全局迭代搜索, 其总时间复杂度为:

$$O_{\text{GWO}} = O(T_{\text{max}} \cdot \zeta^2 \cdot D). \quad (34)$$

NOA 算法的迭代逻辑与 GWO 类似, 均基于种

群协作完成全局解空间遍历, 因此其时间复杂度与GWO处于同一数量级, 即:

$$O_{\text{NOA}} = O(T_{\text{max}} \cdot \zeta^2 \cdot D). \quad (35)$$

从理论推导结果可见, HGWO-ISAA与GWO、NOA的时间复杂度处于同一量级, 说明HGWO-ISAA在引入局部精炼与自适应调度机制后, 未增加算法的理论复杂度量级, 保障了工程可实现性, 但三者的实际运行效率存在显著差异, GWO与NOA全程执行全局搜索, 迭代后期种群已收敛至优质解区域后仍进行无差别遍历, 产生大量冗余计算, 而HGWO-ISAA通过自适应策略调度实现“全局探索”与“局部精炼”的动态切换, 迭代初期侧重GWO全局搜索以快速覆盖解空间, 迭代后期侧重ISAA局部精炼以精细优化优质解, 有效规避冗余计算。

3.4 算法扩展性分析

算法可扩展性表征其性能(运行时间、收敛速度、解的精确性)随无人机节点规模 N 增长的衰减程度, 是评估算法适配大规模无人机自组网场景的核心指标。

针对本文提出的HGWO-ISAA算法, 其可以根据节点规模 N 以及迭代效能自适应的调整GWO全局搜索与ISAA局部寻优两项算子的执行权重。在算法初始阶段, 虚拟温度 T_{temp} 保持在较高的尺度, 算法以高概率选取GWO算子全局搜索并快速缩小优质解区域, 当种群收敛至核心区域后, T_{temp} 逐渐降低, 算法以高概率选取ISAA算子进行局部精炼, 以精细优化优质解。

而GWO与NOA无动态调整机制, 当 N 增大导致解空间维度 D 急剧上升时, 算法需对全种群进行无差别全局遍历, 冗余计算量随 D 同步二次增长, 收敛速度与解的精确性快速下降。

综合上述分析, 随着无人机节点规模 N 增长, HGWO-ISAA的自适应调度机制可有效缓解高维解空间带来的性能衰减, 算法可扩展性表现优异。

4 仿真结果与分析

为验证所提方案的场景适应性及算法优越性, 选取两类典型场景开展仿真, 验证算法有效性。实验以控制变量法固定无人机初始坐标保障对比公平, 叠加场景专属约束与权重贴合特性, 通过与GWO、NOA算法对比, 验证HGWO-ISAA的快速收敛与全局寻优能力。

两类场景的无人机初始空间坐标保持一致, 具体如表3所示。

无人机节点位置如此设置的核心目的是排除初

表3 无人机空间位置坐标

无人机编号	空间坐标xyz
1	[100.2, 80.5, 95.3]
2	[200.7, 150.1, 142.6]
3	[250.5, 70.8, 120.4]
4	[150.3, 220.9, 98.7]
5	[50.8, 150.2, 108.1]

始位置差异对性能指标的干扰, 使两种场景的性能差异更纯粹地源于场景本身的环境特性与任务需求, 确保对比结果的客观性与严谨性。需要说明的是, 初始坐标并非完全随机生成, 而是结合两类场景的共性飞行约束进行约束性生成: 限定无人机飞行高度范围 $z \in [80, 150]$ m, 保证低空作业的实际特性; 同时控制节点初始分布的均匀性, 避免因局部节点过密或过疏引入额外变量。

无人机参数设置为: 通信半径 $r = 200$ m, 发射功率 $P_{\text{tx}} \in [0.2, 2]$ W, 接收功率 $P_{\text{rx}} \in [0.1, 0.3]$ W, 工作带宽 $B_{\text{rx}} \in [1, 10]$ MHz, 网络活跃时间尺度 $T_{\text{act}} = 60$ s, 节点电路基础功耗 $P_c = 1$ W。环境参数为: 噪声功率谱密度 $n_0 = 3.98 \times 10^{-21}$, 单位距离信道增益 $\rho_0 = 0.5$ 。HGWO-ISAA算法参数设置为: 种群规模 $\zeta = 15$, 最大迭代次数 $t_{\text{max}} = 1000$, 最大等温迭代次数 $\eta_{\text{max}} = 20$, 初始温度 $T_0 = 80$, 最低温度限制 $T_{\text{min}} = 1$, 预设退温参数 $\gamma = 2$ 。

4.1 场景一: 密集城区无人机巡检场景

本场景模拟城市高楼环境下的电力巡检任务, 无人机需在建筑遮挡干扰下维持实时数据回传, 核心需求为“高连通度+低时延”, 先通过ANP构建指标网络: 连通度 K 与节点端到端平均时延 T_{avd} 强负相关构成基础保障层, 网络总吞吐量 C 依赖连通度 K 、能耗 E , 与 C 正相关构成性能优化层, 得主观权重 $\mathbf{w}_1 = [0.35, 0.30, 0.20, 0.15]^T$; 再用CRITIC分析数据, K 和 T_{avd} 波动大、相关性强, 得客观权重 $\mathbf{w}_2 = [0.32, 0.28, 0.22, 0.18]^T$; 最后以纳什均衡融合得最终权重 $\mathbf{W} = [0.338, 0.292, 0.208, 0.162]^T$, 精准匹配场景对 K 和 T_{avd} 的优先需求。仿真实验结果如下:

图1展示了在场景一下本文所提出的拓扑优化控制方案生成的无人机自组网拓扑结构。

可以看出在场景一中, 算法生成无人机自组网拓扑结构连通度为3, 因此拥有较强的健壮性, 符合场景需求。

图2展示了场景一中50次迭代内, 无人机自组网连通度 K 、网络总吞吐量 C 、网络通信总能耗 E 及




图1 场景一下的无人机集群通信拓扑图

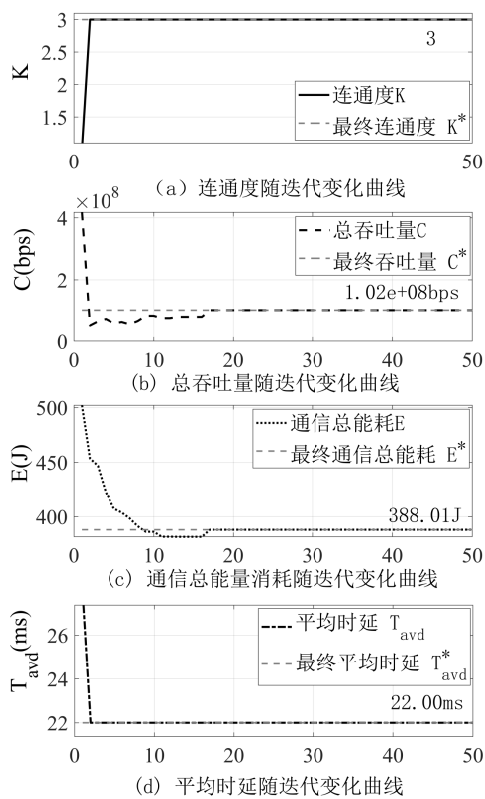


图2 场景一四项核心指标随迭代变化曲线

节点端到端平均时延 T_{ave} 随 HGWO-ISAA 算法的迭代曲线。

该场景以 K 与 T_{ave} 为优化重点,因此网络最终确定连通度 K 高达3,仅次于该网络全连通($K=4$)的情况。由于网络固有特性, K 与 T_{ave} 呈强负相关,因此 T_{ave} 随 K 的快速收敛很快趋于平稳且达到较低的时延22ms。而因为3连通度时网络连通链路仍有很大变化空间, C 与 E 均需一段时间后趋于平稳,最终分别稳定在 1.02×10^8 bps、388.01 J。

4.2 场景二: 开阔区域应急通信场景

本场景模拟地震后开阔灾区的临时通信中继任务,无人机需在远距离低干扰环境下传输救援数据,

核心需求为“高吞吐量+低通信能耗”。ANP分析中,网络总吞吐量 C 与网络通信总能耗 E 强正相关构成核心性能层,连通度 K 和节点端到端平均时延 T_{ave} 需求降低构成基础层,得主观权重 $\mathbf{w}_1 = [0.15, 0.10, 0.40, 0.35]^T$;再通过CRITIC法分析数据,因 C 和 E 对比度高、相关性强,得客观权重 $\mathbf{w}_2 = [0.18, 0.12, 0.36, 0.34]^T$;最后以纳什均衡融合得最终权重 $\mathbf{W} = [0.164, 0.109, 0.382, 0.345]^T$ 。仿真实验结果如下:

图3展示了本文所提出的拓扑优化控制方案生成的场景二的无人机自组网拓扑结构。




图3 场景二下的无人机集群通信拓扑图

可以看出在场景二中,算法生成无人机自组网拓扑结构连通度为1,在保证连通性要求的情况下,尽可能缩减通信拓扑链路以降低通信能耗,符合场景需求。

图4展示了场景二中50次迭代内,无人机自组网连通度 K 、网络总吞吐量 C 、网络通信总能耗 E 及节点端到端平均时延 T_{ave} 随HGWO-ISAA算法的迭代曲线。

由于场景二中网络连通度 K 的低权重性,网络保持最小连通状态($K=1$)后,便不再发生连通度的波动, C 与 E 随着通信连通链路的确定在极短时间内快速收敛至稳定。尽管本场景中 C 与 E 的权重较场景一均有提升,但 E 仅相对场景一增长9%,而 C 实现了75%的大幅跃升;这源于网络模型少量能耗投入即可换取吞吐量的显著增益的固有属性,因此优化算法自然倾向于这种“低能耗代价-高吞吐量回报”的权衡,以最大化系统综合性能。

4.3 算法优化效果对比分析

为验证所提HGWO-ISAA算法在无人机自组网拓扑优化中的性能优势,本节选取经典GWO算法、NOA算法作为对比基准,从收敛速度和不同集群规

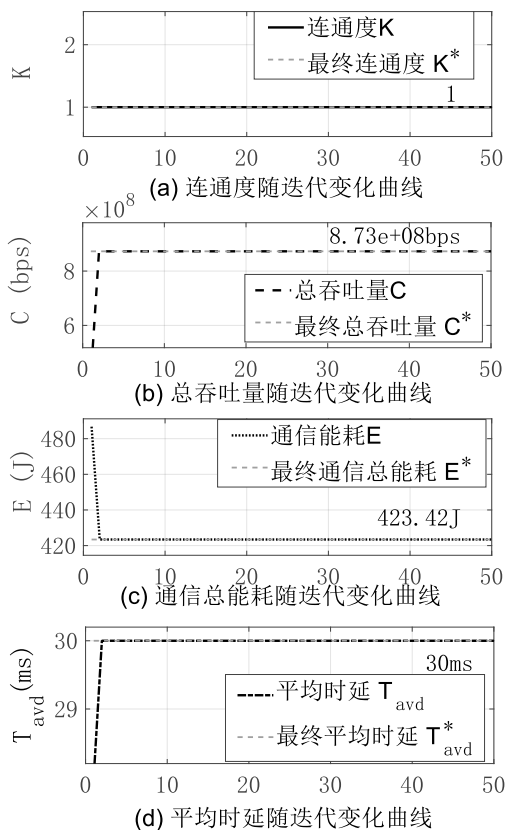


图4 场景二四项核心指标随迭代变化曲线

模下的最终优化效果两个核心维度, 展开量化对比分析.

以场景一中的无人机自组网拓扑优化控制问题为例, 图5展示了150次迭代内HGWO-ISAA、GWO、NOA三种算法经15次运行后的平均综合性能值变化曲线.

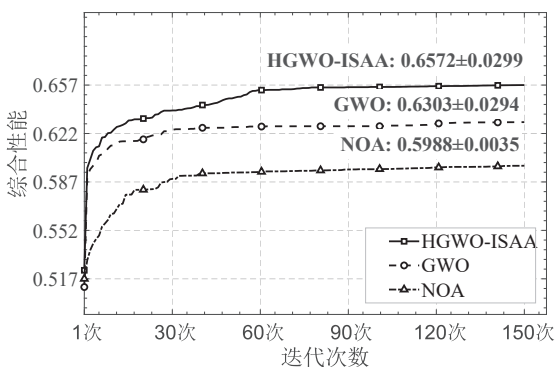


图5 不同算法收敛速度对比图

HGWO-ISAA从迭代初期便保持高于GWO、NOA的综合性能, 且快速收敛并持续维持在更优性能区间, 收敛速度相对较快; 即便GWO(40次迭代)、NOA(60次左右)更早进入平稳阶段, 但二者平稳后的综合性能显著低于HGWO-ISAA, 其最终平均综合性能值较GWO、NOA分别提升4.26%、9.75%. 最终综合性能值标准差方面, HGWO-ISAA继承GWO的种群多样性维持机制, 与GWO基本相当, 虽稍逊

于NOA, 但全局寻优能力优势显著. 综合而言, HGWO-ISAA的收敛速度表现优异, 且兼具更优的最终综合性能值, 更适用于无人机自组网拓扑优化这一多目标控制场景.

图6呈现了场景一中无人机集群规模从5架增至20架时, HGWO-ISAA、GWO及NOA三种算法经15次运行后的平均最终综合性能对比.




图6 不同算法收敛结果对比图

从整体优化效果来看, HGWO-ISAA算法在所有集群规模下均保持最优综合性能, 且随无人机数量增加, 优化问题的复杂程度也随之提升, 其相对GWO、NOA的性能提升幅度逐步扩大. 综合5、10、15、20架集群规模计算, HGWO-ISAA较GWO的平均最终综合性能值提升约8.17%, 较NOA的平均最终综合性能值提升约20.42%, 充分验证了算法的全局寻优能力.

5 结论

为解决无人机自组网复杂任务场景下拓扑控制的优化目标单一、多目标优先级模糊及传统算法寻优不足速度不快问题, 本文提出了整合多目标联合优化模型、ANP-CRITIC博弈权重法与HGWO-ISAA超启发式算法的拓扑优化控制方案. 该方案通过多目标模型提供全局性能评估标准, 通过博弈权重法实现场景化赋权, 通过超启发式算法平衡寻优效率与精度. 整体方案具有较强的场景适配性与鲁棒性. 经理论分析、多场景仿真及算法对比验证, 方案在场景适配性、核心指标优化精度、算法寻优效率上均展现出显著优势, HGWO-ISAA算法较GWO、NOA平均综合性能分别提升8.17%、20.42%, 为复杂场景下无人机自组网拓扑优化控制问题提供了可靠技术路径.

参考文献 (References)

[1] Li B, Fei Z S, Zhang Y. UAV communications for 5G and beyond: Recent advances and future trends[J]. *IEEE Internet of Things Journal*, 2019, 6(2): 2241-2263.

[2] 宋怡成, 齐瑞云, 姜斌. 通信故障下无人机编队网络分

- 布式拓扑重构[J]. *航空学报*, 2025, 46(246(22)): 227-238.
(Song Y C, Qi R Y, Jiang B. Distributed topology reconstruction of UAV formation network under communication fault[J]. *Acta Aeronautica et Astronautica Sinica*, 2025, 46(246(22)): 227-238.)
- [3] 于彦鹏, 余墨多, 汤奇荣, 等. 面向城市应急物资配送的多无人机协同路径规划算法[J]. *控制与决策*, 2025, 40(4): 1098-1106.
(Yu Y P, Yu M D, Tang Q R, et al. Multi-UAV cooperative path planning algorithm for urban emergency material distribution[J]. *Control and Decision*, 2025, 40(4): 1098-1106.)
- [4] Zhang K, Miao Q Y, Jiang B. Learning-based fault-tolerant optimal formation control of helicopters: An incremental fully actuated system approach[J]. *IEEE Transactions on Cybernetics*, 2026, 56(1): 81-93.
- [5] Miao Q Y, Zhang K, Jiang B. Fixed-time collision-free fault-tolerant formation control of multi-UAVs under actuator faults[J]. *IEEE Transactions on Cybernetics*, 2024, 54(6): 3679-3691.
- [6] 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[J]. *自动化学报*, 2025, 51(5): 942-959.
(Jiang B, Ma Y J, Xue S X. Autonomous control of unmanned aerial vehicle swarms: Task allocation based on coalition formation game[J]. *Acta Automatica Sinica*, 2025, 51(5): 942-959.)
- [7] 王祥科, 刘志宏, 丛一睿, 等. 小型固定翼无人机集群综述和未来发展[J]. *航空学报*, 2020, 41(4): 23732-023732.
(Wang X K, Liu Z H, Cun Y R, et al. Miniature fixed-wing UAV swarms: Review and outlook[J]. *Acta Aeronautica et Astronautica Sinica*, 2020, 41(4): 23732-023732.)
- [8] 齐小刚, 吴相远, 刘立芳. 无人机集群编队自组网可靠性评估[J]. *控制与决策*, 2024, 39(2): 689-696.
(Qi X G, Wu X Y, Liu L F. Reliability evaluation of ad hoc network for UAV swarm formation[J]. *Control and Decision*, 2024, 39(2): 689-696.)
- [9] 刘亚群, 谢钧, 邢长友, 等. 飞行自组网拓扑控制研究综述[J]. *通信学报*, 2023, 44(8): 195-214.
(Liu Y Q, Xie J, Xing C Y, et al. Comprehensive survey on topology control for flying ad-hoc network[J]. *Journal of Communications*, 2023, 44(8): 195-214.)
- [10] Gupta L, Jain R, Vaszkun G. Survey of important issues in UAV communication networks[J]. *IEEE Communications Surveys & Tutorials*, 2016, 18(2): 1123-1152.
- [11] 李实吉, 胡谷雨, 丁有伟. 微型无人机集群低时延组网规划方法[J]. *控制与决策*, 2020, 35(11): 2696-2706.
(Li S J, Hu G Y, Ding Y W. A low delay networking planning method for micro UAV swarm[J]. *Control and Decision*, 2020, 35(11): 2696-2706.)
- [12] Wang C X, You X H, Gao X Q, et al. On the road to 6G: Visions, requirements, key technologies, and testbeds[J]. *IEEE Communications Surveys & Tutorials*, 2023, 25(2): 905-974.
- [13] Lakew D S, Umar S, Dao N N, et al. Routing in flying ad hoc networks: A comprehensive survey[J]. *IEEE Communications Surveys & Tutorials*, 2020, 22(2): 1071-1120.
- [14] Bekmezci İ, Sahingoz O K, Temel Ş. Flying ad-hoc networks (FANETs): A survey[J]. *Ad Hoc Networks*, 2013, 11(3): 1254-1270.
- [15] 田畅, 贾倩, 陈润丰, 等. 无人机集群网络资源优化综述[J]. *数据采集与处理*, 2023, 38(3): 506-524.
(Tian C, Jia Q, Chen R F, et al. Review on optimization of resources in UAV swarm networks[J]. *Journal of Data Acquisition and Processing*, 2023, 38(3): 506-524.)
- [16] 王博文, 孙彦景. 基于联盟图博弈的地下空间无人机应急通信网络拓扑控制算法[J]. *电子与信息学报*, 2022, 44(3): 996-1005.
(Wang B W, Sun Y J. Coalitional graph game based topology control algorithm for unmanned aerial vehicle emergency networks in underground space[J]. *Journal of Electronics & Information Technology*, 2022, 44(3): 996-1005.)
- [17] Wang P Y, Li Q K, Yi J K. Topology control of low-connection UAV laser network with virtual nodes[J]. *Applied Sciences*, 2025, 15(3): 1086.
- [18] Guo J J, He J, Chen D W, et al. UAV topology control method based on fuzzy C-clustering algorithm[C]. *6GN for Future Wireless Networks*. Chongqing, 2025: 113-124.
- [19] 谷晓燕, 陈亮, 邓香平. 无人机编队信息交互拓扑多目标优化[J]. *电光与控制*, 2022, 29(9): 27-31.
(Gu X Y, Chen L, Deng X P. Multi-objective optimization of UAV formation information interaction topology[J]. *Electronics Optics & Control*, 2022, 29(9): 27-31.)
- [20] 苏扬, 魏连锁, 郭媛. 多目标融合势博弈无线自组网络拓扑控制算法[J]. *北京邮电大学学报*, 2022, 45(4): 91-97.
(Su Y, Wei L X, Guo Y. Multi-objective fusion potential game wireless Ad Hoc network topology control algorithm[J]. *Journal of Beijing University of Posts and Telecommunications*, 2022, 45(4): 91-97.)
- [21] 张然, 高莹雪, 丁元明. 无人机集群网络分簇优化算法[J]. *计算机工程与设计*, 2022, 43(7): 1848-1855.
(Zhang R, Gao Y X, Ding Y M. Clustering optimization algorithm for UAV cluster network[J]. *Computer Engineering and Design*, 2022, 43(7): 1848-1855.)
- [22] Cevallos M J F, Rizzardi A, Sicari S, et al. Deep Reinforcement Learning for intrusion detection in Internet of Things: Best practices, lessons learnt, and open challenges[J]. *Computer Networks*, 2023, 236: 110016.
- [23] Bai Y J, Yu D J, Zhang X, et al. Link prediction of UAV networks based on dynamic graph neural network[J]. *IET Communications*, 2025, 19: e70092.
- [24] 周文惠, 齐瑞云, 姜斌. 面向突发故障的分布式多无人机任务重规划方法[J]. *控制与决策*, 2023, 38(5): 1373-

1385.
(Zhou W H, Qi R Y, Jiang B. Mission replanning method of distributed multiple unmanned aerial vehicles for pop-up faults[J]. *Control and Decision*, 2023, 38(5): 1373-1385.)
- [25] Xu W Z, Sun Y Y, Zou R, et al. Throughput maximization of UAV networks[J]. *ACM Transactions on Networking*, 2022, 30(2): 881-895.
- [26] 杨光, 姚路, 任培. 基于排队论的 TDMA 数据链报文传输时延分析[J]. *计算机科学*, 2014, 41(3): 120-123.
(Yang G, Yao L, Ren P. Time delay analysis of TDMA data link message transmission based on queue theory[J]. *Computer Science*, 2014, 41(3): 120-123.)
- [27] 段昌盛. 基于 S-DCF 算法的无人机群 Ad Hoc 网络节点布局能耗优化[J]. *测控技术*, 2025, 44(8): 56-61.
(Duan C S. Energy consumption optimization of UAV ad hoc network node layout based on S-DCF algorithm[J]. *Measurement & Control Technology*, 2025, 44(8): 56-61.)
- [28] 吴诗辉, 刘晓东, 贺波, 等. 一种调整 AHP 不一致判断矩阵的优化方法[J]. *控制与决策*, 2016, 31(11): 2106-2112.
(Wu S H, Liu X D, He B, et al. New optimization method to improve the inconsistent comparison matrix in analytic hierarchy process[J]. *Control and Decision*, 2016, 31(11): 2106-2112.)
- [29] Satty T L. Decision making with dependence and feedback: The organization and prioritization of complexity[M]. Pittsburgh: RWS Publications, 2001.
- [30] Wu Y N, Deng Z Q, Tao Y, et al. Site selection decision framework for photovoltaic hydrogen production project using BWM-CRITIC-MABAC: A case study in Zhangjiakou[J]. *Journal of Cleaner Production*, 2021, 324: 129233.

作者简介

徐智豪 (2000–), 男, 硕士生, 主要研究方向为无人机集群拓扑控制与检测, E-mail: logic20000819@nuaa.edu.cn;

张柯 (1981–), 男, 教授, 博士, 博士生导师, 主要研究方向为故障诊断、容错控制, E-mail: kezhang@nuaa.edu.cn;

邢卓琳 (2000–), 女, 博士生, 主要研究方向为无人机集群网络重构与任务规划、无人机飞行控制, E-mail: zl_xing@nuaa.edu.cn;

姜斌 (1966–), 男, 教授, 博士, 博士生导师, 主要研究方向为故障诊断、容错控制, E-mail: binjiang@nuaa.edu.cn;

叶准元 (2002–), 男, 硕士生, 主要研究方向为无人机集群网络重构与检测, E-mail: zhunyuanye@nuaa.edu.cn.