

面向无人机-地面基站协同通感一体化系统的 多维资源联合分配研究

曾海勇^{1,2}, 黄媛艳^{1,2}, 魏忠祥³, 蒋春生^{1,2}, 朱 旭⁴, 曹 杰^{4*}

(1. 广西类脑计算与智能芯片重点实验室(广西师范大学), 广西桂林 541004; 2. 广西师范大学电子与信息工程学院/集成电路学院, 广西桂林 541004; 3. 同济大学电子与信息工程学院, 上海 200092; 4. 哈尔滨工业大学(深圳)信息科学与技术学院, 广东深圳 518000)

摘 要: 针对低空经济背景下6G网络通信与感知融合的基础技术需求, 现有固定多基站协同通感一体化架构灵活性受限, 无人机通感一体化研究多为单基站独立运行, 缺少与地面基站的协同配合, 且空地协同场景下轨迹规划、用户调度与功率分配存在强耦合关系, 优化模型非凸且求解复杂。为此, 本文提出无人机-地面基站协同通感一体化传输架构及其多维资源联合分配和无人机轨迹优化方案。该架构利用无人机灵活机动特性, 与地面基站构建空地协同通信和感知一体化机制, 同步完成边缘用户通信服务与移动目标感知任务。本文以最小化系统总发射功率为优化目标, 在满足用户信干噪比与目标定位克拉美罗下界双重约束的前提下, 建立空地协同场景下包含无人机轨迹、用户调度、功率的多维资源联合优化模型。针对该非凸优化问题中离散调度、连续功率、动态轨迹三类变量深度耦合、难以直接联合求解的特点, 本文提出了基于深度强化学习的双层优化框架。外层采用深度确定性策略梯度算法, 依托连续动作空间优势迭代优化无人机飞行轨迹, 适配高移动性带来的动态拓扑变化; 内层利用半正定松弛技术, 将复杂非凸资源分配问题转化为可高效求解的半正定规划形式, 快速获得给定无人机位置下的联合用户调度和功率分配近似最优解。本文将内层资源优化得到的最小发射功率构造为奖励函数反馈至外层, 实现轨迹策略与资源分配的双向联动更新。该分层耦合设计既规避了全强化学习方案动作空间冗余、约束嵌入困难、训练波动明显的缺陷, 又弥补了传统数学规划方法对初始点敏感、易陷入局部最优的不足, 能够在动态场景下持续维持可行优化域。仿真结果表明, 所提空地协同通感一体化方案相较非协同方法可实现30%~36%的功耗节约, 同时本文提出的双层优化方案相较于全深度强化学习、固定轨迹方案功耗分别降低39%、17%。研究结果可为低空经济下空地协同通感一体化系统的轨迹设计与资源配置提供理论依据和技术参考。

关键词: 无人机-地面基站协同; 通感一体化; 深度强化学习; 多维资源联合分配; 轨迹设计; 低空经济

基金项目: 国家自然科学基金(No. 62301172, No. 62401182, No. U24A20296); 广东省国际科技合作项目(No. 2025A0505020024)

中图分类号: TN929.5; TN915.0

文献标识码: A

文章编号: 0372-2112(2026)06-2583-15

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20260170

Research on Joint Allocation of Multi-Dimensional Resources for UAV-Ground Base Station Coordinated Integrated Sensing and Communication Systems

ZENG Haiyong^{1,2}, HUANG Yuanyan^{1,2}, WEI Zhongxiang³, JIANG Chunsheng^{1,2}, ZHU Xu⁴, CAO Jie^{4*}

(1. Guangxi Key Laboratory of Brain-inspired Computing and Intelligent Chips, Guangxi Normal University, Guilin, Guangxi 541004, China;

2. School of Electronic and Information Engineering / School of Integrated Circuits, Guangxi Normal University, Guilin, Guangxi 541004,

China; 3. School of Electronic and Information Engineering, Tongji University, Shanghai 200092, China;

4. School of Information Science and Technology, Harbin Institute of Technology (Shenzhen), Shenzhen, Guangdong 518000, China)

Abstract: In view of the fundamental technical requirements for the integration of communication and sensing in 6G networks under the background of low-altitude economy, the existing fixed multi-base-station integrated sensing and communication (ISAC) architectures suffer from limited flexibility. Most current unmanned aerial vehicle (UAV)-enabled ISAC studies focus on independent operation without cooperation with ground-based stations. In addition, trajectory planning, user scheduling, and power allocation exhibit strong coupling in air-ground coordinated scenarios, resulting in non-convex and intractable optimization models. To address these issues, this paper proposes an air-ground coordinated ISAC transmis-

sion architecture consisting of UAVs and ground base stations, along with a joint multi-dimensional resource allocation scheme. Leveraging the flexible mobility of UAVs, the constructed architecture establishes an air-ground coordinated communication and sensing mechanism to simultaneously provide communication services for edge users and accomplish sensing tasks for moving targets. With the objective of minimizing the total system transmit power, a multi-dimensional joint optimization model involving UAV trajectory, user scheduling, and power allocation is formulated under the constraints of user signal-to-interference-plus-noise ratio (SINR) and target localization Cramér-Rao lower bound (CRLB). To handle the deeply coupled discrete scheduling, continuous power and dynamic trajectory variables that are difficult to solve jointly, a deep reinforcement learning-based two-layer optimization framework is proposed. In the outer layer, a deep deterministic policy gradient (DDPG) algorithm is adopted to iteratively optimize UAV flight trajectories in continuous action space, adapting to dynamic topological variations caused by high mobility. In the inner layer, semidefinite relaxation (SDR) transforms the non-convex resource allocation problem into a tractable semidefinite programming form, so as to efficiently obtain near-optimal solutions of joint user scheduling and power allocation under fixed UAV positions. The minimal transmit power obtained from inner-layer optimization is constructed as a reward function and fed back to the outer layer, realizing bidirectional interactive updating between trajectory strategies and resource allocation. This hierarchical coupling design avoids the drawbacks of pure reinforcement learning methods, such as redundant action space, difficult constraint embedding and unstable training. Moreover, it alleviates the sensitivity to initial values and local optimum defects of traditional mathematical optimization methods, maintaining feasible optimization domains in dynamic environments. Simulation results demonstrate that the proposed air-ground coordinated ISAC scheme achieves 30%~36% power consumption reduction compared with non-coordinated methods. Furthermore, the proposed two-layer optimization scheme reduces power consumption by 39% and 17% compared with the pure deep reinforcement learning scheme and fixed-trajectory scheme, respectively. This research provides a theoretical basis and technical reference for trajectory design and resource configuration of air-ground coordinated ISAC systems in low-altitude economy scenarios.

Keywords: UAV-ground BS coordination; integrated sensing and communication; deep reinforcement learning; multi-dimensional resource joint allocation; trajectory design; low-altitude economy

Foundation Item(s): National Natural Science Foundation of China (No.62301172, No.62401182, No.U24A20296); Guangdong International Science and Technology Cooperation Program (No.2025A0505020024)

0 引言

在低空经济等新兴应用驱动下,第六代移动通信技术向高频段和智能化演进^[1-3],频谱资源日益稀缺,传统的通信与感知功能分离模式已难以满足未来无线网络对频谱效率和多功能融合的需求。通感一体化(Integrated Sensing And Communication, ISAC)技术^[4-5]通过在同一硬件平台上共享频谱、射频前端与信号处理资源,实现通信与雷达感知功能的深度融合,成为6G网络的关键使能技术之一。ISAC技术不仅可显著提升频谱利用率,还能为智能交通、无人系统协同、环境监测等新兴应用提供一体化解决方案,具有重要的理论与实际应用价值^[6-7]。

早期的ISAC研究主要聚焦于单基站场景下的波形设计与波束成形优化^[8-9]。Hua等人^[10]针对通信与感知功能在单基站共存的场景,研究了最优发射波束成形策略,揭示了通信速率与感知精度之间的本质权衡关系。Behdad等人^[11]将下行通信与多基地感知相结合,提出了基于最大后验概率的联合检测技术。然而,受限于单一观测视角,单基站ISAC系统在覆盖范围、感知分集增益及功率效率方面存在固有局限,尤其在复杂非视距(NLoS)环境下难以同时保证可靠通

信与精确目标定位。为突破单站架构瓶颈,多基站协作ISAC框架成为研究热点^[12-13]。该架构通过协作多点(Coordinated Multi-Point, CoMP)传输技术^[14]将感知与通信任务分配至多个节点,在干扰管理和资源利用方面取得显著性能提升。协作ISAC架构具有显著优势:从传感角度来看,它们提供了更高的阵列增益和波形多样性;从通信的角度来看,它们能够实现更有效的干扰管理和资源利用^[15-17]。李培铭等人^[18]证明了基站间协调功率控制能够在最小化能耗的同时有效平衡双功能性能。Gao等人^[14]提出了协作定位与速率分裂多址接入相结合的帕累托优化框架。Dou等人^[19]通过多设备ISAC架构实现了感知质量与通信公平性的联合保障。Zhao等人^[20]通过联合收发器波束成形设计量化协作双基站场景中的基本性能权衡,提供了理论见解。尽管多基站协作可增强系统性能,但地面基站的固定部署特性限制了网络对突发业务或补盲场景的适应能力,在需要密集组网的区域会导致显著的基础设施成本上升。

无人机(Unmanned Aerial Vehicle, UAV)凭借其高机动性与易于建立视距(Line-of-Sight, LoS)链路的优势,为ISAC系统提供了新的解决思路^[21-22]。通过动态

调整位置,无人机可为通信用户和感知目标建立有利的信道条件,在临时活动、应急响应或地面基础设施受限区域具有特殊价值。然而,现有研究要么专注于纯通信场景而未集成感知能力^[23],要么仅考虑独立的无人机 ISAC 系统而缺少与地面基站的协同设计^[24],未能充分发挥空地基础设施的互补优势。无人机与地面基站的协同集成可构建立体通感一体化架构,将地面网络的可靠性与容量优势同空中平台的灵活性与视距特性有机结合,形成空地协作感知通信框架。然而,这类无人机-地面基站协同 ISAC 系统的综合优化问题仍大部分未被探索,特别是在双功能约束下如何协调空地节点的功率分配与无人机轨迹设计,尚缺乏系统性研究。

该问题面临诸多技术挑战。系统的通信性能,即用户信干噪比(Signal-to-Interference-plus-Noise Ratio,

SINR)与感知精度,即目标定位克拉美-罗下界(Cramér-Rao Lower Bound, CRLB)同时受发射功率与无人机位置的影响,导致资源分配与轨迹设计高度耦合,形成变量强耦合的复杂非凸优化问题。传统凸优化方法依赖问题结构的显式建模与松弛技巧,难以有效处理动态时变环境下的轨迹规划问题。深度强化学习(Deep Reinforcement Learning, DRL)为此提供了有前景的解决框架^[25-26]。DRL是无须环境的显式数学模型,通过与环境交互学习有效策略,特别适用于处理不确定性环境下的序贯决策问题。同时,考虑到无线通信资源与无人机机载能量的有限性,如何开发在满足双功能约束下高效运行的低复杂度资源分配算法,也是亟待解决的关键问题。为直观展示本文与现有代表性工作的差异,表1从系统架构、感知几何配置、协同机制等维度进行了系统对比。

表1 研究现状对比

Table 1 Comparison of research status

对比维度	文献[14]	文献[18]	文献[24]	本文
系统架构	多个地面基站+ISAC	多个地面基站+UAV用户+ISAC	单UAV空中基站+ISAC	地面基站+UAV空中基站+ISAC
UAV在系统中的角色	无UAV	UAV作为用户	UAV作为空中基站	UAV作为辅助通信发射节点+额外感知节点,与GBS协同服务边缘用户并共同感知目标
感知几何配置	多个固定地面站点形成协作定位/感知几何,几何关系基本固定	多个地面基站感知目标位置,感知几何主要由地面多小区基础设施决定	由单UAV轨迹塑造“移动观测几何”,但缺少地面锚点协同	GBS固定、UAV可机动,二者共同构成可重构分布式感知几何;UAV位置变化会同时改变通信链路与定位几何
协同机制	基于多BS协作、RSMA与直接定位的地面协同,重点在固定节点间干扰管理与定位性能权衡	多基站协作功率控制+UAV轨迹优化,重点在于平衡通信/感知性能与能耗	主要依靠UAV轨迹与带宽分配提升联合通信和定位性能	空地异构协同:GBS提供稳定覆盖与感知参考,UAV通过机动补盲并重构链路/感知几何;协同用户由GBS和UAV通过CoMP联合服务
优化变量	侧重多BS传输/接入相关变量的帕累托优化	基站协作功率控制+UAV用户轨迹	UAV轨迹+用户带宽分配,并考虑机载能量约束	用户调度+空地功率分配+UAV轨迹三者联合优化
核心约束与目标	强调通信-定位帕累托权衡	在满足UAV用户SINR和目标定位CRLB的条件下最小化基站能耗	在通信与感知间作权衡,并考虑UAV续航/能量约束	在满足用户SINR约束与目标定位CRLB约束下,最小化系统总发射功率
求解方法	帕累托优化框架	交替优化;对功率控制用SDR,对轨迹用连续凸近似	多阶段轨迹设计,并联合带宽配置	双层DRL-SDR框架:外层DDPG学习轨迹,内层SDR求联合用户调度与功率分配,并将内层结果反馈为奖励

由表1可见,现有代表性研究主要分为三类:一类侧重固定多基站协作ISAC,如文献[14],其优势在于多站协作带来的干扰管理与定位增益,但缺乏空中机动节点,难以适应低空动态补盲场景;一类考虑多小区协作与UAV相关优化,如文献[18],但其UAV主要作为通信用户而非空地协同的通感节点;另一类关注单UAV-ISAC轨迹设计,如文献[24],能够利用机动性改善通信与感知性能,但缺少地面基础设施协同

支撑。相比之下,本文研究的是一种无人机-地面基站空地异构协同ISAC架构:无人机既作为辅助通信节点,又作为额外感知节点,与地面基站共同构成立体分布式感知与协作传输系统;同时,本文进一步将用户调度、空地功率分配与无人机轨迹统一到同一优化框架中,并通过双层DRL-SDR闭环机制揭示轨迹设计与瞬时资源配置之间的深层耦合关系,从而体现出区别于现有工作的差异化贡献。上述差异化贡献

体现在三个层面:在物理机制上,空中机动节点会同时改变通信链路质量与分布式感知几何结构,使通信可靠性和定位精度共同随轨迹演化;在信息交互逻辑上,无人机轨迹、用户调度和功率分配不是串行独立决策,而是彼此影响、相互反馈的耦合闭环;在协同收益来源上,系统目标不再是单纯提升速率或降低某一侧功耗,而是在满足通信 SINR 约束与目标定位 CRLB 约束的前提下,实现空地节点多维资源的联合高效配置。

针对上述研究空白,本文提出了一种低空经济下的无人机-地面基站协同通感一体化系统,并研究多维资源联合分配和轨迹优化问题,主要贡献总结如下:

(1)提出了一种无人机-地面基站协同的通感一体化系统架构,并明确了其区别于现有固定多站协作 ISAC 和独立 UAV-ISAC 的协同机理。在该系统中,无人机与地面基站通过协同传输技术共同服务小区边缘用户,同时利用通信信号执行分布式的目标感知任务。以最小化系统总发射功率为目标,综合考虑通信用户的 SINR 需求与感知目标的 CRLB 精度要求,建立了无人机飞行轨迹与多维资源的联合优化模型。

(2)提出了面向强耦合非凸问题的双层闭环优化框架,有效解决了轨迹设计与资源分配的强耦合问题。外层采用深度确定性策略梯度(Deep Deterministic Policy Gradient, DDPG)算法在连续空间内自主学习无人机的飞行轨迹,内层利用半正定松弛(Semi-Definite Relaxation, SDR)技术求解每个时隙下的最优功率分配,并基于此提出联合用户调度和功率分配方案,通过将内层获得的用户调度和功率分配结果嵌入强化学习算法的奖励函数中,有效解决了轨迹变量与用户调度、功率等多维资源变量的强耦合问题,在保障通信和感知性能的同时显著降低了系统总功耗。

(3)通过仿真验证了所提架构与优化机制的性能优势,并从空间功率分布角度给出算法可解释性分析。本文构建了功率信息地图可视化分析方法,通过对比感知目标移动前后系统功率需求的空间分布变化与无人机轨迹的动态演化规律,为深度强化学习黑箱模型在轨迹优化中的决策提供了可解释性支撑,验证了算法能够自主识别并跟随低功耗区域的空间迁移。

1 系统模型与问题求解

1.1 系统模型

本文研究的无人机-地面基站协同通感一体化系统如图 1 所示,包含一个地面基站、一架无人机以及多个地面用户。该系统采用双功能信号设计方案,利

用通信信号同时完成目标感知任务,通过资源共享实现频谱高效利用。




图1 无人机-地面基站协同通感一体化系统模型

Figure 1 Model of UAV-ground base station coordinated ISAC system

系统架构由多个协同工作的组件构成。地面基站固定部署于位置 $\mathbf{L}_b = [x_b, y_b]^T$, 作为主要通信发射节点的同时兼具目标定位的感知功能。无人机在固定高度 H 飞行, 水平位置可根据优化需求动态调整, 既作为辅助通信发射节点, 又作为额外的感知节点, 与地面基站共同构成分布式感知几何配置。无人机的任务周期为 T , 为便于轨迹优化, 将其离散化为 N 个等长时隙, 每个时隙时长 $\Delta t = T/N$ 。在时隙 $n \in N = \{1, 2, \dots, N\}$, 无人机的水平位置记为 $\mathbf{q}[n] = [x_n, y_n]^T \in \mathcal{D}$, 其中 $\mathcal{D}$ 表示无人机可飞行区域。

系统服务 K 个地面用户, 根据与基站的距离和信道质量分为两类: K_c 个非协作用户位置靠近地面基站, 信道条件较好, 仅由地面基站服务; K_e 个协作用户位于小区边缘, 信道条件相对较差, 由地面基站和无人机通过协作多点传输技术联合服务。用户总数满足 $K = K_c + K_e$, 所有用户位于已知位置 $\mathbf{L}_i = [x_i, y_i]^T$, $i \in \mathcal{K} = \{1, 2, \dots, K\}$ 。系统同时对一个真实位置 $\mathbf{u}_i = [x, y]^T$ 未知的移动目标进行雷达感知。

该系统的核心挑战在于联合优化多维资源分配与无人机轨迹, 在满足通信服务质量需求和感知精度约束的前提下, 实现总发射功率最小化。下文将详细阐述构成优化框架基础的通信模型和感知模型。

1.1.1 通信模型

为简化实现, 假设所有节点均配置单天线。为在保证所有用户服务质量的同时提高频谱效率, 系统采用混合传输方案。地面基站采用非正交多址接入(Non-Orthogonal-Multiple-Access, NOMA)技术。NOMA 是一种面向异构信道与多用户差异化服务需求的多址接入技术, 通过发射端的功率域叠加设计和接收端的串行干扰消除设计, 实现功率域复用, 可在同一频谱资源上同时服务多个用户, 显著提升频谱利用效率。无人机通过时分多址(Time Division Multiple Access, TDMA)方式为协作用户提供增强服务。为控制

连续干扰消除 (Successive Interference Cancellation, SIC) 复杂度并限制误差传播, 每个 NOMA 组恰好包含两个用户: 一个协作用户和一个非协作用户, 从而在系统性能与实现复杂度间保持平衡。

对于无线信道, 采用两种不同的建模方式。在时隙 n , 从无人机到用户 i 在时隙 n 的空地信道遵循视距传播模型^[27]:

$$v_{i,n} = \sqrt{\frac{\beta_u}{H^2 + \|q[n] - L_i\|^2}} \quad (1)$$

其中, β_u 表示参考距离 $d_0=1$ m 处的信道功率增益。假设无人机移动引起的多普勒效应可被成功补偿, 地面基站到用户 i 的信道由大尺度路径损耗与瑞利小尺度衰落组成, 表示为

$$h_{i,n} = g_{i,n} \sqrt{\text{PL}(d_i)} \quad (2)$$

其中, $g_{i,n}$ 表示瑞利衰落信道增益, 服从复高斯分布, $\text{PL}(d_i)$ 表示路径损耗函数, d_i 表示地面基站与用户 i 间的距离。

信号接收和解码遵循非正交多址接入与连续干扰消除原理。设 U_n 表示在时隙 n 服务的用户集, 其中 CoMP 用户索引为 l , 非 CoMP 用户索引为 k 。用户 i 在时隙 n 处的接收信号表示为

$$y_{i,n} = \sum_{i \in U_n} h_{i,n} \sqrt{p_{i,n}} \theta_{i,n} + v_{i,n} \sqrt{p_{u,n}} \theta_{u,n} + z_{i,n} \quad (3)$$

其中, $\theta_{i,n}$ 和 $\theta_{u,n}$ 为单位能量的传输符号, $p_{i,n}$ 和 $p_{u,n}$ 分别表示地面基站为用户 i 分配的发射功率和无人机发射功率, $z_{i,n} \sim \mathcal{CN}(0, \sigma^2)$ 是加性高斯白噪声。

接收端执行连续干扰消除以解码叠加信号。由于协作用户距地面基站通常较远, 其从地面基站接收的信道条件较差, 因此在非正交多址接入组中被视为弱用户, 直接将非协作用户信号视为干扰进行解码。而非协作用户为强用户, 先解码并剔除协作用户信号, 再解调自身信号。记 $H_{i,n} = |h_{i,n}|^2$ 和 $V_{i,n} = |v_{i,n}|^2$ 分别表示来自地面基站和无人机的信道功率增益。非协作用户 k 经 SIC 后的信干噪比为

$$\gamma_{k,n} = \frac{H_{k,n} p_{k,n}}{H_{k,n} p_{l,n} + V_{k,n} p_{u,n} + \sigma^2} \quad (4)$$

其中, 无人机信号被视为干扰。协作用户 l 受益于地面基站与无人机的联合传输, 其信干噪比为

$$\gamma_{l,n} = \frac{H_{l,n} p_{l,n} + V_{l,n} p_{u,n}}{H_{l,n} p_{k,n} + \sigma^2} \quad (5)$$

该混合 CoMP-NOMA 方案实现了灵活的资源分配, 在提高频谱效率的同时, 通过协同传输为边缘用户提供可靠服务。

1.1.2 感知模型

在本文的通感一体化方案中, 通信信号被同时用于分布式雷达感知, 无需专用感知波形, 从而实现通

信与感知功能间的频谱共享。具体而言, 雷达处理在持续时间为 T 的区间上实现, 该区间足够长以保证能量积分充分且不同用户信号间满足正交性, 即 $\int_T |s_l(t)|^2 dt = T$ 以及 $\int_T s_l(t) s_k^*(t) dt = 0, \forall l \neq k$ 。

假设不同的通感一体化发射机和感知接收机在时间和频率上同步, 这是分布式雷达的常见假设, 在蜂窝网络中可通过回程链路的时钟校准或同步信号实现。基于上述假设, 第 n 个感知接收机的接收信号表示为

$$r_n(n) = \sum_{l=1}^L h_{l,k} \sqrt{p \alpha_{l,k}} s_m(n - \tau_{l,k}) + w_{l,k}(n) \quad (6)$$

其中, $w_{l,k}(t)$ 为感知接收机 k 处的零均值循环平稳复高斯噪声, 自相关函数为 $\sigma_w^2 \delta(\tau)$ 。系数 $h_{l,k}$ 包含了第 l 个通感一体化发射机与第 k 个感知接收机间雷达传播路径上目标雷达散射截面 (Radar Cross Section, RCS) 和路径损耗的综合影响。假设当 $l_1 \neq l_2$ 且 $k_1 \neq k_2$ 时, h_{l_1,k_1} 与 h_{l_2,k_2} 相互独立。

雷达信道 (l, k) 的传播延迟 $\tau_{l,k}$ 由双程距离决定:

$$\tau_{l,k} = \frac{D_{\text{tx}} + D_{\text{rx}}}{c} \quad (7)$$

其中, c 是电磁波传播速度。发射距离与接收距离分别为

$$D_{\text{tx}} = \sqrt{(x_l - x)^2 + (y_l - y)^2 + h_l^2} \quad (8)$$

$$D_{\text{rx}} = \sqrt{(x_k - x)^2 + (y_k - y)^2 + h_k^2} \quad (9)$$

其中, h_l 和 h_k 分别表示发射节点和接收节点的高度。当部署的节点是地面基站时, $h_l = h_k = 0$; 当部署的节点是无人机时, 由于其在预设高度执行任务, $h_l = h_k = H$ 。

对于目标定位, 本文采用 CRLB 分析来表征估计精度的理论极限。给定接收信号的条件概率密度函数为循环对称复高斯形式, 对目标位置 (x, y) 的 Fisher 信息矩阵 $\mathbf{F} \in \mathbb{R}^{2 \times 2}$, 利用链式法则分解为 $\mathbf{F} = \mathbf{D}^T \mathbf{J}(\boldsymbol{\tau}) \mathbf{D}$, 其中 $\mathbf{J}(\boldsymbol{\tau})$ 为关于传播时延的 Fisher 信息矩阵, 其第 (l, k) 对角元素为 $\zeta_m \alpha_{l,k} |h_{l,k}|^2 p_l[n]$, $\zeta_m = 8\pi^2 \beta_m^2 T / (\sigma_w^2 c^2)$, 其中 β_m 表示信号的有效带宽, 满足

$$\beta_m^2 = \frac{\int_{B_m} f^2 |S_m(f)|^2 df}{\int_{B_m} |S_m(f)|^2 df}, B_m \text{ 为信号 } s_m(t) \text{ 的带宽, } S_m(f) \text{ 为}$$

$s_m(t)$ 的频域变换。 $\mathbf{D}$ 为传播时延关于目标位置的 Jacobian 矩阵, 其元素由上述 D_{tx} 与 D_{rx} 的定义求偏导得到:

$$\begin{aligned} \frac{\partial \tau_{l,k}}{\partial x} &= \frac{1}{c} \left(\frac{x_l - x}{D_{\text{tx}}} + \frac{x_k - x}{D_{\text{rx}}} \right) \\ \frac{\partial \tau_{l,k}}{\partial y} &= \frac{1}{c} \left(\frac{y_l - y}{D_{\text{tx}}} + \frac{y_k - y}{D_{\text{rx}}} \right) \end{aligned} \quad (10)$$

将上述结果代入并展开, Fisher 信息矩阵 $\mathbf{F}$ 的三个独立元素分别为

$$[\mathbf{F}]_{11} = \sum_{l=1}^L \mathbf{p}_l [n] \sum_{k=1}^K \zeta_m \alpha_{l,k} |h_{l,k}|^2 \left(\frac{x_l - x}{D_{tx}} + \frac{x_k - x}{D_{rx}} \right)^2 \quad (11)$$

$$= \sum_{l=1}^L \mathbf{p}_l [n] \cdot \mathbf{g}_{a_l}$$

$$[\mathbf{F}]_{22} = \sum_{l=1}^L \mathbf{p}_l [n] \sum_{k=1}^K \zeta_m \alpha_{l,k} |h_{l,k}|^2 \left(\frac{y_l - y}{D_{tx}} + \frac{y_k - y}{D_{rx}} \right)^2 \quad (12)$$

$$= \sum_{l=1}^L \mathbf{p}_l [n] \cdot \mathbf{g}_{b_l}$$

$$[\mathbf{F}]_{12} = \sum_{l=1}^L \mathbf{p}_l [n] \sum_{k=1}^K \zeta_m \alpha_{l,k} |h_{l,k}|^2 \left(\frac{x_l - x}{D_{tx}} + \frac{x_k - x}{D_{rx}} \right) \times \left(\frac{y_l - y}{D_{tx}} + \frac{y_k - y}{D_{rx}} \right) = \sum_{l=1}^L \mathbf{p}_l [n] \cdot \mathbf{g}_{c_l} \quad (13)$$

上述三个元素分别对应感知几何系数 $\mathbf{g}_{a_l}$ 、 $\mathbf{g}_{b_l}$ 、 $\mathbf{g}_{c_l}$ 的定义,综合反映了第 l 个发射节点与所有 k 个接收节点构成的发射-接收对在 x 方向、 y 方向及交叉方向对目标定位精度的贡献,其大小由各节点与目标的空间几何关系共同决定。上述 Fisher 信息矩阵可紧凑表示为

$$\mathbf{F} = \sum_{l=1}^L \mathbf{p}_l [n] \begin{bmatrix} \mathbf{g}_{a_l} & \mathbf{g}_{c_l} \\ \mathbf{g}_{c_l} & \mathbf{g}_{b_l} \end{bmatrix} \quad (14)$$

目标位置 (x, y) 的 CRLB 矩阵^[28]为

$$\mathbf{C}_{x,y}(\mathbf{p}_n) = \mathbf{F}^{-1} = \left\{ \sum_{l=1}^L \mathbf{p}_l [n] \begin{bmatrix} \mathbf{g}_{a_l} & \mathbf{g}_{c_l} \\ \mathbf{g}_{c_l} & \mathbf{g}_{b_l} \end{bmatrix} \right\}^{-1} \quad (15)$$

利用 2×2 矩阵求逆公式,对 $\mathbf{C}_{x,y}(\mathbf{p}_n)$ 取迹,得到目标位置 x 方向与 y 方向均方误差下界之和:

$$\begin{aligned} \sigma_{x,y}^2(\mathbf{p}_n) &= \text{tr}(\mathbf{C}_{x,y}(\mathbf{p}_n)) = \frac{[\mathbf{F}]_{11} + [\mathbf{F}]_{22}}{\det(\mathbf{F})} \\ &= \frac{\sum_{l=1}^L \mathbf{p}_l [n] (\mathbf{g}_{a_l} + \mathbf{g}_{b_l})}{\det(\mathbf{F})} \end{aligned} \quad (16)$$

其中,行列式 $\det(\mathbf{F})$ 展开后可整理为 $\mathbf{p}_n^T \mathbf{A} \mathbf{p}_n$ 的二次型形式,矩阵 $\mathbf{A} = \mathbf{g}_a \mathbf{g}_a^T - \mathbf{g}_c \mathbf{g}_c^T$ 。令 $\mathbf{b} = \mathbf{g}_a + \mathbf{g}_b$, $\mathbf{g}_a = [\mathbf{g}_{a_1}, \mathbf{g}_{a_2}, \dots, \mathbf{g}_{a_L}]^T$, $\mathbf{g}_b = [\mathbf{g}_{b_1}, \mathbf{g}_{b_2}, \dots, \mathbf{g}_{b_L}]^T$, $\mathbf{g}_c = [\mathbf{g}_{c_1}, \mathbf{g}_{c_2}, \dots, \mathbf{g}_{c_L}]^T$, 最终得到 CRLB 的紧凑表达式:

$$\sigma_{x,y}^2(\mathbf{p}_n) = \frac{\mathbf{b}^T \mathbf{p}_n}{\mathbf{p}_n^T \mathbf{A} \mathbf{p}_n} \quad (17)$$

由上式可见,感知几何系数 $\mathbf{g}_{a_l}$ 、 $\mathbf{g}_{b_l}$ 、 $\mathbf{g}_{c_l}$ 由各节点与目标的空间位置关系决定,矩阵 $\mathbf{A}$ 和向量 $\mathbf{b}$ 均随无人机位置的变化而改变,因此 CRLB 同时受功率向量 $\mathbf{p}_n = [p_i, p_u]^T$ 与无人机位置的共同影响。由于 CRLB 给出了任意无偏估计器均方误差的理论下界,故本文将 CRLB 作为目标定位精度的理论极限与优化约束指标,联合功率分配与无人机轨迹设计对此进行优化。

1.2 问题建模

本节针对无人机-地面基站协同通感一体化系统建立优化问题。优化目标是在保证通信质量和感知精度的前提下,最小化系统总发射功率。定义时隙 n 的用户调度向量 $\mathbf{C}_n = [C_{k,n}, C_{l,n}]^T$, 其中 $C_{k,n}$ 和 $C_{l,n}$ 分别表示协作用户 $k \in \mathcal{K}_c$ 和非协作用户 $l \in \mathcal{K}_e$ 的调度状态,取值为 1 表示被调度,0 表示未被调度。综合考虑通信用户的 SINR 需求与感知目标的 CRLB 精度要求,建立用户调度、功率分配与无人机飞行轨迹的联合优化模型如下:

$$(P1): \min_{\mathbf{p}_n, \mathbf{q}[n], \mathbf{C}_n} \sum_{n=1}^N \mathbf{1}^T \mathbf{p}_n$$

$$\text{s.t. (18a)} \quad p_{i,n} \geq 0, \forall n \in \mathcal{N},$$

$$(18b) \quad p_{u,n} \geq 0, \forall n \in \mathcal{N},$$

$$(18c) \quad \frac{H_{k,n} p_{k,n}}{H_{k,n} p_{j,n} + V_{k,n} p_u + \sigma^2} \geq \Gamma_k, n \in \mathcal{N}, \forall k \in \mathcal{K}_c,$$

$$(18d) \quad \frac{H_{l,n} p_{l,n} + V_{l,n} p_u}{H_{l,n} p_{k,n} + \sigma^2} \geq \Gamma_l, \forall n \in \mathcal{N}, \forall l \in \mathcal{K}_e,$$

$$(18e) \quad \frac{\mathbf{b}^T \mathbf{p}_n}{\mathbf{p}_n^T \mathbf{A} \mathbf{p}_n} \leq \tau, \forall n \in \mathcal{N},$$

$$(18f) \quad \sum_{k \in \mathcal{K}_c} C_{k,n} = 1, \forall n \in \mathcal{N}, \forall k \in \mathcal{K}_c,$$

$$(18g) \quad \sum_{l \in \mathcal{K}_e} C_{l,n} = 1, \forall n \in \mathcal{N}, \forall l \in \mathcal{K}_e,$$

$$(18h) \quad \sum_{n=1}^N C_k \leq C_{\max}, \forall n \in \mathcal{N}, \forall k \in \mathcal{K}_c,$$

$$(18i) \quad \sum_{n=1}^N C_l \leq C_{\max}, \forall n \in \mathcal{N}, \forall l \in \mathcal{K}_e,$$

$$(18j) \quad \mathbf{q}[n] \in \mathcal{D}, \forall n \in \mathcal{N},$$

$$(18k) \quad \mathbf{q}[n+1] - \mathbf{q}[n] \leq \frac{v_{\max} \cdot T}{N}, \quad \forall n = 1, 2, \dots, N-1 \quad (18)$$

其中, $\mathbf{1}$ 表示具有适当维度的全 1 向量, $\mathbf{p}_n = [p_i, p_u]^T$ 组合了地面基站 p_i 和无人机 p_u 的功率分配。对于地面基站,采用参数化功率分配方案,其中 $p_k = \alpha p_i$ 和 $p_l = (1 - \alpha) p_i$, 其中 $\alpha \in [0, 1]$ 控制非协作用户和协作用户之间的功率分配。

约束条件(18c)和(18d)确保非协作用户和协作用户的信干噪比需求得到满足,约束条件(18e)保证目标定位的克拉美罗下界不超过阈值 τ 。约束条件(18f)和(18g)确保每个时隙恰好选择一个协作用户和一个非协作用户进行 NOMA 传输,约束条件(18h)和(18i)限制每个用户的服务次数以保证公平性,约束条件(18j)和(18k)为无人机运动约束。为简化分析,设定 $\Gamma_k = \Gamma_l = \Gamma$ 。由于功率分配变量 $\mathbf{p}_n$ 与轨迹变量 $\mathbf{q}[n]$ 之间的耦合关系,加之信干噪比约束和克拉美罗下界约束的非凸特性,问题(P1)难以直接求解。

为了使问题更容易处理,将(P1)等价改写为向量表示形式:

$$\begin{aligned}
 & \text{(P2): } \min_{\mathbf{p}_n, \mathbf{q}[n], \mathbf{c}_n} \sum_{n=1}^N \mathbf{1}^T \mathbf{p}_n \\
 & \text{s.t. (18f)~(18k)} \\
 & \text{(19a) } p_{i,n} \geq 0, \forall n \in \mathcal{N}, \\
 & \text{(19b) } p_{u,n} \geq 0, \forall n \in \mathcal{N}, \\
 & \text{(19c) } \mathbf{g}_k^T \mathbf{p}_n \geq \Gamma_k \sigma^2, \forall n \in \mathcal{N}, \forall k \in \mathcal{K}_c, \\
 & \text{(19d) } \mathbf{g}_l^T \mathbf{p}_n \geq \Gamma_l \sigma^2, \forall n \in \mathcal{N}, \forall l \in \mathcal{K}_e, \\
 & \text{(19e) } \mathbf{b}^T \mathbf{p}_n - \tau \mathbf{p}_n^T \mathbf{A} \mathbf{p}_n \leq 0, \forall n \in \mathcal{N}
 \end{aligned} \quad (19)$$

其中, $\mathbf{g}_k = [\alpha \cdot H_{k,n}, -\gamma_k \cdot V_{k,n}]^T$ 和 $\mathbf{g}_l = [(1-\alpha) - \gamma_l \cdot \alpha] \cdot H_{l,n}, V_{l,n}]^T$ 分别表示非协作用户和协作用户的有效信道向量。由于约束条件中的二次项,问题(P2)为非凸优化问题。为确定问题可行性,注意到对于任意满足信干噪比约束的功率向量 $\bar{\mathbf{p}}_n > 0$, 可通过缩放构造可行解: $\tilde{\mathbf{p}}_n = \eta \bar{\mathbf{p}}_n$, 其中 $\eta = \max\left(\frac{\mathbf{b}^T \bar{\mathbf{p}}_n}{\tau \bar{\mathbf{p}}_n^T \mathbf{A} \bar{\mathbf{p}}_n}, 1\right)$ 。该缩放操作在保持

信干噪比约束的同时满足克拉美罗下界约束。因此,问题(P2)可行当且仅当信干噪比约束可行,这可通过标准凸优化工具进行验证。

观察到问题(P2)的目标函数和约束条件在时隙间具有可分离性,在给定无人机位置的情况下,可将其分解为 N 个独立子问题,每个时隙对应一个:

$$\begin{aligned}
 & \text{(P3): } \min_{\mathbf{p}_n, \mathbf{c}_n} \mathbf{1}^T \mathbf{p}_n \\
 & \text{s.t. (18f)~(18j), (19a)~(19e)}
 \end{aligned} \quad (20)$$

问题(P3)的最优解依赖于无人机位置。不同位置对应不同的信道条件,导致用户调度和功率等多维资源分配方案随之变化。另一方面,资源分配决策又影响通信感知性能,进而决定无人机的飞行轨迹。这种多维资源分配与轨迹设计间的强耦合使得传统优化方法难以高效求解。针对这一耦合优化问题,本文提出双层优化框架解决多维资源分配与轨迹设计的联合优化问题。下文将详细阐述求解方法的各个组成部分。

2 优化问题求解

基于第1节中提出的问题分解,本节提出一种基于深度强化学习的双层优化框架解决多维资源分配与轨迹设计的联合优化问题。该框架由内外两层构成:外层采用DDPG算法优化无人机轨迹,内层利用半定松弛技术求解多维资源联合分配问题。内层优化结果作为奖励信号反馈至外层,建立轨迹设计与多维资源分配的耦合优化机制。

2.1 最优功率分配

本节针对给定无人机位置和用户调度结果下的

最优功率分配问题进行求解。为处理问题(P2)中的非凸约束,特别是CRLB约束中的二次分式项,本文采用半正定松弛(SDR)技术^[29-30]。SDR通过将原问题提升到更高维的半正定矩阵空间,利用矩阵秩松弛将非凸问题转化为凸半定规划问题,从而可利用成熟的凸优化工具高效求解。

定义 $\mathbf{P}_n = \mathbf{p}_n \mathbf{p}_n^T$, 并构造增广矩阵:

$$\mathbf{Y} = \begin{bmatrix} \mathbf{1} & \mathbf{p}_n^T \\ \mathbf{p}_n & \mathbf{P}_n \end{bmatrix} \quad (21)$$

该矩阵满足半正定约束 $\mathbf{Y} \geq \mathbf{0}$ 以及秩一约束 $\text{rank}(\mathbf{Y}) = 1$ 。通过该变换,最小化问题(P3)的目标函数 $\mathbf{1}^T \mathbf{p}_n$ 等价于最小化 $[0, \mathbf{1}^T] \mathbf{Y} [0, \mathbf{1}^T]^T$ 。CRLB约束可以改写为

$$\begin{aligned}
 \mathbf{b}^T \mathbf{p}_n - \tau \mathbf{p}_n^T \mathbf{A} \mathbf{p}_n &= \text{tr}(\mathbf{b}^T \mathbf{p}_n - \tau \mathbf{p}_n^T \mathbf{A} \mathbf{p}_n) \\
 &= \text{tr}(\mathbf{b}^T \mathbf{p}_n - \tau \mathbf{A} \mathbf{P}_n) \\
 &= \text{tr} \left(\begin{bmatrix} 0 & \frac{1}{2} \mathbf{b}^T \\ \frac{1}{2} \mathbf{b} & -\tau \mathbf{A} \end{bmatrix} \mathbf{Y} \right)
 \end{aligned} \quad (22)$$

其中, $\text{tr}(\cdot)$ 表示矩阵的迹算子。因此, CRLB约束等价于:

$$\text{tr} \left(\begin{bmatrix} 0 & \frac{1}{2} \mathbf{b}^T \\ \frac{1}{2} \mathbf{b} & -\tau \mathbf{A} \end{bmatrix} \mathbf{Y} \right) \leq 0 \quad (23)$$

类似地, SINR约束可变换为

$$[-\tilde{\gamma}, \mathbf{G}] \mathbf{Y} \mathbf{e}_i \geq 0, \quad i = 1, 2, \dots, M+1 \quad (24)$$

其中, $\mathbf{e}_i$ 是第 i 个元素为1、其余元素为0的单位向量, $\mathbf{G} = [\mathbf{g}_k, \mathbf{g}_l]^T$ 表示信道增益矩阵, $\tilde{\gamma} = [\Gamma_k \sigma_k^2, \Gamma_l \sigma_l^2]^T$ 封装了信干噪比需求和噪声功率。通过上述变换,问题(P3)等价重构为

$$\begin{aligned}
 & \text{(P4): } \min_{\mathbf{Y}} [0, \mathbf{1}^T] \mathbf{Y} [0, \mathbf{1}^T]^T \\
 & \text{s.t. (25a) } \mathbf{Y} \mathbf{e}_i \geq 0, i = 1, 2, \dots, M+1, \\
 & \text{(25b) } \mathbf{Y}(1, 1) = 1, \\
 & \text{(25c) } \mathbf{Y} \geq 0, \text{rank}(\mathbf{Y}) = 1, \\
 & \text{(23), (24)}
 \end{aligned} \quad (25)$$

由于(25b)中的秩一约束,问题(P4)仍然是非凸的。通过去除秩一约束,得到凸半定规划问题(SDR4),该问题可利用CVX等标准凸优化工具高效求解,为原问题提供下界。

为从(SDR4)的最优解 $\mathbf{Y}^*$ 中恢复秩一解,采用高斯随机化方法^[31],提取 $\mathbf{Y}^*$ 中对应功率变量的子矩阵 $\mathbf{P}_n = \mathbf{Y}_{[2:3, 2:3]}^*$, 对其进行特征值分解 $\mathbf{P}_n = \mathbf{V} \mathbf{D} \mathbf{V}^T$, 其中 $\mathbf{V} \mathbf{V}^T = \mathbf{I}$, $\mathbf{D}$ 为非负对角矩阵,生成候选解 $\mathbf{z} = |\mathbf{V} \sqrt{\mathbf{D}} \mathbf{w}|$, 其中 $\mathbf{w} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$ 为高斯随机向量, $|\cdot|$ 表示元素的绝对值运算。

由于生成的 $\mathbf{z}$ 可能不直接满足问题 (P3) 的约束条件, 引入缩放因子 $\xi > 0$ 以寻找可行功率向量 $\xi \mathbf{z}$ 。将 $\mathbf{p}_n = \xi \mathbf{z}$ 代入 (P3), 通过求解以下问题确定最优 ξ :

$$\begin{aligned} \text{(P5): } & \min_{\xi} \quad \xi \mathbf{1}^T \mathbf{z} \\ \text{s.t. (26a)} & \xi > 0, \\ \text{(26b)} & \mathbf{g}_k^T \cdot \xi \mathbf{z} \geq \Gamma_k \sigma^2, \quad \forall k \in \mathcal{K}_c, \\ \text{(26c)} & \mathbf{g}_l^T \cdot \xi \mathbf{z} \geq \Gamma_l \sigma^2, \quad \forall l \in \mathcal{K}_e, \\ \text{(26d)} & \tau \xi^2 \mathbf{z}^T \mathbf{A}_n \mathbf{z} \geq \mathbf{b}^T \mathbf{z} \end{aligned} \quad (26)$$

由于 $\mathbf{1}^T \mathbf{z} > 0$, 最优解 ξ^* 为满足所有约束的最小值:

$$\xi^* = \max \left(\frac{\Gamma \sigma^2}{\mathbf{g}_k^T \mathbf{z}}, \frac{\Gamma \sigma^2}{\mathbf{g}_l^T \mathbf{z}}, \sqrt{\frac{\mathbf{b}^T \mathbf{z}}{\tau \mathbf{z}^T \mathbf{A}_n \mathbf{z}}} \right) \quad (27)$$

为提高解的质量, 执行 L 次高斯随机化迭代, 选择满足所有约束条件下使总发射功率最小的功率向量。算法 1 给出了基于半定松弛的最优功率分配完整流程。

算法 1 基于半定松弛的最优功率分配

输入: 信道参数、SINR 阈值 Γ 、CRLB 阈值 τ 、无人机位置 $\mathbf{q}[n]$ 、随机化次数 L 、用户调度方案 $\mathbf{C}_n$

输出: 最优功率分配 $\mathbf{p}_n^*$

1. 求解松弛问题 (SDR4) 得到 $\mathbf{Y}^*$
 2. 提取 $\mathbf{P}_n = \mathbf{Y}_{[2:3, 2:3]}^*$, 计算特征值分解 $\mathbf{P}_n = \mathbf{V} \mathbf{D} \mathbf{V}^T$
 3. 初始化 $p_{\text{best}} = \infty$
 4. FOR $i = 1$ TO L DO
 5. 生成 $\mathbf{w} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$, 计算 $\mathbf{z} = |\mathbf{V} \sqrt{\mathbf{D}} \mathbf{w}|$
 6. 计算缩放因子 $\xi^* = \max \left(\frac{\Gamma \sigma^2}{\mathbf{g}_k^T \mathbf{z}}, \frac{\Gamma \sigma^2}{\mathbf{g}_l^T \mathbf{z}}, \sqrt{\frac{\mathbf{b}^T \mathbf{z}}{\tau \mathbf{z}^T \mathbf{A}_n \mathbf{z}}} \right)$
 7. IF ξ^* 可行 AND $\xi^* \mathbf{1}^T \mathbf{z} < p_{\text{best}}$ THEN
 8. $\mathbf{p}_n^* = \xi^* \mathbf{z}$, $p_{\text{best}} = \xi^* \mathbf{1}^T \mathbf{z}$
 9. END IF
 10. END FOR
-

2.2 联合用户调度与功率分配

在空-地协同通感一体化场景下, 用户调度与功率分配高度耦合。不同的用户组合因信道条件和空间位置的差异, 导致保障通信质量与感知精度所需的最小发射功率存在显著差异。孤立地进行用户调度或功率分配均无法实现系统性能最优。基于 2.1 节提出的最优功率分配方案, 本文提出一种低复杂度的联合用户调度和功率分配方案, 在满足用户公平性约束的同时最小化系统瞬时功耗。

联合用户调度和功率分配问题定义为: 在当前时隙 n , 从所有非协作用户 $k \in \mathcal{K}_c$ 和协作用户 $l \in \mathcal{K}_e$ 中选择一对最优组合 (k^*, l^*) , 使得在该组合下系统所需的总发射功率最小, 且所选用户未超过其最大允许服务次数 $C_{\max}$ 。

为了避免对所有可能的 $\mathcal{K}_c \times \mathcal{K}_e$ 种用户组合进行耗时的完整 SDR 求解 (包含多次高斯随机化过程), 本文利用 3.1 节中建立的半定松弛框架, 构造一个快速功率评估指标。具体算法步骤如下: 对于任意给定的用户对 (k, l) , 求解松弛问题 (SDR4) 得到最优半定矩阵 $\mathbf{Y}_{k,l}^*$ 。对其功率子矩阵进行特征值分解, 提取主特征向量 $\mathbf{v}_1$ 作为该组合未经随机化的功率方向估计。计算满足该组合所有 SINR 和 CRLB 约束所需的最小缩放因子 $\xi_{k,l}^*$ (计算方式同算法 1 步骤 6), 从而得到该组合的功率代价估计值 $\hat{p}_{k,l} = \xi_{k,l}^* \mathbf{1}^T \mathbf{v}_1$ 。该指标有效反映了在该用户组合下, 系统为满足双功能需求所需付出的能耗下限。

基于上述功率代价估计, 系统在满足公平性约束的可行域内寻找代价最小的用户对。设 c_k 和 c_l 分别记录非协作用户 k 和协作用户 l 的历史服务次数, $C_{\max}$ 为允许的最大服务次数。用户选择问题表述为

$$(k^*, l^*) = \arg \min_{(k, l) \in \mathcal{F}} \hat{p}_{k,l} \quad (28)$$

其中, 可行集 $\mathcal{F} = \{(k, l) | k \in \mathcal{K}_c, l \in \mathcal{K}_e, c_k < C_{\max}, c_l < C_{\max}\}$ 。若因所有用户均达到服务上限导致 $\mathcal{F} = \emptyset$, 系统将放宽约束允许所有用户参与调度, 以避免资源闲置。

该指标在无需进行耗时的高斯随机化过程的情况下, 有效反映了不同用户组合在当前信道与感知何下的能耗水平。系统选择使估计功率最小的用户对 (k^*, l^*) 作为当前时隙的服务对象, 然后对该最优组合执行完整的高斯随机化过程以获得精确的功率分配方案。与穷举法相比, 该方法避免了对次优组合进行昂贵的随机化计算, 在保证系统性能的同时显著降低了算法的计算复杂度。

2.3 基于深度强化学习的轨迹优化

在多维资源分配算法建立后, 本节聚焦于无人机轨迹优化问题。由于轨迹优化问题的高度非凸特性, 以及无人机位置与系统性能之间复杂的耦合关系, 传统优化方法难以高效求解。为此, 本文采用深度强化学习方法。该方法无需环境的显式数学模型, 可通过与环境交互有效探索复杂的解空间。

2.3.1 马尔可夫决策过程构建

将无人机轨迹优化问题建模为马尔可夫决策过程 (Markov Decision Process, MDP), 该过程为不确定性环境下的序贯决策提供数学框架。MDP 由状态空间、动作空间、状态转移函数、奖励函数和折扣因子五元组 $\langle \mathcal{S}, \mathcal{A}, \mathcal{P}, \mathcal{R}, \gamma \rangle$ 定义。时隙 n 的状态定义为 $s_n = [x_n, y_n, n]$, 包含无人机的水平位置坐标及当前时隙索引, 状态空间为 $\mathcal{S} = \mathcal{D} \times \{1, 2, \dots, N\}$ 。动作定义为 $a_n = [\theta_n, v_n]$, 其中 $\theta_n \in [-\pi, \pi]$ 控制飞行方向角, $v_n \in [0, v_{\max}]$ 决定移动速度, 动作空间为连续空间 $\mathcal{A} =$

$[-\pi, \pi] \times [0, v_{\max}]$ 。

给定当前状态 s_n 和动作 $a_n = [\theta_n, v_n]$, 无人机位置按以下规则更新:

$$\begin{aligned} x_{n+1} &= x_n + v_n \cos(\theta_n) \Delta t \\ y_{n+1} &= y_n + v_n \sin(\theta_n) \Delta t \end{aligned} \quad (29)$$

其中, Δt 为时段时长。状态转移具有确定性, 即转移概率 $\mathcal{P}(s_{n+1}|s_n, a_n) = 1$ 。为引导智能体最小化系统总功耗, 奖励函数设计为该时段最优功率分配结果的负值 $R_n = -\sum_{n=1}^N \mathbf{1}^T \mathbf{p}_n$, 其中 $\mathbf{p}_n$ 为通过算法 1 求得的最优功率分配。负号将功率最小化问题转化为奖励最大化问题, 符合强化学习的标准形式。折扣因子 $\gamma \in (0, 1]$ 用于平衡即时奖励与未来奖励的重要性, 累计折扣奖励定义为 $G_n = \sum_{k=0}^{N-n} \gamma^k r_{n+k}$, 智能体的优化目标为最大化期望累计折扣奖励。

2.3.2 基于 DDPG 的无人机轨迹优化

针对上述马尔可夫决策过程, 本文采用 DDPG 算法进行求解。DDPG 是一种特别适用于连续控制问题的强化学习算法, 它结合了基于策略和基于价值的强化学习方法的优势, 通过两个神经网络实现决策: Actor 网络 $\mu(s|\phi)$ 负责确定策略并直接将状态映射为动作, Critic 网络 $Q(s, a|\theta)$ 负责评估策略并逼近动作价值函数。为增强训练稳定性, DDPG 引入了目标网络机制, 即目标 Actor 网络 $\mu'(s|\phi')$ 和目标 Critic 网络 $Q'(s, a|\theta')$, 这些目标网络的参数更新速度远慢于主网络。此外, 算法还利用经验回放池打破训练数据中的时序相关性, 提高样本利用效率。算法的整体架构如图 2 所示, 外层 DDPG 负责轨迹优化, 内层 SDR 求解器计算多维资源分配, 二者通过奖励信号形成闭环优化机制。具体而言, 在给定无人机位置后, 内层 SDR 求解器可得到满足通信 SINR 约束与感知 CRLB 约束的最优功率分配方案 $\mathbf{p}_n^*$ 。本文将该最优总发射功率的负值构造为强化学习奖励, 即功耗越低, 奖励越高。于是, 外层 DDPG 在策略迭代过程中会优先学习那些能够诱导较低内层功耗的位置动作, 从而使无人机轨迹逐步向低功耗、高协同收益的空间区域演化。功率分配结果通过奖励信号反馈至外层策略网络, 间接决定了无人机的轨迹调整方向, 实现了资源配置与轨迹规划的闭环耦合优化。

在与环境交互过程中, DDPG 根据当前策略选择动作, 并叠加探索噪声以保证充分探索:

$$a_n = \mu(s_n|\phi) + \mathcal{N}_n \quad (30)$$

其中, $\mathcal{N}_n$ 表示探索噪声, 通常采用 Ornstein-Uhlenbeck 过程生成, 以实现时间相关的探索行为。执行动作后, 智能体转移至下一状态 s_{n+1} 并接收奖励 r_n 。这些

经验样本 (s_n, a_n, r_n, s_{n+1}) 被存储至经验回放池, 训练时从中随机抽取小批量样本, 有效打破连续样本间的时序相关性。




图 2 基于 DDPG 的空-地协同通感一体化双层优化算法框架

Figure 2 DDPG-based air-ground coordinated ISAC two-layer optimization algorithm framework

Critic 网络通过最小化时序差分损失进行更新:

$$L_c(\theta) = \frac{1}{M} \sum_n (r_n + \gamma Q'(s_{n+1}, \mu'(s_{n+1}|\phi')) - Q(s_n, a_n|\theta))^2 \quad (31)$$

其中, M 为小批量样本数, 目标 Q 值通过目标网络计算以增强稳定性。Actor 网络则利用确定性策略梯度进行更新:

$$\nabla_{\phi} J = \frac{1}{M} \sum_n \nabla_a Q(s, a|\theta)|_{s=s_n, a=\mu(s_n|\phi)} \nabla_{\phi} \mu(s|\phi)|_{s=s_n} \quad (32)$$

该梯度指导策略调整方向, 以最大化期望 Q 值。

Actor 和 Critic 网络的参数更新规则分别为

$$\phi \leftarrow \phi + \alpha_{\phi} \nabla_{\phi} J \quad (33)$$

$$\theta \leftarrow \theta - \alpha_{\theta} \nabla_{\theta} L_c(\theta) \quad (34)$$

其中, α_{ϕ} 和 α_{θ} 分别为 Actor 和 Critic 网络的学习率。

为进一步增强训练稳定性, 目标网络采用软更新机制:

$$\phi' = \tau \phi + (1 - \tau) \phi' \quad (35)$$

$$\theta' = \tau \theta + (1 - \tau) \theta' \quad (36)$$

其中, $\tau \ll 1$ 为软更新系数, 控制目标网络参数的更新速率。通过该机制, 目标网络参数缓慢跟踪主网络, 避免训练过程中的剧烈震荡。在本文提出的双层优化框架中, 智能体根据当前状态输出飞行动作, 确定无人机位置后, SDR 求解器计算该位置下的多维资源分配并将结果反馈为奖励信号, 引导智能体逐步学习能够降低系统功耗的飞行策略。完整的双层优化流程总结于算法 2。

2.3.3 算法复杂度分析

本文双层优化算法的计算复杂度由外层 DDPG

算法2 无人机-地面基站协同通感一体化双层优化算法

输入: 初始状态 s_1 , 最大回合数 M , 时隙数 N , 用户集 $\mathcal{K}_c, \mathcal{K}_e$, 服务限次 $C_{\max}$, DDPG 网络参数

输出: 用户调度方案 $\mathbf{C}_n^*$, 功率分配方案 $\mathbf{p}_n^*$ 及无人机位置 $\mathbf{q}[n]$ 。

1. 初始化 Actor 网络 $\mu(s|\phi)$, Critic 网络 $Q(s, a|\theta)$ 及经验回放池 $\mathcal{R}$
2. FOR episode = 1 TO M DO
3. 初始化状态 s_1 , 重置服务计数 $c_k = 0, c_l = 0$
4. FOR $n = 1$ TO N DO
5. 根据策略 $\mu(s_n|\phi)$ 选择动作 a_n , 更新位置得到 $\mathbf{q}[n+1]$
6. 构建候选用户集 $\mathcal{F} = \{(k, l) | c_k < C_{\max}, c_l < C_{\max}\}$
7. FOR EACH $(k, l) \in \mathcal{F}$ DO
8. 求解松弛问题得到 $\mathbf{Y}_{k,l}^*$, 计算初始功率估计 $\hat{p}_{k,l}$
9. END FOR
10. 选择最优用户对 $(k^*, l^*) = \arg \min_{(k, l) \in \mathcal{F}} \hat{p}_{k,l}$
11. 对 (k^*, l^*) 执行高斯随机化, 得到最优功率分配 $\mathbf{p}_n^*$
12. 更新服务计数 $c_{k^*} \leftarrow c_{k^*} + 1, c_{l^*} \leftarrow c_{l^*} + 1$
13. 计算奖励 r_{n+1} , 观测新状态 s_{n+1}
14. 将 (s_n, a_n, r_n, s_{n+1}) 存入 $\mathcal{R}$
15. 从 $\mathcal{R}$ 中采样数据, 更新 Actor 和 Critic 网络参数
16. END FOR
17. END FOR

轨迹优化与内层 SDR 资源分配两部分构成。外层 DDPG 的训练复杂度为 $O(T \cdot L)$, 与训练回合数 T 和时隙数 L 呈线性关系, 训练完成后推理阶段仅需执行 Actor 网络的前向传播, 计算开销极低。内层 SDR 求解半正定规划问题的复杂度为 $O(n^3 \log(1/\epsilon))$, 其中矩阵维度 $\epsilon = 3$, ϵ 为求解精度, 在本文设定下属于常数级复杂度。在用户调度方面, 本文提出的两阶段筛选策略对 $\mathcal{K}_c \times \mathcal{K}_e$ 种用户组合先通过 SDR 松弛解进行功率代价快速评估, 再对筛选出的最优组合执行完整的高斯随机化求解, 将调度相关复杂度从穷举法的 $O(\mathcal{K}_c^m \mathcal{K}_e^k)$ 降至 $O(\mathcal{K}_c + \mathcal{K}_e)$, 其中 m 和 k 分别为每次调度时从协作用户集合与非协作用户集合中选取的用户数量, $\mathcal{K}_c$ 和 $\mathcal{K}_e$ 分别为协作用户与非协作用户的总数量。综合上述三部分, 算法整体复杂度为 $O(TL + L(\mathcal{K}_c + \mathcal{K}_e))$ 。

与现有方案相比, 全传统数学规划方法需求解联合非凸混合整数规划问题, 复杂度呈指数级增长; 端到端全强化学习方案因动作空间包含离散调度与连续功率、轨迹变量, 维度随用户数量急剧扩张, 训练开销显著高于本文方案。本文通过将问题分解为适合 SDR 求解的凸结构资源分配子问题与适合 DRL 搜索的非凸轨迹优化子问题, 在保证求解质量的同时将整体复杂度控制在多项式级, 在用户数量增加时仍能保持良好的可扩展性, 这也与图 10 所示的用户数量可扩展性实验结果相吻合。

3 仿真结果分析

本节通过实验仿真结果评估所提算法的有效性。仿真设置和关键系统参数如表 2 所示。仿真场景设定在 $300 \text{ m} \times 300 \text{ m}$ 的区域内, 地面基站固定部署于 $(50, 50) \text{ m}$ 处, 无人机初始位置位于 $(100, 100) \text{ m}$ 处。待感知目标初始位置为 $(150, 70) \text{ m}$, 以 3 m/s 的速度沿水平方向持续移动, 模拟低空经济场景下的动态目标感知需求。

表 2 仿真参数设置

Table 2 Simulation parameter settings

参数符号	参数名称	参数值
f_c / GHz	载波频率	6
B / MHz	系统带宽	1
$\sigma^2 / (\text{dBm} \cdot \text{Hz}^{-1})$	噪声功率谱密度	-110
β_0 / dB	信道功率增益	-60
H / m	无人机飞行高度	100
$V_{\max} / (\text{m} \cdot \text{s}^{-1})$	无人机最大飞行速度	20
Γ	SINR 阈值	20.0
τ	CRLB 阈值	1.0
$\mathcal{K}_c$	非协作用户数量	3
$\mathcal{K}_e$	协作用户数量	3
$C_{\max}$	任务周期内最大服务次数	15
N	任务周期时隙数	30
$\Delta t / \text{s}$	单个时隙时长	1

对于 DDPG 算法的实现, Actor 和 Critic 网络均采用全连接神经网络结构, 包含两个隐藏层, 神经元数分别为 128 和 256, 激活函数采用 ReLU。经验回放缓冲区大小设置为 10^4 , 折扣因子 $\gamma = 0.95$, 软更新系数 $\tau = 0.001$, Actor 学习率和 Critic 学习率均设置为 $\alpha = 2 \times 10^{-3}$ 。探索噪声采用 Ornstein-Uhlenbeck 过程生成, 训练过程持续 1 000 个回合以确保策略收敛。同时, 选定现有的深度 Q 网络 (Deep Q-Network, DQN) 和非协同 ISAC 等方法作为提出的基于 DDPG 的空地协同 ISAC 方案的对比方案。

图 3 分析了感知精度约束对系统功率开销的影响, 对比了所提空地协同 ISAC 方案与仅地面基站服务的非协同 ISAC 方案。结果显示, 在不同 SINR 阈值下, 随着 CRLB 阈值从严格到宽松, 系统功率开销均呈现单调递减趋势。这是因为更宽松的感知精度要求允许系统在保持目标可定位的前提下降低发射功率。协同方案相比非协同方案实现了 30%~36% 的功耗节约, 这得益于无人机与地面基站联合服务带来的性能增益。此外, SINR 阈值越高, 功耗曲线整体上移, 这是由于更严格的通信质量需求迫使系统提高发射功率以对抗干扰和路径损耗。这些结果揭示了通信质量、感知精度与功率能耗之间的内在权衡关系,

并证实了所提算法能够在不同约束条件下稳健地找到有效工作点。




图3 克拉美罗下界阈值对系统能耗的影响

Figure 3 The impact of the threshold of CRLB on system power consumption




图4 不同方法下系统功率随时隙的变化

Figure 4 Variation of system power with time slots under different methods

图4展示了在 $\text{SINR}=12$ 、 $\text{CRLB}=5$ 的约束条件下,不同优化方法在整个任务周期内的瞬时功率消耗对比。无人机固定悬停方案指无人机固定在起始位置,固定轨迹方案指无人机从起点到终点直线飞行,全DDPG方案指将轨迹、功率分配与用户调度统一纳入端到端强化学习框架求解。图4结果显示,所提DDPG协同方案在所有时隙均保持最低功耗,相较于DQN协同方案、全DDPG方案、固定轨迹方案、DDPG非协同方案和无人机固定悬停方案,功耗分别降低7%、39%、17%、36%和78%。固定悬停方案功耗随时隙持续攀升,从初始的2.44 W增至任务末期的8.51 W,这是由于感知目标持续远离无人机初始位置,导致感知约束收紧而被迫提高发射功率。全DDPG方案因混合动作空间维度过高且硬性约束难以直接嵌入,策略学习不稳定,各时隙功率曲线波动显著,部分时隙可能会出现约束违反情况,整体功耗远高于所提方案。DQN协同方案受限于离散动作空间,轨迹调整精度不足,功耗略高于所提方案。相比之下,所提DDPG协同方案通过双层框架将内层SDR优化结果

嵌入奖励信号,使外层DDPG在约束可行域内稳定搜索轨迹,功率曲线保持平稳,在动态感知目标场景下展现出显著的性能优势。

为验证内层SDR近似处理在本文空-地协同ISAC约束下的可靠性,本节在小规模可枚举场景下补充了SDR方法与穷举法的基准对比实验。穷举法以0.005 W为步长从0开始遍历所有可能的功率组合,在满足通信与感知双重约束的所有可行解中选取总功率最小的组合,作为近似全局最优基准。实验在1个非协作用户、1个协作用户、1个感知目标的场景下进行,其中时隙数 $N=30$, SINR 阈值设为20, CRLB 阈值设为5。图5给出了两种方法在各时隙的瞬时总发射功率对比。可以看出,SDR方法与穷举法的功率曲线在整个任务周期内高度吻合,两条曲线几乎重合,仅在个别时隙存在微小偏差。表3进一步给出了定量统计结果。




图5 SDR方法与穷举法各时隙总发射功率对比

Figure 5 Comparison of total transmission power per time slot between the SDR method and the exhaustive method

表3 SDR方法与穷举法性能对比

Table 3 Performance comparison between the SDR method and the exhaustive method

方法	平均系统功率/W	平均单时隙计算时间/s
SDR+高斯随机化	1.052	0.155 2
穷举法	1.037	2.773 9

结果表明,SDR方法的平均总功率与穷举法仅相差1.44%,两种方法在全部时隙内均严格满足通信 SINR 与感知 CRLB 的双重约束,验证了SDR近似处理的低损耗与高可靠性。在计算效率方面,SDR方法的单时隙平均计算时间仅为穷举法的5.6%,计算效率提升约17.87倍。值得注意的是,当场景规模扩展至本文原始仿真设定(3个非协作用户、3个协作用户)时,穷举法的搜索空间急剧增大,已无法在合理时间内完成计算,而SDR方法仍能保持高效稳定的求解性能,证明该近似处理在本文复杂ISAC约束下的适用性。

图6展示了不同 CRLB 阈值下的优化无人机飞行轨迹。无人机从起始点出发,在三种不同的感知精度

约束下呈现出差异化的飞行模式。当CRLB约束较严格时,轨迹相对较低,更接近感知目标的移动路径,以获得有利的感知几何配置。随着CRLB约束放宽,轨迹向协作用户密集区域偏移,在满足感知精度要求的同时兼顾通信需求。当约束进一步放宽时,轨迹主要受通信需求主导,无人机明显向右上方的协作用户群飞行,通过缩短通信距离降低路径损耗。三条轨迹在任务初期均从起点快速向服务区域移动,后期根据感知目标的水平移动趋势动态调整。该结果表明,所提算法能够通过自适应轨迹规划在通信与感知需求间实现灵活权衡。

图7展示了系统在任务起点与终点的功率信息空间分布,色标表示无人机在不同位置部署时系统所需的最小总发射功率。对比两个时刻的功率分布可以发现,随着感知目标的水平移动,低功耗区域由左下方向右侧扩展并发生显著偏移。结合图6中DDPG学习到的轨迹可以看出,无人机的飞行路径与低功耗区域的动态迁移趋势一致,算法成功捕捉了功率需求空间分布的动态演化特征。通过功率信息分布地图





图6 不同感知需求下的无人机轨迹设计


Figure 6 UAV trajectory design under different perception requirements

的可视化分析,可以观察到DDPG算法能够自主识别低功耗区域并据此规划飞行路径,这为深度强化学习的黑箱决策提供了可解释性支撑。结果表明,所提算法能够动态感知系统功率需求的空间分布变化,并自主规划高效的飞行路径,验证了深度强化学习方法在处理动态ISAC场景中的有效性。



(a) 无人机起点功率分布

(a) Power distribution at UAV starting point



(b) 无人机终点功率分布

(b) Power distribution at UAV terminal point

图7 功率信息空间分布地图(SINR=20, CRLB=5)

Figure 7 Power information spatial distribution map (SINR=20, CRLB=5)

图8展示了所提DDPG算法的学习性能。奖励值随训练进行稳步上升,并在约500个回合后趋于收敛,表明智能体成功学习到了有效的轨迹策略。图中阴影区域随训练推进逐渐收窄,显示方差降低,证实了算法的稳定性。这些结果验证了双层优化框架在最小化系统功耗方面的有效性。

图9探讨了不同超参数配置下DDPG算法的收敛特性,以验证双层优化框架的鲁棒性。结果表明,算法在各种学习率和折扣因子下均能实现相对稳定的性能。通过将基于半定松弛的功率分配嵌入轨迹优化中,约束了搜索空间并增强了不同超参数设置下的收敛稳定性,这证实了架构设计的有效性。




图8 DDPG算法训练收敛曲线

Figure 8 Training convergence curve of the DDPG algorithm




图9 超参数敏感度分析

Figure 9 Hyperparameter sensitivity analysis

图10展示了用户数量对系统总功耗的影响。在保持其他参数不变的情况下,将用户总数从4个增加至32个。结果表明,系统功耗在一定范围内小幅波动,并未随用户数量呈现显著增长趋势。更大的用户集为3.2节提出的联合调度策略提供了更丰富的选择空间,使算法能够在每个时隙选择信道条件更优的用户对。同时,基于SDR初始解的快速筛选机制避免了对所有 $K_c \times K_c$ 种组合进行完整优化,在用户增加时仍能保持较低的计算复杂度。上述结果验证了所提算法在多用户场景下的良好可扩展性。




图10 用户数量对系统能耗的影响

Figure 10 Impact of the number of users on system energy consumption

图11展示了最大调度次数限制对系统总功耗的影响。随着单用户最大调度次数 $C_{\max}$ 从10次增加至20次,系统功耗呈现显著的单调递减趋势。当 $C_{\max}$ 较小时,调度策略受公平性约束限制,算法被迫选择信道条件次优的用户对,导致功耗较高。随着 $C_{\max}$ 增大,约束逐渐放松,算法获得更充分的优化空间,功耗曲线趋于平缓。该结果揭示了系统能效与调度公平性之间的内在权衡关系,为实际系统中公平性参数

的设置提供了理论依据。




图11 最大调度次数限制对系统能耗的影响

Figure 11 Impact of the maximum scheduling count constraint on system energy consumption

4 结论

本文面向低空经济等应用场景,提出了无人机-地面基站协同的通感一体化系统框架,研究了多维资源分配与轨迹设计的联合优化问题。为在满足通信质量与感知精度双重约束下最小化系统总发射功率,构建了用户调度、功率分配与轨迹设计的多维资源联合优化问题,提出了基于DDPG的双层优化框架。该框架通过深度确定性策略梯度算法优化无人机飞行轨迹,结合半正定松弛技术求解瞬时功率分配和用户调度,并将优化结果作为奖励信号反馈至轨迹学习过程,实现了两个子问题的协同优化。仿真结果验证了所提方案的有效性,算法能够动态平衡通信与感知需求。通过功率信息分布地图的可视化分析,揭示了算法能够自主识别并跟随低功耗区域的动态迁移规律,为深度强化学习的黑箱决策提供了可解释性支撑。

值得说明的是,本文聚焦低空经济背景下的基础

性研究场景,尚未考虑实际应用中的高动态、多任务并行与复杂干扰等特征。后续将围绕低空经济实际需求进一步拓展:一是构建多无人机-地面基站协同通感一体化架构,研究多节点分布式轨迹规划与资源协同分配方法;二是引入高动态特性,面向移动用户与多目标随机运动场景设计自适应动态资源调度与轨迹优化算法;三是融入复杂干扰模型与信道不确定性,研究干扰抑制与资源分配联合优化策略,使理论与方案更贴近低空经济实际应用需求。

参考文献

- [1] Xiao Zhiqiang, Zeng Yong. An overview on integrated localization and communication towards 6G[J]. *Science China Information Sciences*, 2021, 65(3): 131301.
- [2] Cui Yuanhao, Liu Fan, Jing Xiaojun, et al. Integrating sensing and communications for ubiquitous IoT: Applications, trends, and challenges[J]. *IEEE Network*, 2021, 35(5): 158-167.
- [3] Yuan Weijie, Wei Zhiqiang, Li Shuangyang, et al. Integrated sensing and communication-assisted orthogonal time frequency space transmission for vehicular networks[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2021, 15(6): 1515-1528.
- [4] Liu Fan, Cui Yuanhao, Masouros C, et al. Integrated sensing and communications: Toward dual-functional wireless networks for 6G and beyond[J]. *IEEE Journal on Selected Areas in Communications*, 2022, 40(6): 1728-1767.
- [5] Pin Tan D K, He Jia, Li Yanchun, et al. Integrated sensing and communication in 6G: Motivations, use cases, requirements, challenges and future directions[C]//2021 1st IEEE International Online Symposium on Joint Communications & Sensing. Piscataway: IEEE, 2021: 1-6.
- [6] Wei Zhiqing, Qu Hanyang, Wang Yuan, et al. Integrated sensing and communication signals toward 5G-A and 6G: A survey[J]. *IEEE Internet of Things Journal*, 2023, 10(13): 11068-11092.
- [7] Yuan Weijie, Li Shuangyang, Wei Zhiqiang, et al. New delay Doppler communication paradigm in 6G era: A survey of orthogonal time frequency space (OTFS) [J]. *China Communications*, 2023, 20(6): 1-25.
- [8] Liu An, Huang Zhe, Li Min, et al. A survey on fundamental limits of integrated sensing and communication[J]. *IEEE Communications Surveys & Tutorials*, 2022, 24(2): 994-1034.
- [9] Liu Fan, Masouros C, Petropulu A P, et al. Joint radar and communication design: Applications, state-of-the-art, and the road ahead[J]. *IEEE Transactions on Communications*, 2020, 68(6): 3834-3862.
- [10] Hua Haocheng, Xu Jie, Han T X. Optimal transmit beamforming for integrated sensing and communication[J]. *IEEE Transactions on Vehicular Technology*, 2023, 72(8): 10588-10603.
- [11] Behdad Z, Demir Ö T, Sung K W, et al. Power allocation for joint communication and sensing in cell-free massive MIMO[C]//GLOBECOM 2022 - 2022 IEEE Global Communications Conference. Piscataway: IEEE, 2022: 4081-4086.
- [12] Zhang A, Rahman M L, Huang Xiaojing, et al. Perceptive mobile networks: Cellular networks with radio vision via joint communication and radar sensing[J]. *IEEE Vehicular Technology Magazine*, 2021, 16(2): 20-30.
- [13] Godrich H, Haimovich A M, Blum R S. Target localization accuracy gain in MIMO radar-based systems[J]. *IEEE Transactions on Information Theory*, 2010, 56(6): 2783-2803.
- [14] Gao Peng, Lian Lixiang, Yu Jinpei. Cooperative ISAC with direct localization and rate-splitting multiple access communication: A Pareto optimization framework[J]. *IEEE Journal on Selected Areas in Communications*, 2023, 41(5): 1496-1515.
- [15] Gesbert D, Hanly S, Huang H, et al. Multi-cell MIMO cooperative networks: A new look at interference[J]. *IEEE Journal on Selected Areas in Communications*, 2010, 28(9): 1380-1408.
- [16] Wei Zhiqing, Xu Ruizhong, Feng Zhiyong, et al. Symbol-level integrated sensing and communication enabled multiple base stations cooperative sensing[J]. *IEEE Transactions on Vehicular Technology*, 2024, 73(1): 724-738.
- [17] Ma Jianpeng, Zhang Shun, Li Hongyan, et al. Interference-alignment and soft-space-reuse based cooperative transmission for multi-cell massive MIMO networks[J]. *IEEE Transactions on Wireless Communications*, 2018, 17(3): 1907-1922.
- [18] 李培铭, 吕忠昊, 方园, 等. 多小区协作无人机通信感知一体化系统的资源分配[J]. *信号处理*, 2022, 38(8): 1592-1600.
- Li Peiming, Lyu Zhonghao, Fang Yuan, et al. Resource allocation for multi-cell cooperative integrated sensing and communication with UAVs[J]. *Journal of Signal Processing*, 2022, 38(8): 1592-1600. (in Chinese)
- [19] Dou Chenglong, Huang Ning, Wu Yuan, et al. Integrated sensing and communication enabled multidevice multitask

- get cooperative sensing: A fairness-aware design[J]. IEEE Internet of Things Journal, 2024, 11(17): 29190-29201.
- [20] Zhao Na, Wang Yunlong, Zhang Zhibo, et al. Joint transmit and receive beamforming design for integrated sensing and communication[J]. IEEE Communications Letters, 2022, 26(3): 662-666.
- [21] Zeng Yongs, Wu Qingqing, Zhang Rui. Accessing from the sky: A tutorial on UAV communications for 5G and beyond[J]. Proceedings of the IEEE, 2019, 107(12): 2327-2375.
- [22] Zeng Yong, Zhang Rui, Lim T J. Wireless communications with unmanned aerial vehicles: Opportunities and challenges[J]. IEEE Communications Magazine, 2016, 54(5): 36-42.
- [23] Zeng Haiyong, Zhang Rui, Zhu Xu, et al. A fast-converging UAV-TBS stereoscopic CoMP-NOMA system: Resource allocation and 3D trajectory design[C]//2023 IEEE 98th Vehicular Technology Conference. Piscataway: IEEE, 2023: 1-5.
- [24] Jing Xiaoye, Liu Fan, Masouros C, et al. ISAC from the sky: UAV trajectory design for joint communication and target localization[J]. IEEE Transactions on Wireless Communications, 2024, 23(10): 12857-12872.
- [25] Jiang Wangjun, Ma Dingyou, Wei Zhiqing, et al. ISAC-NET: Model-driven deep learning for integrated passive sensing and communication[J]. IEEE Transactions on Communications, 2024, 72(8): 4692-4707.
- [26] Hazarika B, Singh K. AFL-DMAAC: Integrated resource management and cooperative caching for URLLC-IoV networks[J]. IEEE Transactions on Intelligent Vehicles, 2024, 9(6): 5101-5117.
- [27] Zeng Yong, Lyu Jiangbin, Zhang Rui. Cellular-connected UAV: Potential, challenges, and promising technologies[J]. IEEE Wireless Communications, 2019, 26(1): 120-127.
- [28] Godrich H, Petropulu A P, Poor H V. Power allocation strategies for target localization in distributed multiple-radar architectures[J]. IEEE Transactions on Signal Processing, 2011, 59(7): 3226-3240.
- [29] Luo Zhiqian, Ma W K, So A M, et al. Semidefinite relaxation of quadratic optimization problems[J]. IEEE Signal Processing Magazine, 2010, 27(3): 20-34.
- [30] Burer S, Vandenbussche D. A finite branch-and-bound algorithm for nonconvex quadratic programming via semi-definite relaxations[J]. Mathematical Programming, 2008, 113(2): 259-282.
- [31] Huang Yi, Fang Yuan, Li Xinmin, et al. Coordinated power control for network integrated sensing and communication[J]. IEEE Transactions on Vehicular Technology, 2022, 71(12): 13361-13365.

作者简介



曾海勇 男, 1989年7月出生于湖南省郴州市。现为广西师范大学电子与信息工程学院/集成电路学院副教授、硕士生导师。主要研究方向为无人机通信、通信感知一体化。
E-mail: zenghaiyong@gxnu.edu.cn



蒋春生 男, 1990年9月出生于广西壮族自治区桂林市。现为广西师范大学电子与信息工程学院/集成电路学院教授、博士生导师。主要研究方向为新型低功耗纳米器件制备与建模。中国电子学会会员编号: E190035968S。
E-mail: 20210038@gxnu.edu.cn



黄媛艳 女, 2001年5月出生于广西壮族自治区崇左市。现为广西师范大学电子与信息工程学院/集成电路学院硕士研究生。主要研究方向为通感一体化、空地协同、深度强化学习等。
E-mail: yyy_59o3o@163.com



朱旭 女, 1977年8月出生于河南省郑州市。现为哈尔滨工业大学(深圳)信息科学与技术学院教授、博士生导师。主要研究方向为大规模MIMO、无人机通信。
E-mail: xuzhu@ieee.org



魏忠祥 男, 1986年11月出生于山西省太原市。现为同济大学副教授、博士生导师。主要研究方向为大规模MIMO、匿名通信。
E-mail: z_wei@tongji.edu.cn



曹杰 男, 1994年8月出生于山西省运城市。现为哈尔滨工业大学(深圳)信息科学与技术学院副教授、硕士生导师。主要研究方向为语义通信、通感算控一体化。
E-mail: caojhitsz@ieee.org