

文章编号:1671-1637(2026)04-0033-17

# 端到端的无人机群仿蛛网覆盖搜索双层规划优化方法

丁鹏翀<sup>1</sup>, 上官伟<sup>\*1,2,3</sup>, 陈俊杰<sup>1,2</sup>, 柴琳果<sup>1,2</sup>, 彭佳力<sup>1,4</sup>

(1. 北京交通大学 自动化与智能学院, 北京 100044; 2. 北京交通大学 自主智能与无人系统研究中心, 北京 100044; 3. 北京交通大学 先进轨道交通自主运行全国重点实验室, 北京 100044; 4. 安徽大学 互联网学院, 安徽 合肥 230039)

**摘要:**为解决无人机群协同覆盖搜索中资源配置与搜索执行的均衡优化难题,减少资源消耗的同时提升区域覆盖均衡性、灵活性及响应速度,提出了一种端到端的无人机群仿蛛网覆盖搜索双层规划优化方法。第1层实现多目标区域无人机资源配置优化,构建了多目标均衡的无人机资源配置优化模型,建立基于深度学习的端到端网络,将搜索区域特征与无人机参数编码为输入矩阵,直接输出多区域无人机群最优协同数量方案,确保在可靠性约束下满足覆盖任务需求;第2层实现仿蛛网覆盖路径优化,基于第1层数量配置结果的最大资源配额,借鉴蛛网放射丝与捕丝结构,将任意凸四边形区域划分为自适应子区域,通过放射路径与平行路径结合实现覆盖优化,支持无人机群并行搜索。研究表明:提出的深度学习资源配置网络的目标优化能力与遗传算法相当,强于同结构线性损失组合的深度学习网络以及混合损失单步强化学习,策略均衡性较遗传算法提高84.62%,且方案求解时间较遗传算法大幅缩短;仿蛛网覆盖路径规划优化方法在基站与子区域关联程度、搜索路径的灵活性上均优于对比方法,子区域路径均衡性提高75.45%以上,且无人机群规模越大,优化效果越显著。建立的无人机群协同覆盖搜索框架兼顾资源与路径优化,可在城市巡检、应急救援等场景中提升资源利用率与任务可靠性。

**关键词:**低空交通;无人机群;覆盖搜索;路径优化;资源配置;深度学习;仿生结构;端到端

**中图分类号:**U8 **文献标志码:**A **DOI:**10.19818/j.cnki.1671-1637.2026.162

## End-to-end two-layer planning and optimization method for UAV swarm spider web-inspired coverage search

DING Peng-chong<sup>1</sup>, SHANGGUAN Wei<sup>\*1,2,3</sup>, CHEN Jun-jie<sup>1,2</sup>, CHAI Lin-guo<sup>1,2</sup>, PENG Jia-li<sup>1,4</sup>

(1. School of Automation and Intelligence, Beijing Jiaotong University, Beijing 100044, China; 2. Research Center for Autonomous Intelligence and Unmanned Systems, Beijing Jiaotong University, Beijing 100044, China; 3. State Key Laboratory of Advanced Rail Autonomous Operation, Beijing Jiaotong University, Beijing 100044, China; 4. School of Internet, Anhui University, Hefei 230039, Anhui, China)

**Abstract:** To address the challenges of balanced optimization between resource allocation and search execution in unmanned aerial vehicle (UAV) swarm collaborative coverage search, and to improve

出版历程:2025-08-31 收稿,2026-01-10 修回,2026-01-23 录用

基金项目:北京市卓越青年科学家计划(JWZQ20240101010);教育部装备预研联合基金(8091B022238);京津冀基础研究合作专项项目(F2024210051);北京交通大学人才基金项目(2024XKRC054);石家庄铁道大学省部共建交通工程结构力学行为与系统安全国家重点实验室开放课题(KF2025-01)

作者简介:丁鹏翀(1999-),男,内蒙古乌兰察布人,工学博士研究生,E-mail:pcding@bjtu.edu.cn。

\*通信作者:上官伟(1979-),男,陕西咸阳人,教授,博士生导师,工学博士,E-mail:wshg@bjtu.edu.cn。

引用格式:丁鹏翀,上官伟,陈俊杰,等.端到端的无人机群仿蛛网覆盖搜索双层规划优化方法[J].交通运输工程学报,2026,26(4):33-49.

Citation: DING Peng-chong, SHANGGUAN Wei, CHEN Jun-jie, et al. End-to-end two-layer planning and optimization method for UAV swarm spider web-inspired coverage search[J]. Journal of Traffic and Transportation Engineering, 2026, 26(4): 33-49.

the balance, flexibility, and response speed of regional coverage while reducing resource consumption, an end-to-end two-layer planning and optimization method for UAV swarm spider web-inspired coverage search was proposed. The first layer focused on UAV resource allocation optimization for multi-target regions. A multi-target balanced UAV resource allocation optimization model was constructed, and a deep learning-based end-to-end network was built. The search region features and UAV parameter encoding served as the input matrix, and the optimal collaborative quantity scheme of UAV swarms for multiple regions was directly output, to ensure the coverage task requirements under reliability constraints. The second layer achieved spider web-inspired coverage path optimization. Based on the maximum resource quota from the first layer's quantity allocation result, using the structure of radial threads and capture threads in spider webs, an arbitrary convex quadrilateral region was divided into adaptive sub-regions. Through the combination of radial and parallel paths, coverage optimization was realized and parallel search of UAV swarms was supported. The results demonstrate that the objective optimization performance of the proposed deep learning-based resource allocation network is comparable to the genetic algorithm (GA), and outperforms the deep learning network with linear loss combination of the same structure and the hybrid-loss single-step reinforcement learning method. Its strategic equilibrium is improved by 84.62% compared with GA, and the solution time is greatly reduced. The planning and optimization method for UAV swarm spider web-inspired coverage search is superior to its counterpart methods in terms of the association degree between base stations and sub-regions and the flexibility of search paths. The path equilibrium of sub-regions is increased by more than 75.45%, and the larger the UAV swarm scale, the more significant the optimization effect. The UAV swarm collaborative coverage search framework considers both resource and path optimization. It can improve resource utilization rate and task reliability in urban inspection, emergency rescue, and other scenarios.

**Keywords:** low-altitude traffic; UAV swarm; coverage search; path optimization; resource allocation; deep learning; bionic structure; end-to-end

**Publication history:** Received 2025-08-31; Received in revised form 2026-01-10; Accepted 2026-01-23

**Funding:** Beijing Outstanding Young Scientist Program (JWZQ20240101010); Equipment Preresearch Joint Foundation of Ministry of Education (8091B022238); Beijing-Tianjin-Hebei Basic Research Cooperation Program (F2024210051); Talent Fund of Beijing Jiaotong University (2024XKRC054); Open Project of State Key Laboratory of Mechanical Behavior and System Safety of Traffic Engineering Structures of Shijiazhuang Tiedao University (Co-sponsored by Hebei Province and the Ministry of Education)(KF2025-01)

\* **Corresponding author:** SHANGGUAN Wei, professor, PhD, E-mail: wshg@bjtu.edu.cn.

## 0 引 言

随着大数据、人工智能与城市基建深度融合,综合交通的研究如火如荼<sup>[1-2]</sup>。同时由于低空经济和陆空立体交通兴起,智慧城市与应急治理也迎来新增长点。空域容量研究、飞行汽车性能分析、“通感算一体化”架构的发展为空域交通管理等提供了新范式,也凸显了低空体系的潜力与挑战<sup>[3-5]</sup>。在此背景下,无人机(Unmanned Aerial Vehicle, UAV)因

快速灵活的特点,在城市巡检、应急救援等场景应用潜力巨大。但现实场景复杂、任务需求增加,单架无人机难以全面覆盖,需多机协同,而能量受限下,如何合理配置无人机资源以实现“全覆盖、低消耗”,成为支撑低空应用落地的关键问题。

现有研究已有许多针对无人机资源方面的优化,一部分研究建立了可靠性分析模型、能耗优化模型,实现了单机或编队任务下的可靠性分析<sup>[6]</sup>和路径航迹能耗优化<sup>[7-10]</sup>。但多数研究针对单一目标任

务展开,忽视了多任务区域下无人机群的整体数量配置与资源调度问题。涉及无人机数量位置的资源配置方面,Feng等<sup>[11]</sup>利用相位任务可靠性建模与重要度度量,提出“无人机数量-任务可靠性”的联合优化框架。部分研究实现了通信或无线覆盖场景下无人机搭载基站的部署优化<sup>[12]</sup>、无人机数目优化<sup>[13]</sup>、回程及部署优化<sup>[14]</sup>。然而,上述工作多以通信覆盖与基站部署为主,且无人机主要工作为静态的通信基站,难以直接应对多区域、总数受限场景下面向任务“资源配置-覆盖优化”联合覆盖搜索的动态任务。

在多无人机覆盖搜索优化方面,当前主流的覆盖搜索规划可分为2类核心场景:一类是基于目标区域几何特征的全域覆盖,其路径规划结果具有强结构化特征,能够满足长期、稳定、快速重复执行的任务需求;另一类是基于目标位置概率分布的高风险区域优先覆盖,旨在通过最短路径聚焦高概率区域,提升目标发现效率<sup>[15-17]</sup>。在日常巡防、基础设施故障排查等需要周期性全覆盖的场景中,全域覆盖的结构化路径更能适配任务的重复性与稳定性要求,因此成为本文的研究焦点。

早期,Araújo等<sup>[18]</sup>系统梳理了螺旋式、平行式等全域覆盖经典路径模式,为后续研究奠定了方法基础。Chen等<sup>[19]</sup>综述了多无人机协同全域覆盖的研究现状。随着研究深入,学者们针对不同场景与约束持续优化算法,Liu等<sup>[20]</sup>面向矩形区域提出基于最小生成树的协同覆盖策略,平衡了搜索覆盖率与无人机连通性;刘全义等<sup>[21]</sup>融合栅格地图、传统路径规划与改进粒子群算法,提升了复杂山区的路径适应性;陈佳雨等<sup>[22]</sup>将旋转区域划分与Q-Learning结合,增强了网格扩展区域的双机路径规划灵活性。上述研究虽提升了路径规划的灵活性与环境适应性,但大多以矩形区域为研究对象,未充分考虑区域空洞等复杂几何特征。针对非矩形区域,相关学者开展了针对性探索,吴青坡等<sup>[23]</sup>通过优化转弯时机与位置,提升了覆盖搜索的效率与均匀性;Vinh等<sup>[24]</sup>提出低计算量区域分解策略,简化复杂区域以应对几何不确定性;戴健等<sup>[25]</sup>设计按无人机来向均衡的区域划分与路径联动方案,提升了协作效率;李道文等<sup>[26]</sup>构建并行全覆盖航道与无缝切换逻辑,减少了路径冗余。总体而言,现有无人机协同覆盖搜索优化工作虽取得很多成果,但多聚焦于“拟定无人机数量”的路径层优化,全域覆盖搜索规划方法缺乏在复杂几何区域适配、基站位置关联、无人机数量-区域划分协同等方面的优化。

综上,现有研究在无人机资源配置、区域覆盖路径规划方面均取得了重要进展,但仍存在:①能耗与可靠性分析揭示了无人机任务约束,但未能直接指导任务需求驱动的无人机资源分配优化等问题;②协同搜索路径规划缺乏对无人机基站与搜索区域空间关系的解析,未将无人机数量配置与搜索区域结构、位置与路径规划进行协同优化,对既能适配区域特征,又便于多机分区协作的结构化路径骨架关注不足等问题。为解决上述问题,本文提出一种端到端的无人机群仿蛛网覆盖搜索双层规划优化方法,采用分层端到端架构,其中端到端指从高层覆盖需求输入到最终部署无人机覆盖路径决策输出的闭环决策流程。

## 1 问题描述与方法框架

### 1.1 端到端无人机群覆盖搜索双层优化方法框架

本研究面向多无人机在有限资源预算下的区域协同覆盖搜索优化问题。核心目标是:在保证系统整体可靠性不低于可接受阈值的前提下,基于数据驱动的覆盖需求,合理配置多无人机资源,并在资源约束与能量/续航限制下,设计具有“可靠-低耗-均衡-灵活”特性的端到端区域协同覆盖执行策略,使目标区域得到完整均衡的覆盖。为此,构建如图1的2层耦合的优化框架。

需求层资源优化(端到端的深度学习数量资源配置):依据无人机搜索性能与环境特征,输出各区域期望的无人机数量与覆盖配额,作为资源分配决策的初值,同时为单个覆盖搜索目标区域提供执行任务的无人机数量配额,作为执行层的资源预算,即区域覆盖搜索路径规划的前提基础。

执行层路径优化(端到端仿蛛网结构协同覆盖搜索路径规划):在资源层给定的数量约束下,以无人机参数,目标区域及基站空间参数为输入,设计具有“放射丝-捕丝”仿生结构特征的精细化协同覆盖路径生成策略,输出无人机群的任务子区域和协同搜索路径,提高搜索子区域与基站的关联程度,增强覆盖路径与目标区域的灵活适配能力。搜索执行层与覆盖需求层通过协同反馈机制实施资源配置的反馈修正。

在上述统一框架下,深度学习的数量配置承担“从覆盖需求层面推断资源规模”的职能,输出从系统出发的任务损失最小的每个目标区域的无人机配置数量,为执行层优化提供无人机数量配额,并为双层反馈修正提供基础资源配置方案;在执行层,基于

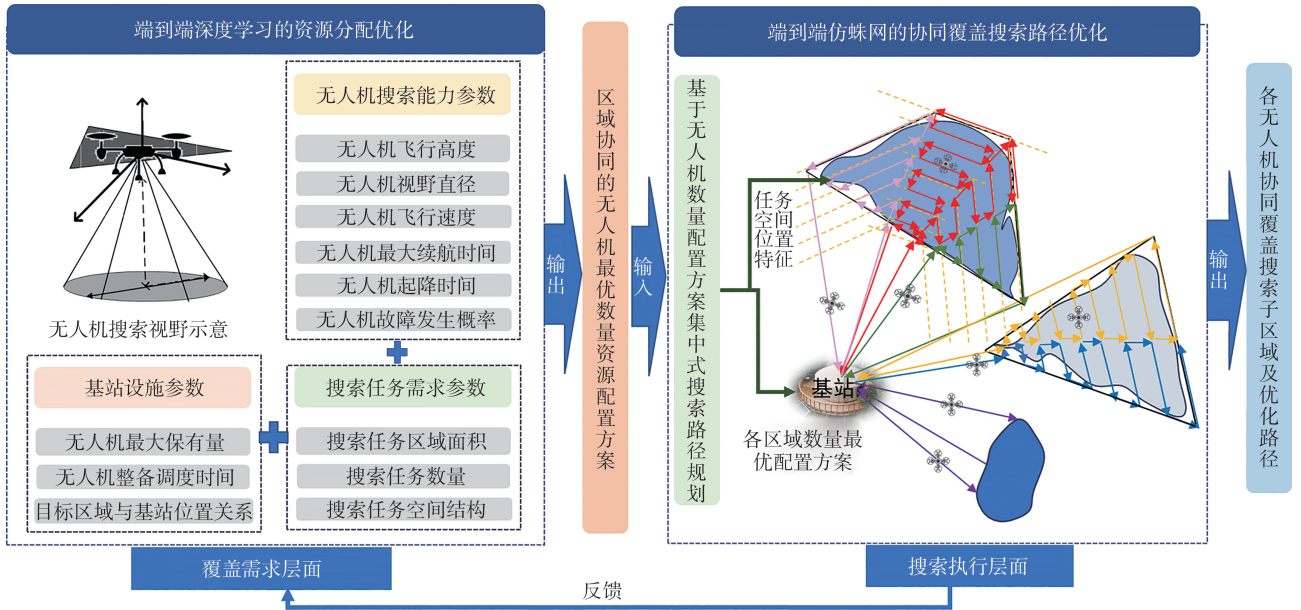


图1 无人机群覆盖搜索双层优化方法框架

Fig. 1 Framework of two-layer optimization method for UAV swarm coverage search

上层分配至该区域的无人机数量,采用仿蛛网结构的协同覆盖路径规划方法划分子区域,将“放射-环形”的仿生结构转化为均衡灵活覆盖的可操作策略,输出配置无人机的协同搜索路径;执行层将基于实际规划结果在能耗,覆盖任务未完成情况等方面的指标统计反馈需求层,需求层根据指标实施资源配置调整。二者通过“需求规模-数量配额-任务划分-路径规划-反馈调整”的闭环耦合,实现了神经网络给出配额与规模的上层资源画像,仿生结构在下层执行层将资源画像落地为均衡且灵活的覆盖动作。

## 1.2 无人机群覆盖搜索双层优化方法模型及目标

### 1.2.1 需求层多目标均衡的资源配置优化目标及模型

在自主覆盖搜索任务中,研究的核心问题是如何在能耗、可靠性和覆盖效率之间实现优化平衡,从需求层面出发,核心任务为规划任务执行最优资源预算。给定一个 $R$ 表征的搜索目标任务区域,受一般地理、经济因素限制,系统需从同一固定的基站 $P$ 调度合适数量的无人机群。无人机群数量的确定,代表任务所能消耗的最大资源预算为所有被分配无人机能量总额。考虑实际场景中复杂约束,结合图1表述,本问题中每架无人机受限于最大续航时间、满电电量、出发点与目标区域的空间距离、调度整备无人机所需的时间以及在任务执行过程的可靠性等。

结合搜索执行层的路径规划方法特征,即每架

无人机划分独立的搜索子区域,搜索路径从基站 $P$ 向目标搜索区域远端呈现等间距“Z”字路径扩散覆盖,且每个无人机的覆盖子区域不重叠。保证任务在安全性要求内运行,针对一个目标区域,任务建模为

$$S_{\max}^u = d \left( T_u - T_u^{\text{inv}} - \frac{D_{\max} + D_{\min}}{v} \right) v + \pi \left( \frac{d}{2} \right)^2 \quad (1)$$

式中: $S_{\max}^u$ 为每架被配置执行任务的无人机 $u$ 最大可覆盖的搜索面积; $T_u$ 为无人机 $u$ 续航时间; $T_u^{\text{inv}}$ 为无人机 $u$ 含起降、调试等在内的非搜索执行总时间; $v$ 为无人机的匀速飞行速度; $d$ 为无人机搜索视野直径; $D_{\max}$ 为 $P$ 点与目标区域内的最远距离; $D_{\min}$ 为 $P$ 点与目标区域内的最近距离。

当每架无人机的任务量相同时,第 $r$ 个区域的 $N_r$ 架无人机执行搜索任务的时间 $t_{\text{tar}}$ 为

$$t_{\text{tar}} = \frac{\min\{|R|, S_{\max}^u N_r\}}{v N_r d} + T_u^{\text{inv}} \quad (2)$$

式中: $|R|$ 为目标区域 $R$ 的面积。

简化无人机的故障模型为常规的故障韦伯分布模型 $\mathcal{F}_u(t)$ 为

$$\mathcal{F}_u(t) = 1 - e^{-\zeta t} \quad (3)$$

系统总体可靠度为

$$\mathcal{F}_{\text{sys}}(N_r, t) = 1 - [1 - \mathcal{F}_u(t)]^{N_r} \quad (4)$$

式中: $\zeta$ 为每架无人机的单位时间故障率; $\mathcal{F}_{\text{sys}}(N_r, t)$ 为系统总体任务失败概率,由各无人机独立失效事件的互补概率构成。

综合上述条件,需求层资源优化目标可形式化为一个多目标约束优化问题:在保证区域覆盖完整性和系统总体故障率不超过阈值的前提下,最小化任务总代价,表示为

$$r_{\text{res}} = \alpha \left| |R| - \min \left\{ |R|, S_{\max}^u N_r \right\} \right| + \beta N_r t_{\text{tar}} \rho_u + \gamma \max \left\{ \mathcal{F}_{\text{sys}}(N_r, t_{\text{tar}}) - \mathcal{I}, 0 \right\} + \eta t_{\text{tar}} \quad (5)$$

式中: $\mathcal{I}$ 为系统容许的最大故障概率; $\rho_u$ 为单位时间的能量消耗; $\alpha, \beta, \gamma, \eta$ 均为任务权重参数,由实际搜索任务中的重要性确定。

总代价函数由任务未完成度、能耗开销、故障风险以及搜索时间等目标做量级统一化处理后的加权叠加。将上述优化目标扩展为 $N_{\text{tar}}$ 个目标搜索区域后,配置约束为

$$\sum_{r=1}^{N_{\text{tar}}} N_r \leq N_U \quad (6)$$

式中: $N_U$ 为无人机保有量总数; $N_r = \{N_1, N_2, \dots, N_{N_{\text{tar}}}\}$ 为各个区域配置的无人机数量集合。

基于需求层的目标优化,将从宏观的角度,保证在可靠性满足阈值的前提下,无人机配置数量可以在区域覆盖执行层的搜索任务执行时间,任务能量总消耗预算上达到最小,继而在执行层面,将协同搜索优化目标转向覆盖路径的精细化、灵活性以及均衡性。其次资源配置层与搜索执行层间建立耦合的覆盖搜索闭环资源配置反馈调整机制,以应对由于不规则目标区域几何结构复杂,搜索路径可能存在冗余等问题造成的配置方案误差及失效等问题。

### 1.2.2 搜索执行层精细化灵活均衡覆盖优化目标及模型

本文设计的双层覆盖搜索优化框架,基于宏观覆盖资源需求层,已经做出了最优的任务资源配额,搜索执行层则负责优化区域覆盖搜索路径与目标区域的适配性、灵活性、均衡性,增强基站与任务目标区域的关联程度,更加均衡、灵活地完成目标区域的自主协同搜索。

为实现无人机群协同并行自主覆盖搜索,搜索子区域质心与基站 $P$ 的平均距离、子区域质心与搜索路径中点的平均距离,以及子区域质心与搜索路径中点距离的方差,将作为衡量路径规划紧凑性、匹配度与均衡性的核心优化目标。子区域质心与基站平均距离 $\bar{D}_p$ 为

$$\bar{D}_p = \frac{1}{K} \sum_{k=1}^K \sqrt{(x_{\mathcal{R}_k} - x_p)^2 + (y_{\mathcal{R}_k} - y_p)^2} \quad (7)$$

式中: $(x_{\mathcal{R}_k}, y_{\mathcal{R}_k})$ 为第 $k$ 个子区域的质心坐标; $(x_p, y_p)$

为基站 $P$ 坐标。

该目标直观反映子区域划分与基站的空间关联性,数值越小,意味着子区域布局更贴近基站,整体任务布局更紧凑,能有效降低无人机续航消耗,提升任务响应速度。

子区域质心与搜索路径中点平均距离 $\bar{D}_{\mathcal{R}}$ 为

$$\bar{D}_{\mathcal{R}} = \frac{1}{K} \sum_{k=1}^K \sqrt{(x_k^{\text{s.m}} - x_{\mathcal{R}_k})^2 + (y_k^{\text{s.m}} - y_{\mathcal{R}_k})^2} \quad (8)$$

式中: $(x_k^{\text{s.m}}, y_k^{\text{s.m}})$ 为第 $k$ 个子区域对应的搜索路径中点坐标。

此处的搜索路径为包含从 $P$ 点出发后完成搜索返回 $P$ 点的完整闭环路径。数值越小,表明路径设计越贴合子区域几何特征,无人机在子区域内的搜索轨迹能更精准覆盖核心区域,提升子区域覆盖效率。

子区域质心与搜索路径中点距离方差 $V_{D_{\mathcal{R}}}$ 为

$$V_{D_{\mathcal{R}}} = \frac{1}{K} \sum_{k=1}^K \left[ \sqrt{(x_k^{\text{s.m}} - x_{\mathcal{R}_k})^2 + (y_k^{\text{s.m}} - y_{\mathcal{R}_k})^2} - \bar{D}_{\mathcal{R}} \right]^2 \quad (9)$$

子区域质心与搜索路径中点距离方差是衡量整体覆盖均衡性的关键指标,直接体现路径规划方法的灵活性与均衡性。方差越小,代表各子区域的路径匹配度差异越小、一致性越高,避免因部分子区域路径不合理拖慢整体任务进度,保障大规模协同覆盖任务的稳定性与可靠性。

上述3个指标从空间关联、区域匹配、整体均衡3个维度形成互补,共同构成多无人机协同覆盖搜索路径优化的核心目标,是实现“低消耗、高覆盖、强均衡”任务目标的重要支撑。

### 1.2.3 双层耦合的覆盖搜索闭环资源配置反馈调整机制

为实现资源配置层与仿蛛网路径规划层之间的协同优化,在第 $r$ 区域分配 $N_r$ 架无人机的情况下,路径规划层对每一子区域执行路径生成并评估关键任务执行指标,表示为

$$\Xi(r) = \zeta F_r - \nu \frac{E_r^{\text{rem}}}{E_r^{\text{used}} + E_r^{\text{rem}}} \quad (10)$$

式中: $F_r$ 为规划后仍未覆盖的任务区域面积与区域总面积之比; $E_r^{\text{used}}$ 和 $E_r^{\text{rem}}$ 分别为区域内所有分配给该区的无人机的预估已耗总能量和剩余能量,当区域无人机数为0,将式(10)中的分式定义为0; $\zeta > 0$ 与 $\nu > 0$ 为权重系数,用以平衡覆盖缺失优先与能量可用性惩罚的相对重要性。

资源配置层据此计算每一子区域的优先级指标

$\Xi(r)$ ,针对存在未能完全覆盖的子区域(即存在 $r$ 使得 $F_r > 0$ )的情况,采用滚动增量策略对资源分配进行逐步修正。先计算并按降序排序所有子区域对应指标、优先增派指标更大区域,每轮仅对单个子区执行“+1架无人机”的单步增量增派,新增无人机取自空闲池或从优先级最低子区回收调配,每次分配调整后重新运行路径规划层并更新 $\Xi(r)$ ,重复迭代直至 $\forall r, F_r = 0$ ,调整步数达到上限或分配前后各区目标函数之和无显著下降。通过以量化指标 $\Xi(r)$ 为优先级的“单次微调+重评估”循环,能够在保证每次调整可验证的前提下,逐步修复欠覆盖区域并保留系统的全局资源约束。

## 2 端到端的深度学习的区域覆盖资源分配优化

### 2.1 输入矩阵编码及特征提取网路结构

针对面向区域覆盖需求层面的多任务区域无人机资源配额问题,本质是“挑选+排序”的组合优化问题,涉及约束满足和离散决策,随着问题规模增大,求解最优解所需的计算时间会呈指数级或阶乘级增长。因此实际中常采用启发式算法寻找近似最

优解。同时以优化多个区域目标函数总和为目标的协同资源配置问题为多最优解问题,也可称为“等效最优解问题”。这类问题的核心是:优化问题的可行域中存在多个不同的可行解,它们的目标函数值相等且均达到最优。

然而,遗传算法等启发式算法本质是通过局部枚举的方式在大量的解中寻找更优的解,并不能解析区域特征-无人机参数-数量配置方案之间的映射关系;然而深度学习DNN网络一方面通过组合局部核可逼近多项式/分段函数,从而捕获复杂非线性关系,使得DNN不只是简单模仿启发式算法的解,而是在学习复杂非线性映射关系的基础上,通过专家指导,得到一套属于自己的考虑资源配置复杂均衡的资源配置方案,从而在保证配置方案水平的前提下,实现常数时间决策,大大降低资源配置方案的求解时间。

为此,本文提出基于深度学习的无人机数量配置方法,利用遗传算法生成的预训练集训练网络,实现大规模场景下的最优分配。如图2所示,网络采用“特征编码-信息增强-决策输出”的端到端结构。

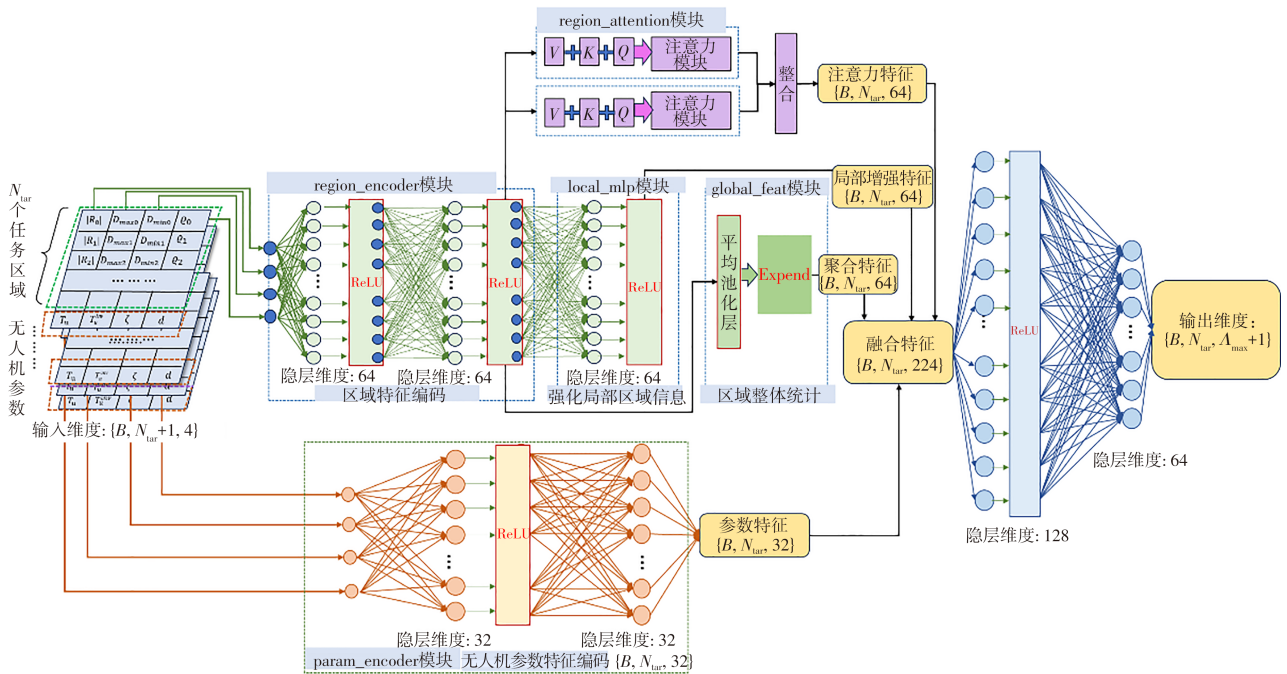


图2 无人机数量资源配置特征处理网络结构

Fig. 2 Network structure for feature processing of UAV quantity resource allocation

在输入矩阵构造层面,将第1.2节中涉及的搜索目标区域 $|R|, D_{max}, D_{min}$ 作为特征向量,形成输入向量的前 $N_r \times 3$ 维,计算每个区域间面积的比例作为输入矩阵的最后一列。无人机参数的 $T_u, T_u^{inv}, d, \zeta$

作为输入矩阵的最后一行,共同构成完整的无人机数量资源配置的网络输入,图2中: $B$ 为迭代的样本数量; $A_{max}$ 为单次最大配置数量。

在特征提取与融合处理层面上,本文设计了多

模态特征融合骨干网络,通过“分支路编码-局部增强-区域依赖建模-多尺度融合”的层级架构,实现特征的深度提取与跨模态整合,网络整体结构及特征处理逻辑如下。

①特征拆分:输入矩阵被拆分为两部分,即搜索目标区域特征部分以及无人机参数特征部分。②分支路编码:搜索区域特征经区域编码器映射为高维特征,无人机参数特征经参数编码器映射为嵌入特征,并通过维度扩展适配区域特征的序列维度。③局部与全局特征增强:编码后的搜索区域特征一方面经局部增强MLP处理,得到局部增强特征,另一方面区域特征输入自注意力模块,以自身为Query/Key/Value完成注意力计算,输出融合区域间依赖的注意力特征,替代原始区域特征实现跨区域信息交互,并对注意力特征执行全局平均池化,得到全局聚合特征。④多特征融合:将注意力特征、局部增强特征、全局聚合特征及参数特征在特征维度拼接,得到融合特征。⑤决策输出:将融合特征映射为动作概率分布,通过策略梯度优化学习无人机数量的最优配置,实现任务需求与无人机能力的最优匹配。

## 2.2 网络损失定义及训练迭代优化机制

本文提出融合遗传算法数据集、蒙特卡洛动态指导、多目标损失约束与数据滚动更新的一体化训练框架。框架通过“专家数据生成-动态指导优化-损失约束学习-数据迭代更新”的闭环设计,为网络提供高质量先验知识与持续优化方向,实现无人机数量配置策略的高效学习与性能提升。

(1)遗传算法构建专家先验训练数据集:鉴于遗传算法在此类问题上具有的优势,但是同时其计算量大计算时间长的问题,本文采用遗传算法(Genetic Algorithm, GA)求解的数量分配方案数据集作为专家指导的基础方案,进行监督训练,以使得训练好的网络能达到遗传算法的优化能力的同时提升其求解效率,为后续学习提供高质量先验。

(2)蒙特卡洛采样变异策略指导:在训练过程中,本文引入蒙特卡洛采样变异策略,在专家动作的构建中,训练初始为GA求解的资源配置方案,每轮迭代过程中,有一定的概率在当前专家经验配置上进行±1~3的随机调整、重新分配,或将专家经验配置按照任务面积比例调整。对生成的候选解,利用目标优化函数进行评估,选取最优解作为“专家动作”,一方面修正或引导网络输出,避免网络陷入局部最优,另一方面,可防止基于专家经验的动作概率

的交叉熵损失过快的收敛导致网络策略固化或过拟合。

(3)损失函数设计:本文设计了融合多目标的损失函数,用于引导Actor网络训练,表示为

$$L_{\text{Actor}} = L_{\text{ent}}^{\pi} + L_{\text{reward}} \exp(\lambda_{\text{scal}} L_{\text{CE}}) + \lambda_{\text{ratio}} L_{\text{ratio}} \quad (11)$$

式中: $L_{\text{CE}}$ 为交叉熵损失,约束网络预测的无人机数量配置分布与专家动作保持一致; $L_{\text{ratio}}$ 为比例约束损失,最小化UAV配置比例与区域面积比例之间的均方误差; $L_{\text{reward}}$ 为奖励一致性损失,约束网络预测方案与专家动作在奖励上的一致性,避免仅追求动作与专家差异最小化而忽视任务性能; $L_{\text{ent}}^{\pi}$ 为策略固化惩罚项,如果网络的动作输出保持固化,即不同样本的输出结果相差不大,且这种情况发生在超过半数规模的训练数据中,则此时 $L_{\text{ent}}^{\pi}$ 设置为较大的损失值,引导网络给出多样化策略; $\lambda_{\text{ratio}}$ 为比例约束指导动态权重,训练前期较大,后期逐渐减小; $\lambda_{\text{scal}}$ 为指数型交叉熵项的 $L_{\text{CE}}$ 缩小权重,防止指数化后此部分损失远超其他项。

利用指数函数性质处理交叉熵损失,当 $L_{\text{CE}}$ 降到接近0时,指数项接近1,不仅防止其降为0后相乘的其他损失无法继续优化,一定程度上也降低了其抢占网络损失梯度主导权的可能。训练初期时指数项的变化率较大,与 $L_{\text{reward}}$ 结合可以加快网络动作空间与专家经验、目标函数间差距的收敛,为训练过程中数据替换做好准备;另一方面如果网络在训练中期未能适应新的训练数据导致网络出现较大波动时,指数项有助于网络损失快速收敛回落,矫正网络参数,有效避免网络收敛到次优解。

(4)数据滚动更新机制:为增强模型泛化性,本文引入滚动数据更新机制,在网络训练前中期每个训练周期中,网络评估当前输出的配置结果的目标函数值和结果稳定性,当达到更换训练数据的要求后,将新训练样本替换1/3的旧样本,并更新对应专家动作。网络不断学习新分配方案,实现性能逐步提升。其次由于在损失构造方面引入了指数项,在数据更换后网络能加快收敛回落,但是也会引起网络在训练后期的波动,为此网络训练采用两段式学习率策略,在存在数据滚动更新机制的前半段采用较大的固定学习率,加快网络收敛,在网络后半段采用余弦退火衰减,逐步平滑衰减,防止训练末期出现振荡波动。

## 3 端到端的仿蛛网无人机区域覆盖协同搜索路径优化

端到端仿蛛网无人机区域覆盖协同搜索路径优

化方法,构建了从需求参数到路径结果的一体化规划体系。输入:①无人机资源参数,包括参与协同搜索的无人机数量、单机续航能力、搜索半径等硬件约束条件;②搜索任务参数,包含目标搜索区域的边界顶点坐标和基站位置坐标。最终输出结果直接对应每架无人机的精细化搜索路径规划方案,实现从资源配置层的“资源-任务-空间”输入到“多机协同均衡路径优化”输出的端到端闭环。

### 3.1 圆网蜘蛛网模式结构启发

本研究借鉴自然界蜘蛛网的几何结构特征,基于需求层无人机最优资源配置结果,提出一种适配任意凸四边形区域及任意位置无人机基站的协同覆盖搜索路径优化方法。自然界蜘蛛网是高度优化的生物结构,由辐射状的放射丝、停泊丝与环形的捕丝、框丝组成<sup>[27-28]</sup>。图3为横纹金蛛蛛网部分结构:停泊丝和框丝共同确定蛛网最大覆盖区域;放射丝从网心向外辐射,既为蛛网提供骨架与力学支撑,又作为振动传导通道,为蜘蛛提供网心到边缘的快速路径及猎物大致定位;捕丝沿近似同心路径连接各放射丝,形成封闭环带。放射丝的直达性与捕丝的环境性结合,让蜘蛛网兼顾快速定位与全域覆盖,在保证捕捉效率的同时,最大化覆盖范围与猎物拦截概率,这种几何与力学协同结构是自然选择优化的结果,能显著提升捕食成功率与能量利用效率。



图3 圆网蜘蛛的蛛网模式结构

Fig. 3 Web pattern structure of orb-weaving spiders

受蛛网的模式结构启发,本文基于不规则目标搜索区域的最小外接凸四边形,将无人机基站 $P$ 选作“网心”,从基站向边界发射若干条“放射丝”,可实现从中心向外围的快速覆盖与子区域划分,每一块分区可指派一架无人机执行覆盖搜索,减少了单个无人机的任务难度。以“Z”字路径为基础“捕丝”,结合目标区域的几何特征规划每个子区域的覆盖搜索路径,形成多层闭合覆盖搜索框架。

相比传统的覆盖路径规划方法,仿蛛网将基站作为“网心”,结合放射丝与捕丝仿生结构,通过射

线-环带结构更自然地将“基站到边界”远近差异纳入路径拓扑,能显著提升子区域与基站的关联程度。同时,仿蛛网方法在子区划分上是角度驱动与半径驱动的组织方式,环带间隔与UAV视野直径直接耦合,在角度方向上天然保证路径连续性,易于实现并行化。仿蛛网结构的路径规划方法继承了蛛网结构可拓展性,网心到捕食面的快速等优点,为区域协同覆盖搜索路径规划提供了新的思路。

### 3.2 仿蛛网无人机协同任务区域划分与路径规划

在实际场景中,需要覆盖搜索或巡检的区域大多难以呈现规则的矩形,圆形等轴对称或者中心对称的几何图形,且形状多为不规则,本文的仿蛛网无人机协同覆盖搜索路径优化方法可基于不规则搜索区域的外接凸四边形实施路径规划,外接图形不拘泥于直角矩形,更加灵活,一定程度上也减少了部分区域由于矩形的直角约束产生的无效覆盖面积。

本节将从不规则目标搜索区域的近似处理开始,建模搜索区域的几何特征,基于近似处理的目标搜索区域,结合蛛网仿生结构和资源配置层的无人机配置结果,划分多无人机协同搜索子区域,并基于子区域几何特征规划协同覆盖搜索路径。

#### 3.2.1 搜索区域近似处理与仿蛛网协同搜索子区域划分

设不规则目标搜索区域 $\Omega$ 是二维平面上的一个闭合区域, $\Omega$ 可用包含 $\chi$ 个点的点集的凸包表示,其复杂度为 $O[\chi \lg(\chi)]$ ,此凸包的最小外接矩形(Minimum Enclosing Rectangle, MER)可用旋转卡壳在复杂度 $O(\sigma)$ 内精确求得,其中 $\sigma$ 为凸包顶点数。由于最小外接凸四边形的优化问题在理论上需 $\sigma$ 条凸包边方向中选取4条方向向量组合进行枚举,搜索空间规模为 $O(\sigma^4)$ ,每次组合需计算4次支撑距离与一次交集面积评估,总体复杂度达 $O(\sigma^5)$ 。为减少计算复杂度,采用以MER四个边的法向量为起点,利用局部窗口搜索方法在较低计算复杂度下快速求解。

若MER每条边都与凸包共有 $H$ 个交点,这些交点均代表MER邻边正交方向上,凸包跨度最大的点,以这些点所在MER四个方向的单位法向量 $\{b_e\}_{e=1}^4$ 附近建立角度窗口 $[\theta_e - \Delta, \theta_e + \Delta]$ ,并仅在该区间内选取候选法向量作为搜索子集 $U_e$ ,构造四条半平面支撑线,使4条支撑线的半平面交集包含 $\Omega$ 且面积最小。在实现上,为保证离散化精度与搜索代价平衡,可在每个窗口内均匀采样 $h$ 个方向。

于是原始组合空间  $O(\varpi^4)$  被压缩为  $H_1H_2H_3H_4h^4$ , 由于  $H \ll \varpi$ , 由此计算复杂度将实现与凸包规模的解耦, 并得到近似最小外接凸四边形  $R$ 。在保留近似最优解精度的同时显著提升求解效率。

对于显著非凸区域, 先对主域做分块分解<sup>[25]</sup>, 再对每个子块分别生成最优外接凸四边形并单独规划; 对于存在显著空洞的区域, 保留面积大且显著影响空洞, 求解保留的空洞区域的近似几何中心和最大内接圆, 用空洞中心连线的垂直平分线所定义的半平面进行裁剪, 求解每个空洞中心的 Voronoi 单元, 每个单元内将其空洞中心作为中转空中基站  $P_{TS}$ , 此时定义每个  $P_{TS}$  的目标搜索区域为其 Voronoi 单元与空洞最大内接圆外的交集。

定义求得目标区域的最小外接凸四边形  $R$  的顶点集合为  $Z$ , 边集合为  $E$ , 表示为

$$\begin{cases} R = \sum_{i=1}^4 \lambda_i Z_i \\ \lambda_1 + \lambda_2 + \lambda_3 + \lambda_4 = 1 \quad \lambda_i \geq 0, i = 1, 2, 3, 4 \end{cases} \quad (12)$$


$$E = \{\{Z_1, Z_2\}, \{Z_2, Z_3\}, \{Z_3, Z_4\}, \{Z_4, Z_1\}\} \quad (13)$$

式中:  $\lambda_i$  为正实数, 表示权重, 均为正数或 0, 且总和为 1;  $Z_1 \sim Z_4$  分别为  $R$  的 4 个顶点。


对每个  $P$  点与  $R$  顶点的方向向量计算向量极角, 极角中的最大值  $\theta_{\max}$ 、最小值  $\theta_{\min}$  所对应的  $R$  的顶点为  $Q_1, Q_2$ , 若  $\theta_{\max}$  或  $\theta_{\min}$  存在多个对应的顶点, 则取距离  $P$  较近的那一个, 构成搜索区域顶点边界的集合  $Q = \{Q_1, Q_2\}$ 。若  $P \in R$ , 即表示  $P$  点在目标区域内部, 此时  $\theta_{\max} = \theta_{\min} + 2\pi$ 。

此时 2 条射线  $L_1 = \overrightarrow{PQ_1}, L_2 = \overrightarrow{PQ_2}$  构成扇形区域边界及内部  $S(P, Q_1, Q_2)$ , 表示为


$$\begin{cases} S(P, Q_1, Q_2) = \{X \mid \theta_{\min} \leq \theta_X \leq \theta_{\max}\} \\ \theta_X = \arctan(y_X - y_P, x_X - x_P) \end{cases} \quad (14)$$



(a) 基站在搜索区域内



(b) 子区域在目标区域边界



(c) 搜索区域顶点在子区域内

图4 典型子区域几何结构与覆盖路径规划模式

Fig. 4 Typical sub-region geometric structure and coverage path planning modes

以  $P \notin R$  为例, 模拟放射丝结构, 需  $N-1$  条放射丝切分整个目标区域为不重叠的子区域, 定义射线集合为

$$\mathcal{L} = \left\{ L_k = \text{ray}(P, \theta_k) \mid \theta_k = \theta_{\min} + (k-1)\delta, \right. \\ \left. k = 1, \dots, N+1 \right\} \quad (15)$$

式中:  $\delta$  为等角度间隔划分的间隔角;  $N$  为需求层计算出每个目标搜索区域最优的无人机数量配额。

若需要每架无人机的搜索任务量均衡, 定义目标区域的子区域均衡面积  $G = |R|/N$ , 然后用一维线性反插值把目标值  $\mathcal{G}_k = \{0, G, 2G, \dots, NG\}, k = 1, 2, \dots, N+1$  映射到角度近似值  $\theta_k$ 。

确定射线集合后, 定义射线子区域边界即内部为  $S(P, L_k, L_{k+1})$  以及每个搜索子区域内部及边界  $\mathcal{R}_k$  为

$$S(P, L_k, L_{k+1}) = \{X \mid \theta_k \leq \theta_X \leq \theta_{k+1}\} \quad (16)$$

$$\mathcal{R}_k = S(P, L_k, L_{k+1}) \cap R \quad (17)$$

### 3.2.2 基于子区域几何特征的仿蛛网覆盖搜索路径规划

蜘蛛结网过程一般是从外侧的“框丝”逐层向内, 也就是说蛛网的“捕丝”通常与“框丝”平行, 能保证整个蛛网区域的结构完整性。同时, 结合蛛网的“捕丝”与“Z”字路径基础, 以最外层“框丝”为平行航线基础不会产生过度的冗余航线, 同时针对目标区域最外层的边界搜索区域不会因为无人机转角导致的覆盖区域盲区产生, 所规划的航线更能适应不规则的搜索区域的几何特征。

图4表示  $P$  点在  $R$  区域内部以及外部的典型子区域情况。

以图4(b)的子区域场景为例, 2条射线边界与  $E$  形成 3 个交点设为集合  $V_k$ , 定义交集

$$V_k = \{A_1, A_2, Z^*\}$$

式中:  $A_1, A_2$  为  $L_k$  与  $E_i, E_j$  的交点;  $Z^*$  为除  $A_1, A_2$

以外的第3个交点,为一个 $R$ 区域边界顶点。

模拟“捕丝”结构,从 $A_1$ 点开始以 $Z \cdot A_2$ 的斜率为基准平行航线的斜率,相邻间隔 $d$ 生成平行航线簇,求解每条平行航线与搜索子区域及边界 $\mathcal{R}_k$ 的交点。定义基准平行航线 $Z \cdot A_2$ ,且穿过 $A_1$ 点生成第1条平行航线,依次从 $A_1$ 点向远端等间隔递进,构造平行航线集合

$$L_{\text{pal}} = \left\{ l_m \mid l_m(s) = A_1 + mdn + s\xi_{\text{base}}, m \in \{-M, \dots, M\} \right\} \quad (18)$$

$$\xi_{\text{base}} = \overrightarrow{PA_2} - \overrightarrow{PZ^*} \quad (19)$$

式中: $\mathbf{n} = \text{unit}(\xi_{\text{base}}^\perp)$ 为基准平行航线的单位法向方向; $M$ 为最大可布设平行线层数(受 $d$ 限制); $s$ 为实数参数,用于表示平行线上的移动距离或步长。

定义每条平行航线与区域边界射线 $L_k$ 交点序列 $J_m$ ,与扇形内另一条边界边 $A_1Z^*$ 的交点序列 $I_m$ ,若针对图3(a)的子区域场景, $I_m$ 为平行航线组与 $L_{k+1}$ 的交点集合,且 $I_0 = J_0 = P$ ,具体为

$$J_m = \left\{ \begin{array}{l} J_0, J_1, \dots, J_M \\ \left. \begin{array}{l} J_m = l_m \cap L_k \\ \text{dist}(l_m, Z \cdot A_2) \leq \frac{d}{2} \\ J_0 = A_1 \\ \text{dist}(J_m, P) < \text{dist}(J_{m+1}, P) \\ m \in \{0, 1, \dots, M-1\} \\ l_q \cap \mathcal{R}_k \neq \emptyset \\ q \in \{0, 1, \dots, M-1\} \end{array} \right\} \end{array} \right. \quad (20)$$

$$I_m = \left\{ \begin{array}{l} I_0, I_1, \dots, I_M \\ \left. \begin{array}{l} I_m = l_m \cap A_1Z^* \\ \text{dist}(l_m, Z \cdot A_2) \leq \frac{d}{2} \\ I_0 = A_1 \\ \text{dist}(I_m, P) < \text{dist}(I_{m+1}, P) \\ m \in \{0, 1, \dots, M-1\} \\ l_q \cap \mathcal{R}_k \neq \emptyset \\ q \in \{0, 1, \dots, M-1\} \end{array} \right\} \end{array} \right. \quad (21)$$

一般情况下,每条平行线 $l_m$ 会有一个点落在 $A_1Z^*$ ,另一个点落在 $L_k$ 射线上。结合“Z”字构造奇偶层交错的搜索路径航路点序列: $P \rightarrow J_0 \rightarrow I_0 \rightarrow I_1 \rightarrow J_1 \rightarrow J_2 \rightarrow I_2 \rightarrow I_3 \rightarrow J_3 \rightarrow J_4 \rightarrow \dots \rightarrow J_M \rightarrow P$ 。

针对图4(c)的场景其特征为子区域内包含一个或多个区域边界顶点,此时连接 $P$ 点与子区域内顶点,将子区域继续切分,为了降低航线冗余,此时以平行航线簇从最远的区域边界为基准平行线,向 $P$ 点近端方向递进,交点序列为平行航线与射线或区

域边界或 $P$ 与区域顶点连线的交点,并依照与 $P$ 点距离由近到远的方式排列。

以图4(c)为例, $Z$ 为子区域内包含的 $R$ 区域的顶点,且 $Z^*$ 不在射线边界 $L_k, L_{k+1}$ 上。设左侧区域 $\mathcal{R}_{k1}$ 中,平行航线簇 $L_{\text{lef}}$ 与 $\mathcal{R}_{k1}$ 边界构成的交点序列为 $\{I_0, I_1, \dots, I_{M-1}, I_M\}$ ;  $L_{\text{lef}}$ 与 $PZ^*$ 构成的交点序列为 $\{\Psi_0, \Psi_1, \dots, \Psi_{M-1}, \Psi_M\}$ ;右侧区域 $\mathcal{R}_{k2}$ 中, $L_{\text{rig}}$ 与 $\mathcal{R}_{k2}$ 边界构成的交点序列为 $\{J_0, J_1, \dots, J_{N-1}, J_N\}$ ;  $L_{\text{rig}}$ 与 $PZ^*$ 构成的交点序列为 $\{\Phi_0, \Phi_1, \dots, \Phi_{N-1}, \Phi_N\}$ ,形成路径点序列如下。

区域 $\mathcal{R}_{k1}$ 搜索路径为 $S_{\Phi-P}: \Phi_N \rightarrow J_N \rightarrow J_{N-1} \rightarrow \Phi_{N-1} \rightarrow \Phi_{N-2} \rightarrow J_{N-2} \rightarrow \dots \rightarrow \Phi_1 \rightarrow J_1 \rightarrow J_0 \rightarrow \Phi_0 \rightarrow P$ 。

区域 $\mathcal{R}_{k2}$ 搜索路径为 $S_{P-\Psi}: P \rightarrow I_0 \rightarrow \Psi_0 \rightarrow \Psi_1 \rightarrow I_1 \rightarrow I_2 \rightarrow \Psi_2 \rightarrow \Psi_3 \rightarrow I_3 \rightarrow I_4 \rightarrow \dots \rightarrow I_M \rightarrow \Psi_M$ 。

最后该子区域的覆盖搜索路径为 $S_{P-\Psi} + S_{\Phi-P}$ 。其他子区域形状通过子区域内 $R$ 顶点数量, $R$ 顶点位于子区域的位置, $P$ 点与子区域内顶点位置关系分解,且均可由此3种情况组合而成。

对于存在显著空洞的区域,由上文定义每个 $P_{\text{TS}}$ 的目标搜索区域 $R$ 为其Voronoi单元与空洞最大内接圆外的交集,将 $P_{\text{TS}}$ 作为目标区域的网心,此时网心在区域内,靠近 $P_{\text{TS}}$ 的圆边界可近似看成一条直线,子区域 $R$ 内的情况可分为远端不包含凸顶点,和包含凸顶点两种,可由图4中情况组合而成,最终生成的覆盖路径会呈现出数量为保留空洞数量的若干张以Voronoi单元脊线为分隔的完整的“蛛网”,每架无人机的搜索路径需首先执行 $P \rightarrow P_{\text{TS}}$ 再执行各自的区域覆盖路径。

至此,端到端仿蛛网无人机区域覆盖协同搜索路径优化方法即可实现输入无人机资源参数、搜索任务和基站位置参数,输出每辆无人机的均衡、灵活的闭环覆盖搜索路径,为无人机自主搜索执行提供引导航路。

## 4 试验与分析

### 4.1 端到端的深度学习无人机协同搜索数量资源配置试验与分析

为验证本文所提的端到端无人机覆盖搜索数量资源配置网络在配置方案、求解时间、网络结构策略方面的优越性,本节设置3个对比算法,即:深度学习网络结构相同的混合损失单步强化学习网络、网络结构相同但损失各部分采用线性组合的深度学习网络以及遗传算法,从多个维度分析评估。

(1)由于资源配置问题中,配置方案确定,任

务即为结束,与单步强化学习的特点较为契合。本节用于对比的单步强化学习网络采用和深度学习相同的特征提取和动作输出网络结构,加入基于蒙特卡洛的专家动作模仿损失形成混合损失形式,基于Critic的评估来优化策略的同时,利用专家的先验知识来引导Actor的学习,以实现公平性的对比设置。

混合损失单步强化学习的状态  $W_{state}$  采用在深度学习网络输入最后一列补充当前网络  $N_T$  个目标区域的无人机配置数量方案构成,维度为  $N_T \times 5$ ,并随着网络动作输出的更新而更新作为Critic网络的输入。增加Critic网络,其特征提取层增加数量配置方案特征提取模块,通过2层线性层将数量配置方案特征提取与图2中其他模块融合。

Actor的输入与本文所提深度学习网络维度形式一致,网络损失由两部分构成:策略梯度损失和专家模仿损失,并通过动态权重平衡

$$L_{policy} = -\ln(W_{act}|W_{state}) [W_{reward} - C(W_{state})] \quad (22)$$

$$L_{Actor} = L_{policy} + \lambda_{imi} L_{CE} \quad (23)$$

$$L_{Critic} = \mathbb{E}[W_{reward}, C(W_{state})] \quad (24)$$

式中:  $W_{act}$  为网络动作输出;  $L_{policy}$  为策略梯度损失,将即时奖励与价值估计的差值作为单步优势估计,通过最大化带优势加权的动作对数概率优化策略;  $C(W_{state})$  为Critic网络的价值估计,Critic网络通过均方误差优化价值估计与真实奖励  $W_{reward}$  的差距;  $\lambda_{imi}$  为专家指导权重,训练、前、中后3段,设置1到0.3;  $\mathbb{E}(\cdot)$  为求解均方差运算。

(2)为验证本文所提的深度学习网络在损失设计上的有效性和必要性,设计同样网络结构的深度学习网络,仅以线性组合的方式构造网络损失,表示为

$$L_{Actor}^{linear} = L_{ent} + L_{reward} + L_{CE} + \lambda_{ratio} L_{ratio} \quad (25)$$

本节测试验证面向中小型区域的精细化覆盖搜

索,网络输入训练数据集的无人机参数采用限定范围内随机生成,搜索区域与基站位置参数采用随机生成方式,结合商业无人机的续航时间  $T_u$  规定范围1 800~2 400 s,调试及起降总时间等  $T_u^{inv}$  设定范围360~800 s,俯视摄像头视野角度  $60^\circ$ ;结合精细化覆盖搜索场景要求,设定无人机飞行高度10~50 m,匀速飞行速度  $16.7 \text{ m}\cdot\text{s}^{-1}$ ,无人机总数为80架。

3种网络训练输入均从基于遗传算法求解的数据集里批量选择500个,采用蒙特卡洛专家指导,迭代2 000次,初始学习率一致,目标函数为总代价函数负值。为防止网络不收敛,单步强化学习网络训练过程不增设数据替换。线性损失组合的深度学习网络增设数据滚动更新,2种对比算法的学习率不随训练轮数的增加而改变。

图5给出了3种网络训练时平均目标函数的迭代曲线,纵轴为目标函数相反数,数值越小方案越优。图5(a)为本文网络的优化曲线:前期快速收敛,数据集更新带来的波动可迅速回落;中期整体平稳,小幅波动后快速恢复;后期关注细节特征,经短暂波动后平稳收敛至最优。图5(b)为同结构线性损失组合网络曲线:前期波动下降,中期收敛至次优解,后期大幅波动后仍停留在局部最优,主要是因为线性损失难以同时平衡动作模仿与目标优化,最终收敛于局部最优。图5(c)为混合损失单步强化学习曲线:前期剧烈波动下降,中期持续偏离最优,后期在波动中收敛至次优解。对比可知,相同结构下,本文采用的指数型损失组合在收敛速度、训练稳定性和优化效果上优势显著,能更好地关联各损失项,使得网络在学习专家动作概率分布的同时,兼顾目标函数的优化。

将训练好的3种网络进行无人机数量配置效果的对比试验,设置P点最大可分配无人机总数为80架,一次性输出10个目标搜索区域的无人机数量配置方案。设置GA初始解一个目标区域最多分配20架




图5 目标函数网络优化迭代曲线对比


Fig. 5 Comparison of objective function iteration curves for network optimization

无人机,以减少其初始可行解生成的时间,种群数为20,迭代50次或至收敛。对4种算法随机输入相同的任务区域参数和无人机参数,以目标函数值,配置方案求解时间,方案与区域特征适配程度为对比评价标准,对比试验测试105次得到稳定的试验结果,并统计各项指标平均值,结果见表1,试验结果对比曲线如图6~8所示。


如图6(a)所示,本文方法的目标函数统计曲线与GA算法基本一致。其平均目标函数值为

表1 无人机协同覆盖搜索资源配置指标对比

resource allocation indicators			
无人机资源配置求解方法	目标函数平均值	求解时间/ms	策略均衡方差
资源配置深度学习网络	-0.215 0	3.9	0.000 12
遗传算法	-0.221 0	2 927.7	0.000 78
混合损失单步强化学习网络	-0.626 6	4.1	0.000 41
线性损失组合深度学习网络	-0.495 0	4.0	0.000 04




(a) 深度学习、GA及单步强化学习目标函数对比



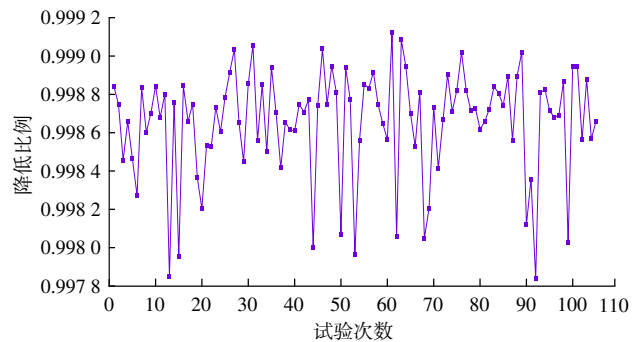
(b) 深度学习与同结构线性损失网络目标函数对比

图6 无人机配置方案目标函数值统计对比

Fig. 6 Statistical comparison of objective function values for UAV configuration schemes



(a) 神经网络策略求解时间对比



(b) 深度学习与遗传算法求解时间对比

图7 无人机配置方案求解时间对比

Fig. 7 Comparison of solution times for UAV configuration schemes




图8 无人机配置方案均衡性方差对比

Fig. 8 Statistical comparison of balance variance for UAV configuration schemes

-0.215 0,GA 算法为-0.221 0,二者基本持平,且本文方法在部分试验中更优。该网络采用蒙特卡洛变异训练,每轮专家策略优于或等效于GA,继承了其优良的优化性能。而混合损失单步强化学习网络收敛于次优解,目标函数显著偏低。图6(b)中,本文网络与同结构线性损失网络在部分测试中结果相近,但后者约14%的样本出现明显偏离,说明其未学到完整的资源配置策略,仅适用于部分场景,进一步验证了本文损失函数设计的有效性。

在配置方案求解时间方面,深度学习方法平均求解时间为3.9 ms,混合损失的单步强化学习方法

的平均求解时间为4.1 ms,线性损失的深度学习网络平均求解时间为4.0 ms,且如图7(a),3种网络的策略求解时间基本相近。如图7(b),本文所提深度学习方法相比遗传算法平均求解时间2.927 7 s大幅减少了99.87%,在继承GA优秀的求解优化能力的同时,显著的弥补了GA求解时间过长的短板。

在配置方案均衡性分析中,线性损失组合深度学习网络的输出偏差显著、策略不完备,因此仅对比其余3种方法。图8统计了各目标区域无人机配置数量与面积比例的方差,结果显示:遗传算法的平均方差为0.000 78,本文深度学习方法为0.000 12,混合损失单步强化学习为0.000 41,本文所提深度学习方法的配置方案均衡性相比GA提高84.62%。究其原因,遗传算法本质是优化后的“枚举”方法,以整体优化目标函数为导向,不会注重各区域的任务特征;而本文网络通过多层特征提取与融合,能够捕捉区域与无人机参数间的复杂非线性关系,同时,本文网络在训练中采用基于遗传算法并经蒙特卡洛变异修正的专家指导,兼顾了全局目标优化与区域分配均衡性。这表明该网络并非简单模仿遗传算法,而是基于GA策略的映射关系下,形成了更均衡的资源配置策略。

综上,试验结果充分证明了提出的需求层端到端深度学习无人机资源配置方法在目标函数优化、计算效率以及无人机配置均衡性方面的综合优势。该方法能够在保证可靠性的前提下实现快速、稳定、均衡且高效的多无人机协同配置,为多目标的区域覆盖搜索任务提供了一种有效的资源配置解决方案,也为搜索执行层提供最优的可靠资源配额预算。

#### 4.2 端到端仿蛛网无人机区域覆盖协同搜索路径优化试验与分析

为验证本文所提的搜索执行层无人机仿蛛网区域协同覆盖搜索路径优化方法的均衡性、灵活性等方面的性能,设置区域基站 $P(0,0)$ ,作为无人机的起降、回收枢纽。设置目标覆盖区域I由顶点 $Z_1(150.0, 800.0)$ 、 $Z_2(250.0, 1250.0)$ 、 $Z_3(1151.7, 1092.4)$ 、 $Z_4(1350.0, 180.0)$ m,构成的凸多边形;凸多边形目标覆盖区域II的顶点为 $Z_1(-50.0, 1200.0)$ m、 $Z_2(3200.0, 180.0)$ m、 $Z_3(2200.7, 3000.4)$ m、 $Z_4(480.6, 2800.4)$ m。

试验以精细化覆盖搜索场景下多无人机协同覆盖搜索路径规划结果为研究对象,设置“Z”字型水平线路程均匀切分方法为对比方法,即通过水平等距离航线切分目标搜索区域,并将区域内路径按照近似等路程长度的方式分配给执行任务的无人机。仿

蛛网结构协同划分方法采用等角度间隔的子区域切分模式,对比分析仿蛛网结构协同划分方法与水平线路程均匀切分2种路径规划方法的性能差异。本节试验设置无人机群为同质无人机群,俯视摄像头视野角度 $60^\circ$ ,匀速飞行速度为 $16.7\text{ m}\cdot\text{s}^{-1}$ ,针对区域I的无人机续航设置为1800 s,设定无人机飞行高度17.32 m,单个无人机视野角度宽度为20 m;对于较大面积的区域II,设定无人机飞行高度为26 m,无人机续航设置为2400 s,无人机视野宽度为30 m。

试验变量设置为无人机数量(区域I测试4、6、8、12架,区域II测试17、26架),量化评估选取核心优化目标:①子区域质心与 $P$ 平均距离 $\bar{D}_p$ ;②子区域质心与搜索路径中点平均距离 $\bar{D}_r$ ;③子区域质心与搜索路径中点距离方差 $V_{D_r}$ 。

部分子区域划分与协同路径规划结果如图9、10所示,评价指标数值见表2。

在不同无人机数量下,仿蛛网结构协同划分均优于水平线均匀切分方法:区域I中,4架无人机时,仿蛛网结构子区域几何中心与 $P$ 点的平均距离较水平线等覆盖路程切分降低1.62%,6架时降低2.28%,8架时降低2.43%,12架时降低2.40%;区域II中,17架无人机时,仿蛛网结构子区域几何中心与 $P$ 点的平均距离较水平线等覆盖路程切分降低0.90%,26架时降低0.88%,且在区域I、II中,随无人机数量增加,仿蛛网结构的路径规划结果在 $\bar{D}_p$ 指标上均有所下降,同时均优于对比方法且优势略有扩大,说明其在多无人机任务分区中,能更合理平衡子区域与基站的空间分布,强化二者空间关系,提升无人机从基站到达子区域的速度。

覆盖搜索路径中点与子区域几何中心的平均距离,可直观反映路径对目标区域的聚焦能力与空间匹配度。表2中,仿蛛网结构的平均距离显著低于水平线等覆盖路程切分。区域I中,4架无人机时,仿蛛网结构的平均距离较水平线切分降低31.06%,6架时差距扩大至50.99%,8架时差距达79.97%,12架时差距达82.82%。区域II中,17架无人机时,仿蛛网结构的平均距离较水平线切分降低76.16%,26架时差距为73.44%。结合路径规划可见:仿蛛网结构通过放射状与环状路径协同设计,能更精准覆盖子区域核心;而水平线均匀切分因路径方向单一,易导致部分子区域质心与路径中点偏离较远。

从子区域几何中心与搜索路径中点距离的方差来看,仿蛛网结构规划方法的稳定性优势进一步得

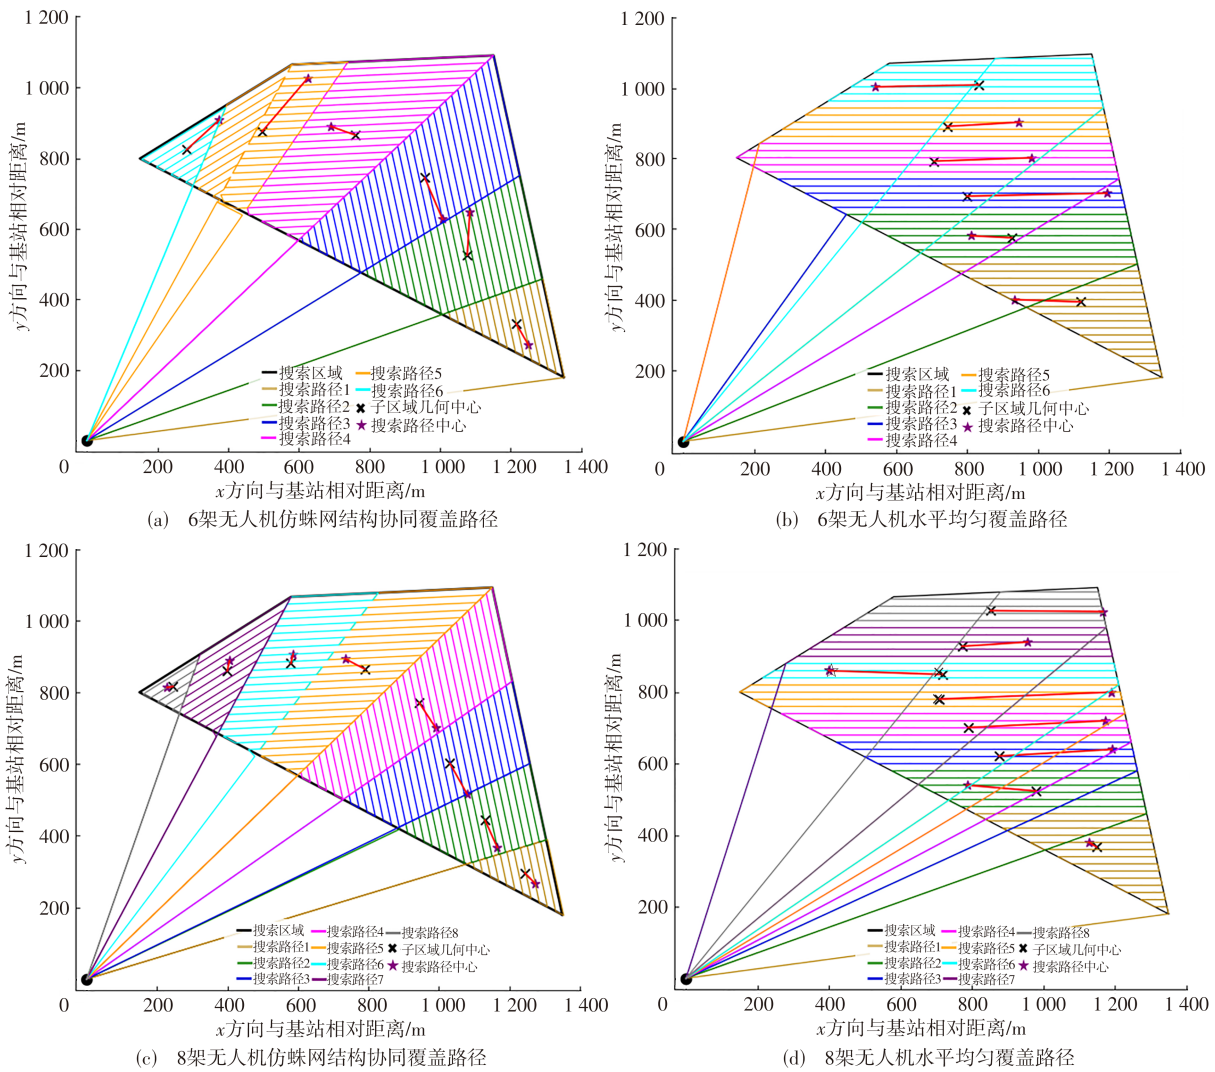


图9 区域I无人机协同覆盖搜索路径规划结果对比

Fig.9 Comparison of UAV cooperative coverage search path planning results in area I

到验证:其方差始终维持在较低水平,且随无人机数量和密度增加整体呈下降趋势(区域I内6架无人机的方差较4架时降低27.74%,区域I内8架无人机的方差较4架时降低67.14%,12架无人机的方差较4架时降低84.62%,区域II内26架无人机较17架时方差降低13.73%),说明多无人机协同场景下,该方法的覆盖均衡性持续优化。

反观水平线等覆盖路程切分方法,其方差显著偏高,仿蛛网结构规划方法在均衡性上相比之提高75.45%以上:区域I内,4架无人机时,方差是仿蛛网结构的8.38倍;增加至8架无人机,方差为仿蛛网结构的20.40倍。12架无人机,方差为仿蛛网结构的39.46倍。区域II内,17架无人机,方差为仿蛛网结构的5.79倍,26架时,方差为仿蛛网结构的4.07倍。这一结果与路径示意图特征相符,水平线切分的“条带状分区”无法灵活适配目标区域,固定方向的路径

易导致子区域覆盖偏差分散;而仿蛛网结构的多方向路径分布能有效降低误差,且其子区域几何中心、搜索路径中点的空间分布,与目标搜索区域的几何形状特征保持一致。

同时,在区域I、II的试验中,子区域的几何特征会受到区域内是否包含整个搜索区域的边界顶点而一定程度上影响子区域的性能指标,但是随着无人机规模增加,仿蛛网结构的路径规划结果在优化目标上整体呈现下降趋势,表示随着无人机规模增加,仿蛛网覆盖路径规划优化方法优化能力越显著;其次,水平线切分方法的搜索路径中心空间分布杂乱,既无法契合目标区域几何特征,还会出现各子区域间无人机搜索路径重叠的情况,大幅增加实际轨迹规划中无人机航线冲突的风险;而仿蛛网结构的子区域相互独立,无跨区域搜索路径,能为实际轨迹规划降低碰撞风险,实现更均衡的覆盖效果。

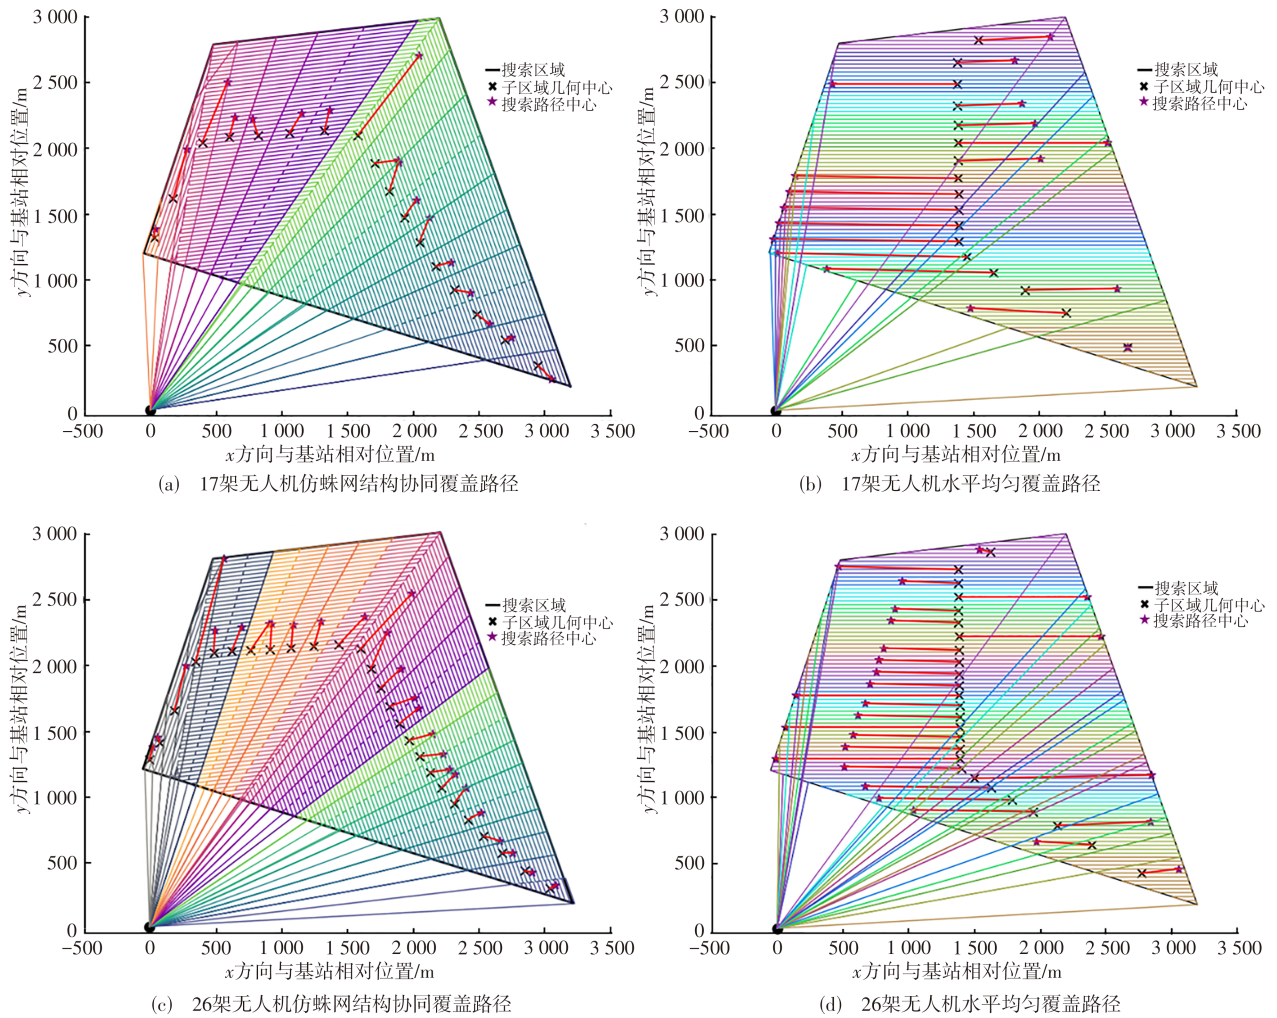


图 10 区域 II 无人机协同覆盖搜索路径规划结果对比

Fig.10 Comparison of UAV cooperative coverage search path planning results in area II

表 2 无人机协同覆盖搜索路径规划指标

Table 2 Indicators for UAV cooperative coverage search path planning

区域	无人机数量/架	协同覆盖搜索路径规划方法	$\bar{D}_p/m$	$\bar{D}_R/m$	$V_{D_c}$
区域 I	4	仿蛛网结构规划方法	1 120.57	114.55	2 568.19
		水平线等路程切分方法	1 139.01	166.16	21 509.31
	6	仿蛛网结构规划方法	1 117.10	119.83	1 855.76
		水平线等路程切分方法	1 143.21	244.51	7 960.78
	8	仿蛛网结构规划方法	1 116.48	55.57	843.90
		水平线等路程切分方法	1 144.28	277.41	17 215.31
区域 II	12	仿蛛网结构规划方法	1 116.03	53.46	394.97
		水平线等路程切分方法	1 143.45	311.25	15 586.94
	17	仿蛛网结构规划方法	2 359.67	217.77	30 133.14
		水平线等路程切分方法	2 381.08	913.60	174 361.70
	26	仿蛛网结构规划方法	2 358.82	211.52	25 996.86
		水平线等路程切分方法	2 379.68	796.34	105 881.48

综上所述,试验结果充分证明了需求层深度学习无人机数量资源配置方法在目标函数优化、计算效率以及无人机配置均衡性方面的综合优势。该方法能够在保证可靠性的前提下实现快速、稳定且高效的

多无人机协同数量配置,为多目标的区域覆盖搜索任务提供了一种有效的资源配置解决方案;执行层仿蛛网结构协同路径规划方法也在多无人机协同覆盖搜索任务中表现出显著优势:通过适配子区域

与基站的空间关联,有效增强了出发位置与目标区域的响应能力;灵活方向路径设计能精准聚焦子区域质心,基站与搜索路径中心,增强搜索路径与目标区域的适配性,更适用于多无人机复杂区域覆盖任务,其性能随无人机数量增加呈优化趋势,为大规模无人机群协同搜索提供了高效可行的路径规划方案。

## 5 结 语

(1)本研究围绕多无人机协同覆盖搜索的核心需求,以“端到端双层规划”为核心框架破解数量配置与路径规划协同难题:第1层聚焦无人机资源配置优化,结合多目标总代价与可靠性约束构建模型,通过“深度学习+启发式优化算法融合”设计高效求解网络,实现从区域特性、无人机参数到多区域最优数量方案的端到端输出;第2层侧重覆盖路径规划的灵活性、均衡性,以仿生学为思路提出仿蛛网协同搜索路径优化方法,自适应适配多无人机区域覆盖需求。本文所提方法通过与启发式算法、同结构线性损失组合的深度学习、混合损失单步强化学习、水平路径等路程切分方法的对比试验,从优化能力、求解快速性、策略均衡性验证资源配置方法的优势,从路径均衡性、规划灵活性、空间适配性证实仿蛛网路径优化的价值,充分证实端到端双层规划方法的技术先进性。

(2)本文研究具有广泛实用价值。在工程应用层面,可落地于城市巡检、应急救援、安保巡逻等多区域覆盖搜索场景,依托端到端框架快速输出多区域最优无人机数量与协同覆盖路径,在保障全覆盖的同时控制能耗与故障风险,且求解高效、响应即时,满足应急场景时效性需求。在技术体系层面,构建“需求层面资源配置优化-执行层面路径规划优化”的端到端双层技术范式,为无人机群协同覆盖搜索提供技术参考,为后续研究奠定方法论基础。

(3)本文资源配置网络采用单步强化学习结构,在配置方案的均衡性以及目标优化的逻辑上具有较强潜力,未来可以继续借鉴强化学习的逻辑思想,深入优化网络结构、训练逻辑和损失设计。

(4)在端到端双层规划方法的基础上,应结合目标搜索区域空间结构与历史数据中的区域先验风险概率分布,基于现有数量配置方案与路径规划结果,提出面向日常巡检与高风险区域应急响应的无人机覆盖搜索路径规划与优化调度方法,进一步拓展端到端框架的场景适配能力。

## 参 考 文 献 :

### Reference :

- [ 1 ] 陈 聪,张国惠,马晓磊,等.利用大数据挖掘和知识发现技术辅助智慧城市发展[J].大数据,2016,2(3):39-48.  
CHEN Cong, ZHANG Guo-hui, MA Xiao-lei, et al. Big data analysis and knowledge discovery for smart city development enhancement [J]. Big Data Research, 2016, 2(3): 39-48.
- [ 2 ] 徐志刚,申丹丹,高 赢,等.基于文献计量的综合交通研究综述[J].交通运输工程学报,2025,25(2):37-60.  
XU Zhi-gang, SHEN Dan-dan, GAO Ying, et al. Review of multimodal transport research based on bibliometrics[J]. Journal of Traffic and Transportation Engineering, 2025, 25(2): 37-60.
- [ 3 ] 李晨玮,周建山,田大新,等.立体交通系统通感算一体化关键技术[J].移动通信,2024,48(3):14-20.  
LI Chen-wei, ZHOU Jian-shan, TIAN Da-xin, et al. Key technology for integrated communication sensing and computing in three-dimensional transportation system[J]. Mobile Communications, 2024, 48(3): 14-20.
- [ 4 ] 张洪海,夷 珈,李 珊,等.低空空域容量评估研究综述[J].交通运输工程学报,2023,23(6):78-93.  
ZHANG Hong-hai, YI Jia, LI Shan, et al. Review on research of low-altitude airspace capacity evaluation [J]. Journal of Traffic and Transportation Engineering, 2023, 23(6): 78-93.
- [ 5 ] 刘文学,侯 聪,杨亚联,等.面向城市空中交通的电动飞行汽车关键性能指标分析[J].机械工程学报,2024,60(22): 257-275.  
LIU Wen-xue, HOU Cong, YANG Ya-lian, et al. Analysis of key performance metrics of electric flying cars for urban air mobility [J]. Journal of Mechanical Engineering, 2024, 60(22): 257-275.
- [ 6 ] 杨 成,高建勋.基于故障树分析法的无人机可靠性分析[J].环境技术,2022,40(6):122-126.  
YANG Cheng, GAO Jian-xun. Reliability analysis of UAV based on fault tree analysis [J]. Environmental Technology, 2022, 40(6): 122-126.
- [ 7 ] DAI X H, DUO B, YUAN X J, et al. Energy-efficient UAV communications: A generalized propulsion energy consumption model [J]. IEEE Wireless Communications Letters, 2022, 11(10): 2150-2154.
- [ 8 ] BLAKESLEY A, ANVARI B, KROLL J, et al. Minimum energy route optimisation of a quad-copter UAV with landing incentivisation[C]//IEEE. 2022 IEEE International Conference on Intelligent Transportation Systems. New York: IEEE, 2022: 2300-2306.
- [ 9 ] 欧阳权,徐罗旻,杨继阳,等.基于能耗优化的四旋翼无人机航迹规划:分段式高斯伪谱法[J].电光与控制,2025,32(1):1-7.  
OUYANG Quan, XU Luo-min, YANG Ji-yang, et al. Energy-efficient trajectory planning for quadrotor UAVs: A segmented Gaussian pseudospectral method [J]. Electronics

- Optics & Control, 2025, 32(1): 1-7.
- [10] IM H S, KIM K Y, LEE S H. Trajectory optimization for cellular-enabled UAV with connectivity and battery constraints [J]. IEEE Transactions on Vehicular Technology, 2025, 74(11): 17812-17828.
- [11] FENG Q, LIU M, DUI H Y, et al. Importance measure-based phased mission reliability and UAV number optimization for swarm [J]. Reliability Engineering & System Safety, 2022, 223: 108478.
- [12] ALZENAD M, EI-KEYI A, LAGUM F, et al. 3-D placement of an unmanned aerial vehicle base station (UAV-BS) for energy-efficient maximal coverage [J]. IEEE Wireless Communications Letters, 2017, 6(4): 434-437.
- [13] HUANG H L, HUANG C, MA D Z. A method for deploying the minimal number of UAV base stations in cellular networks [J]. IEEE/CAA Journal of Automatica Sinica, 2020, 7(2): 559-567.
- [14] SABZEHALI J, SHAH V K, FAN Q, et al. Optimizing number, placement, and backhaul connectivity of multi-UAV networks [J]. IEEE Internet of Things Journal, 2022, 9(21): 21548-21560.
- [15] 沈东,魏瑞轩,祁晓明,等.基于MTPM和DPM的多无人机协同广域目标搜索滚动时域决策[J].自动化学报,2014,40(7):1391-1403.  
SHEN Dong, WEI Rui-xuan, QI Xiao-ming, et al. Receding horizon decision method based on MTPM and DPM for multi-UAVs cooperative large area target search [J]. Acta Automatica Sinica, 2014, 40(7): 1391-1403.
- [16] 文超,董文瀚,解武杰,等.基于回访机制的无人机集群分布式协同区域搜索方法[J].航空学报,2023,44(11):253-270.  
WEN Chao, DONG Wen-han, XIE Wu-jie, et al. Distributed cooperative area search method for UAV swarms based on revisit mechanism [J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(11): 253-270.
- [17] 吴韬,陈思恒,罗泽霖,等.基于概率图的多无人机覆盖搜索路径规划方法[J].信息对抗技术,2025,4(4):30-42.  
WU Tao, CHEN Si-heng, LUO Ze-lin, et al. Path planning method for multi-UAV coverage search based on probability graph [J]. Information Countermeasure Technology, 2025, 4(4): 30-42.
- [18] ARAÚJO J F, SUJIT P B, SOUSA J B. Multiple UAV area decomposition and coverage [C]//IEEE. 2013 IEEE Symposium on Computational Intelligence for Security and Defense Applications. New York: IEEE, 2013: 30-37.
- [19] CHEN Y Y, ZHANG H D, XU M. The coverage problem in UAV network: A survey [C]//IEEE. Fifth International Conference on Computing Communications and Networking Technologies. New York: IEEE, 2014: 1-5.
- [20] LIU Z, GAO X, FU X. A cooperative search and coverage algorithm with controllable revisit and connectivity maintenance for multiple unmanned aerial vehicles [J]. Sensors, 2018, 18(5): 1472.
- [21] 刘全义,刘继豪,艾洪舟,等.基于混合策略的复杂山区覆盖搜索方法[J].清华大学学报(自然科学版),2026,66(2): 233-240.  
LIU Quan-yi, LIU Ji-hao, AI Hong-zhou, et al. Coverage search methods for complex mountainous areas using hybrid strategy [J]. Journal of Tsinghua University (Science and Technology), 2026, 66(2): 233-240.
- [22] 陈佳雨,李文,李泰融,等.基于Q-Learning的双无人机覆盖路径规划[J].遥测遥控,2025,46(4):96-104.  
CHEN Jia-yu, LI Wen, LI Tai-rong, et al. Q-learning based dual drone coverage path planning [J]. Journal of Telemetry, Tracking and Command, 2025, 46(4): 96-104.
- [23] 吴青坡,周绍磊,尹高扬,等.多无人机协同区域覆盖搜索算法的改进[J].光电与控制,2016,23(1):80-84.  
WU Qing-po, ZHOU Shao-lei, YIN Gao-yang, et al. Improvement of multi-UAV cooperative coverage searching method [J]. Electronics Optics & Control, 2016, 23(1): 80-84.
- [24] VINH K, GEBREYOHANNES S, KARIMODDINI A. An area-decomposition based approach for cooperative tasking and coordination of uavs in a search and coverage mission [C]//IEEE. 2019 IEEE Aerospace Conference. New York: IEEE, 2019: 1-8.
- [25] 戴健,许菲,陈琪锋.多无人机协同搜索区域划分与路径规划[J].航空学报,2020,41(增1):149-156.  
DAI Jian, XU Fei, CHEN Qi-feng. Multi-UAV cooperative search area division and path planning [J]. Acta Aeronautica et Astronautica Sinica, 2020, 41(S1): 723770.
- [26] 李道文,杨鑫松,孙亚平,等.多无人机协同区域覆盖航道规划[J/OL].控制工程,2025,https://doi.org/10.14107/j.cnki.kzgc.20240891.  
LI Dao-wen, YANG Xin-song, SUN Ya-ping, et al. Cooperative area coverage route planning for multi-UAVs [J/OL]. Control Engineering, 2025, https://doi.org/10.14107/j.cnki.kzgc.20240891.
- [27] 卓春晖,蒋平,王昌河,等.蛛网结构性能及其适应性[J].四川动物,2006,25(4):898-902.  
ZHUO Chun-hui, JIANG Ping, WANG Chang-he, et al. Structure and mechanical property of spider's web and their adaptations [J]. Sichuan Journal of Zoology, 2006, 25(4): 898-902.
- [28] 张学阳,曾培煌.蜘蛛网结构性能研究[J].数学建模及其应用,2013,2(1):34-38.  
ZHANG Xue-yang, ZENG Pei-huang. Study on structure and properties of spider web [J]. Mathematical Modeling and Its Applications, 2013, 2(1): 34-38.