

# 多无人机辅助车联网中基于流匹配模型的时延敏感任务协同资源调度方法

刘新秀<sup>1</sup>, 喻鹏<sup>1</sup>, 方宏林<sup>2</sup>, 辛戎玥<sup>1</sup>, 李文璟<sup>1</sup>, 齐飞<sup>3</sup>, 郭少勇<sup>1</sup>, 肖培<sup>4</sup>

(1. 北京邮电大学网络与交换技术国家重点实验室, 北京, 100876; 2. 西南交通大学计算机与人工智能学院, 四川 成都, 611756; 3. 中国电信研究院移动通信技术研究部, 北京, 100035; 4. 英国萨里大学通信系统研究所 5G 与 6G 创新中心, 英国 吉尔福德, GU2 7XH)

**摘要:** 多无人机辅助车联网中, 车流与任务负载动态变化易造成通信与计算资源供需失配。为保障时延敏感任务, 提出基于流匹配模型的协同资源调度方法。构建兼顾任务时延、系统能耗和截止期违约的优化模型, 设计轨迹—资源—卸载三层机制: 轨迹层采用凸内近似与顺序求解优化无人机部署, 资源层利用流匹配模型生成并筛选资源优先级和发射功率候选, 卸载层结合路径可用性与排队反馈优化任务拆分。仿真结果表明, 所提方法获得更低的系统总时延和能耗—时延积以及更高的任务成功率, 有效提升了时延敏感任务的服务保障能力。

**关键词:** 车联网; 无人机辅助边缘计算; 流匹配模型; 协同资源调度; 服务保障

## Flow Matching Model-Based Coordinated Resource Scheduling for Delay-Sensitive Tasks in Multi-UAV-Assisted Internet of Vehicles

LIU Xinxiu<sup>1</sup>, YU Peng<sup>1</sup>, FANG Honglin<sup>2</sup>, XIN Rongyue<sup>1</sup>, LI Wenjing<sup>1</sup>, Qi Fei<sup>3</sup>, GUO Shaoyong<sup>1</sup>, XIAO Pei<sup>4</sup>

1. State Key Laboratory of Networking and Switching Technology, Beijing University of Posts and Telecommunications, Beijing 100876, China

2. School of Computing and Artificial Intelligence, Southwest Jiaotong University, Chengdu, 611756, China

3. Department of Mobile Communication Technology Research, China Telecom Research Institute, Beijing 100035, China

4. 5G and 6G Innovation Centre, Institute for Communication Systems (ICS), University of Surrey, GU2 7XH Guildford, U.K.

**Abstract:** In multi-unmanned-aerial-vehicle (UAV)-assisted Internet of Vehicles (IoV) systems, dynamic variations in traffic flows and task loads can cause mismatches between communication and computing resource supply and demand. To support delay-sensitive tasks, a coordinated resource scheduling method based on a flow matching model was proposed. An optimization model considering task delay, system energy consumption, and deadline violations was formulated, and a three-layer trajectory—resource—offloading mechanism was designed. UAV deployment was optimized through convex inner approximation and sequential optimization, resource-priority and transmit-power candidates were generated and screened using the flow matching model, and task partitioning was optimized based on path availability and queueing feedback. In simulations, lower total system delay and energy-delay product, as well as a higher task success rate, were achieved by the proposed method. The proposed method effectively improves service assurance for delay-sensitive tasks.

**Key words:** IoV, UAV-assisted edge computing, flow matching model, coordinated resource scheduling, service assurance

收稿日期: 2026-08-11; 修回日期: 2026-09-18

通信作者: 喻鹏, yupeng@bupt.edu.cn

基金项目: 北京市自然基金—海淀原始创新联合基金(批准号:L232045)

**Foundation Items:** Beijing Natural Science Foundation - Haidian Original Innovation Joint Fund (Approval Number: L232045)

## 0 引言

随着智能网联汽车的快速普及,自动驾驶、增强现实导航等车载应用不断涌现,此类任务普遍具有时延敏感与计算密集的双重特征,而车载终端的计算能力难以独立支撑其严苛的截止期约束<sup>[1]</sup>。移动边缘计算(mobile edge computing, MEC)通过将计算资源下沉至网络边缘,为车辆提供了低时延的任务卸载途径<sup>[2]</sup>。然而,地面基础设施部署位置固定,在交通热点区域易发生负载聚集,且路侧覆盖存在盲区,难以适应车流时空分布的动态变化。

无人机(unmanned aerial vehicle, UAV)凭借机动灵活、视距链路概率高的优势,可作为空中边缘节点对地面网络进行动态补充,无人机辅助车联网因此受到广泛关注<sup>[1,3]</sup>。在此类系统中,网络性能取决于三个相互耦合的决策层面:无人机轨迹控制决定覆盖范围与信道质量,通信资源分配决定各链路的传输速率,任务卸载决策则在此基础上权衡本地、基站与无人机三条计算路径的时延与能耗。随着车辆位置、任务负载和节点队列动态变化,空中覆盖、无线传输与边缘计算资源容易出现供需失配。无人机轨迹决定空中覆盖和计算资源的空间分布,无线资源配置决定链路传输能力,任务卸载则协调不同计算节点的负载。本文将三者根据实时网络与任务状态进行跨层协调的过程称为协同资源调度。

围绕协同资源调度问题,现有研究主要包括模型驱动和学习驱动两类方法。模型驱动方法能够显式处理覆盖、功率与计算容量等约束<sup>[4-5]</sup>,但部分研究主要面向准静态状态或单一决策周期,对车流移动、任务到达和节点排队的持续变化考虑不足;同时,现有工作多侧重平均时延或系统能耗,对时延敏感任务的截止期违约关注有限。基于深度强化学习(deep reinforcement learning, DRL)的方法能够从交互数据中学习动态调度策略<sup>[6-8]</sup>,但通常以长期平均回报为目标,对截止期与队列约束缺乏显式保障。此外,现有DRL方法多采用确定性策略,在由资源优先级和发射功率构成的高维多峰空间中仅输出单一决策,容易陷入局部最优。因此,如何兼顾截止期保障与资源搜索质量仍面临挑战。

近年来,以扩散模型和流匹配(flow matching)模型为代表的生成式模型在无线资源管理领域展现出潜力<sup>[9-10]</sup>。与判别式的策略网络不同,生

成式模型学习的是条件解分布本身,具备刻画多峰解空间、产生多样化候选决策的能力;其中流匹配以常微分方程刻画从噪声分布到目标分布的传输路径,其可通过较少积分步生成多样化候选。

因此,本文提出一种基于流匹配模型的时延敏感任务协同资源调度方法。主要贡献如下:

1) 构建了面向时延敏感任务的协同资源调度模型,综合考虑通信传输、边缘计算、任务排队与系统能耗,协调优化无人机三维位置、无线资源配置和三路任务卸载比例。

2) 设计了轨迹—资源—卸载三层协同求解框架。轨迹层采用凸内近似与顺序求解调整无人机三维位置,卸载层利用混合整数线性规划(mixed integer linear programming, MILP)结合路径可用性和排队反馈迭代修正任务拆分比例,实现覆盖、传输与计算资源的协同调度。

3) 提出基于流匹配模型的资源分配方法FlowRA(flow matching-based resource allocation)。该方法根据任务负载和链路状态学习发射功率与资源优先级的条件候选分布,运行时并行生成多个候选,经资源块解码和卸载代价评价后择优执行,以提升高维资源空间中的搜索能力。

本文其余部分安排如下:第2节介绍系统模型与问题建模;第3节详述协同资源调度框架及各层算法;第4节给出实验验证;第5节总结全文。

## 1 相关工作

本节梳理了无人机辅助车联网中协同资源调度的现有研究,并分析已有方法的局限,并阐明了本文的研究动机。

### 1.1 无人机辅助车联网中的联合优化方法

无人机轨迹与通信资源的联合设计已经受到广泛关注。Wu等<sup>[4]</sup>针对多无人机使能的无线网络,将用户调度、功率控制与轨迹设计建模为混合整数非凸规划,提出基于块坐标下降(block coordinate descent, BCD)与逐次凸近似(successive convex approximation, SCA)的迭代算法,该分解框架成为后续大量工作的方法论基础;Zeng等<sup>[11]</sup>为旋翼无人机建立了闭式推进功耗模型,通过路径离散化与SCA联合优化悬停位置与飞行轨迹,在满足吞吐量需求的前提下最小化无人机能耗;Cui等<sup>[12]</sup>进一步在无人机网络中联合设计多址接入方式、轨迹

与资源分配,验证了通信与轨迹协同优化的增益。

随着 MEC 的发展,联合优化框架被扩展至计算卸载场景。Jeong 等<sup>[13]</sup>研究了无人机搭载计算单元时比特分配与路径规划的联合优化,利用 SCA 在时延与能量预算约束下最小化终端能耗;Zhou 等<sup>[14]</sup>在无线供能的无人机边缘计算系统中推导了中央处理器(central processing unit, CPU)频率与卸载时间的闭式解;Hu 等<sup>[15]</sup>将卸载决策、资源调度与轨迹设计纳入统一的时延最小化框架,采用交替优化算法求解;Zhang 等<sup>[16]</sup>面向随机任务到达,研究了长期系统能耗优化。然而,部分研究在固定飞行高度下规划二维轨迹,未充分利用无人机三维机动能力动态调整覆盖范围;此外,部分研究采用相对稳定的用户分布、信道或任务需求,难以刻画车流热点迁移引起的覆盖与资源需求变化。

上述研究表明,模型驱动方法能够显式刻画覆盖、功率和计算容量等约束,但现有模型对车辆移动、任务负载与链路状态的联合动态描述不足。预先确定的无人机轨迹与资源方案可能随车流变化迅速失配。因此,需要根据实时任务和网络状态,协同调整无人机三维位置、无线资源与卸载路径。

## 1.2 基于深度强化学习的资源调度与任务卸载

近年来,大量研究采用 DRL 进行资源调度与任务卸载。He 等<sup>[17]</sup>将车联网中的组网、缓存与计算资源统一纳入 DRL 决策框架;Tan 等<sup>[18]</sup>在此基础上考虑车辆移动性,联合优化边缘缓存与计算调度;Ning 等<sup>[19]</sup>以用户体验质量最大化为目标,结合双边匹配与 DRL 构建了智能卸载系统;Liu 等<sup>[20]</sup>将车辆边缘计算中的卸载与资源分配建模为半马尔可夫决策过程并采用 DRL 求解。此类集中式方法验证了学习范式在动态网络决策中的可行性,但单智能体架构难以适应多无人机系统的分布式决策需求。

为此,多智能体架构得到广泛采用。Wang 等<sup>[21]</sup>利用深度确定性策略梯度(deep deterministic policy gradient, DDPG)为多无人机边缘计算规划轨迹;Zhao 等<sup>[22]</sup>提出多智能体 DRL 任务卸载方法,实现无人机间的协同负载均衡;Seid 等<sup>[23]</sup>将多无人机网络中的卸载与资源分配建模为随机博弈,以多智能体深度强化学习(multi-agent deep reinforcement learning, MADRL)最小化长期时延-能耗成本。近期工作进一步融入先验信息:Li 等<sup>[24]</sup>

引入专家知识辅助多智能体训练,联合优化卸载决策与无人机轨迹;Li 等<sup>[25]</sup>针对部分信道状态信息可得的场景,提出基于多智能体近端策略优化的鲁棒卸载与轨迹设计方法。

上述方法提高了动态环境中的自适应决策能力,但其优化目标多侧重长期平均时延、能耗或传输效率,对单任务截止期违约、服务器排队和不同计算路径的负载差异关注有限,因而难以直接保障时延敏感任务的完成质量。此外,现有 DRL 方法普遍采用确定性策略网络,将高维多峰资源空间映射为单一动作,训练易受局部最优影响,也难以利用多个性能相近的候选方案提升决策稳定性。

近年来,生成式模型为突破上述局限提供了新思路。生成式方法通过学习条件决策分布,可针对同一网络状态产生多个候选。扩散模型具有较强的分布表达能力<sup>[9]</sup>,但通常依赖多步去噪,生成多候选时采样开销较大;VAE 采样较快,但候选质量依赖潜变量表示与解码器;随机采样无需训练,却不能利用网络状态与低代价动作之间的映射,在高维动作空间中的有效采样率较低。流匹配通过条件速度场学习噪声到目标动作的连续传输<sup>[10]</sup>,能够从不同初始噪声生成多样化候选,并以较少积分步完成采样。基于此,本文利用流匹配模型进行资源分配。

## 2 系统模型和问题建模

本章建立多无人机辅助车联网边缘计算系统的数学模型:2.1 节概述系统组成,2.2 节至 2.4 节依次建立无人机轨迹模型、通信模型以及任务计算与排队模型,2.5 给出了联合优化目标。

### 2.1 系统概述

考虑如图 1 所示的多无人机辅助车联网边缘计



图1 多无人机辅助车联网边缘计算环境

算系统, 由1个基站、 $U$ 架旋翼无人机与 $M$ 辆车辆组成, 分别记无人机集合为 $\mathcal{U} = \{1, \dots, U\}$ , 车辆集合为 $\mathcal{M} = \{1, \dots, M\}$ 。基站配备边缘计算服务器; 无人机作为空中边缘节点搭载计算单元; 车辆沿城市道路行驶, 周期性产生时延敏感的计算任务。

系统按帧运行, 每帧时长 $T_f$ , 包含 $N_s$ 个等长传输时隙。在第 $t$ 帧内, 系统依次完成四个环节: □ 车辆位置更新, 车辆 $m$ 产生数据量为 $D_m(t)$ 的计算任务; □ 无人机根据当前车流分布调整三维部署位置; □ 系统为各通信链路分配资源块与发射功率; □ 每个任务按比例 $\gamma_m^l(t)$ 、 $\gamma_m^i(t)$ 、 $\gamma_{m,u}^u(t)$ 拆分为三部分, 分别由本地车载处理器执行、经车对基础设施 (vehicle-to-infrastructure, V2I) 链路卸载至基站执行、经车对无人机 (vehicle-to-UAV, V2U) 链路卸载至无人机 $u$ 执行, 三条路径并行处理。任务须在时延阈值 $\tau_{\max}$ 内完成, 否则视为违约。V2I链路对全部车辆可用, 而V2U链路仅对处于无人机覆盖范围内的车辆可用, 每辆车在每帧仅关联可连接无人机中大尺度信道质量最高的一架。本文采用正交RB-时隙资源分配, 不同链路不在同一资源单元上复用, 因此链路速率主要考虑噪声影响。

## 2.2 无人机移动与覆盖模型

记第 $t$ 帧无人机 $u$ 的三维位置为 $\mathbf{q}_u(t) = (x_u(t), y_u(t), z_u(t))$ , 车辆 $m$ 的位置为 $\mathbf{p}_m(t)$ 。无人机以固定半张角 $\theta$ 向下辐射, 其地面覆盖半径随飞行高度线性变化:

$$R_u(t) = z_u(t) \tan \theta \quad (1)$$

车辆 $m$ 与无人机 $u$ 之间存在可用V2U链路, 当且仅当车辆处于其覆盖圆内, 定义连接指示变量:

$$c_{m,u}(t) = \begin{cases} 1, & \|\mathbf{p}_m(t) - (x_u(t), y_u(t))\| \leq R_u(t) \\ 0, & \text{其他} \end{cases} \quad (2)$$

若车辆 $m$ 被多架无人机覆盖时, 则选择大尺度信道质量最优的一架关联:

$$u_m^*(t) = \arg \max_{u \in \mathcal{U}: c_{m,u}(t)=1} \bar{g}_{m,u}(t) \quad (3)$$

其中 $\bar{g}_{m,u}(t)$ 为V2U大尺度平均信道增益。实际关联的无人机为:

$$\alpha_{m,u}(t) = c_{m,u}(t) \mathbb{I}\{u = u_m^*(t)\} \quad (4)$$

受机动能力与空域管制限制, 无人机相邻帧间的位置调整须满足:

$$\|(x_u(t), y_u(t)) - (x_u(t-1), y_u(t-1))\| \leq v_{\max} T_f, \quad \forall u, t \quad (5)$$

$$|z_u(t) - z_u(t-1)| \leq \Delta z_{\max}, z_{\min} \leq z_u(t) \leq z_{\max}, \quad \forall u, t \quad (6)$$

同时, 任意两架无人机间须保持最小安全距离以保障飞行安全:

$$\|\mathbf{q}_u(t) - \mathbf{q}_{u'}(t)\| \geq d_{\min}, \quad \forall u \neq u', \forall t \quad (7)$$

无人机的飞行能耗采用旋翼机型的功率模型<sup>[11]</sup>构建。设第 $t$ 帧无人机 $u$ 的水平速度为 $v_u^x(t)$ 、垂直速度为 $v_u^z(t)$  (向上为正), 其水平飞行功率为:

$$P^h(v^x) = \max \left\{ \frac{P_{\text{hov}}}{1 + (v^x/v_r)^2} + c_d (v^x)^3, \rho P_{\text{hov}} \right\} \quad (8)$$

其中 $P_{\text{hov}}$ 为悬停功率, 第一项为随速度增大而衰减的诱导功率 ( $v_r$ 为参考速度), 第二项为随速度三次方增长的废阻功率 ( $c_d$ 为机身阻力系数),  $\rho P_{\text{hov}}$ 为经济巡航功率下限。垂直方向的爬升/下降功率为:

$$P^v(v^z) = \begin{cases} m_{\text{uav}} g v^z + c_c (v^z)^2, & v^z > 0 \\ \frac{1}{2} m_{\text{uav}} g v^z, & v^z \leq 0 \end{cases} \quad (9)$$

其中 $m_{\text{uav}}$ 为无人机质量,  $g$ 为重力加速度,  $c_c$ 为爬升气动损耗系数。计入机载电子设备的基础功耗 $P_0$ , 无人机 $u$ 在第 $t$ 帧的飞行能耗为:

$$E_u(t) = \left[ P_0 + \max \left\{ \rho P_{\text{hov}}, P^h(v_u^x(t)) \right\} + P^v(v_u^z(t)) \right] T_f \quad (10)$$

## 2.3 通信模型

系统总带宽划分为 $K$ 个正交资源块 (resource block, RB), 每块带宽为 $B_0$ , 在每帧的 $N_s$ 个时隙上复用, 构成 $K \times N_s$ 个资源块-时隙单元。定义二元分配变量 $x_{m,k,s}^i(t)$ 与 $x_{m,u,k,s}^u(t)$ , 分别表示资源块 $k$ 在时隙 $s$ 是否分配给车辆 $m$ 的V2I链路或车辆 $m$ 至无人机 $u$ 的V2U链路, 本节分别建立两类链路的信道与速率模型。

### 2.3.1 V2I传输模型

V2I链路工作在蜂窝频段, 其大尺度衰落由路径损耗与阴影衰落组成。车辆 $m$ 与基站间的路径损耗采用城市宏蜂窝模型 (dB):

$$L_m^i(t) = 128.1 + 37.6 \log_{10}(d_m^i(t)) \quad (11)$$

其中  $d_m^i(t)$  为车辆天线与基站天线间的三维距离 (km)。阴影衰落  $S_m(t)$  服从标准差为  $\sigma_s$  的对数正态分布, 并随车辆移动按指数相关模型演化。V2I 链路以非视距传播为主, 各资源块上的小尺度衰落系数  $h_{m,k}^i(t)$  服从瑞利分布。综上, 车辆  $m$  在资源块  $k$  上的 V2I 信道功率增益为:

$$g_{m,k}^i(t) = 10^{-(L_m^i(t) + S_m(t) - G_v - G_{bs})/10} |h_{m,k}^i(t)|^2 \quad (12)$$

其中  $G_v$ 、 $G_{bs}$  分别为车辆与基站的天线增益。设  $P_m(t)$  为第  $t$  帧内车辆的总发射功率, 上限为  $P_{\max}$ , 当车辆在同一时隙获得多个 RB 时, 总发射功率在其占用的全部 V2I 和 V2U RB 之间等分。记  $n_m(t,s)$  为时隙  $s$  内分配给车辆  $m$  的 RB 总数, 则其单 RB 实际发射功率  $p_m(t,s)$  为:

$$\begin{aligned} n_m(t,s) &= \sum_{k=1}^K x_{m,k,s}^i(t) + \sum_{u \in \mathcal{U}} \sum_{k=1}^K x_{m,u,k,s}^u(t), \\ p_m(t,s) &= \begin{cases} \frac{P_m(t)}{n_m(t,s)}, & n_m(t,s) > 0, \\ 0, & n_m(t,s) = 0. \end{cases} \end{aligned} \quad (13)$$

则 V2I 链路的等效平均可达速率为:

$$R_m^i(t) = \frac{1}{N_s} \sum_{s=1}^{N_s} \sum_{k=1}^K x_{m,k,s}^i(t) B_0 \log_2 \left( 1 + \frac{p_m(t,s) g_{m,k}^i(t)}{B_0 N_0 F_{bs}} \right) \quad (14)$$

其中  $N_0$  为噪声功率谱密度,  $F_{bs}$  为基站接收机噪声系数。

### 2.3.2 V2U 传输模型

V2U 链路为空地信道, 视距 (line-of-sight, LoS) 传播概率随仰角增大而提高。记车辆  $m$  与无人机  $u$  间的三维距离为  $d_{m,u}^u(t)$ , 仰角为  $\varphi_{m,u}(t) = \frac{180}{\pi} \arcsin\left(\frac{z_u(t)}{d_{m,u}^u(t)}\right)$ , 则 LoS 概率采用经典空地信道模型刻画:

$$\Pr_{m,u}^{\text{LoS}}(t) = \frac{1}{1 + \omega_a \exp(-\omega_b(\varphi_{m,u}(t) - \omega_a))} \quad (15)$$

其中  $\omega_a$ 、 $\omega_b$  为由传播环境决定的常数,  $\varphi_{m,u}(t)$  以度为单位。V2U 平均路径损耗由自由空间损耗与附加损耗的概率加权组成 (dB):

$$L_{m,u}^u(t) = 20 \log_{10} \left( \frac{4\pi f_c d_{m,u}^u(t)}{c_0} \right) + \Pr_{m,u}^{\text{LoS}}(t) \eta_{\text{LoS}} + (1 - \Pr_{m,u}^{\text{LoS}}(t)) \eta_{\text{NLoS}} \quad (16)$$

其中  $f_c$  为 V2U 载波频率,  $c_0$  为光速,  $\eta_{\text{LoS}}$ 、 $\eta_{\text{NLoS}}$  分别为视距与非视距条件下的附加损耗。由于 V2U 链路存在较强的直射分量, 小尺度衰落采用莱斯因子为  $K_r$  的莱斯模型刻画, 与式(12)同理可得 V2U 信道功率增益  $g_{m,u,k}^u(t)$ , 其中天线增益为  $G_v$  与  $G_{\text{uav}}$ 。车辆  $m$  的 V2U 链路可达速率为:

$$R_{m,u}^u(t) = \frac{\alpha_{m,u}(t)}{N_s} \sum_{s=1}^{N_s} \sum_{k=1}^K x_{m,u,k,s}^u(t) B_0 \log_2 \left( 1 + \frac{p_m(t,s) g_{m,u,k}^u(t)}{B_0 N_0 F_{\text{uav}}} \right) \quad (17)$$

其中  $F_{\text{uav}}$  为无人机接收机噪声系数, 因子  $\alpha_{m,u}(t)$  保证仅覆盖范围内的链路可用。

### 2.4 任务计算与排队模型

车辆  $m$  的任务  $D_m(t)$  按比例  $\gamma_m^l(t)$ 、 $\gamma_m^i(t)$ 、 $\gamma_{m,u}^u(t)$  拆分为本地、基站与无人机三部分并行处理, 处理 1 bit 数据所需 CPU 周期数为  $c$ , 本地、无人机与基站的计算频率分别为  $f_l$ 、 $f_u$  与  $f_i$ 。

#### 2.4.1 任务计算模型

任务的本地份额、基站份额与无人机份额分别由车载处理器、基站服务器和无人机计算单元执行。三类节点对应的计算时延为:

$$\begin{aligned} T_m^l(t) &= \frac{\gamma_m^l(t) D_m(t) c}{f_l}, T_m^{i,\text{cp}}(t) = \frac{\gamma_m^i(t) D_m(t) c}{f_i}, \\ T_{m,u}^{u,\text{cp}}(t) &= \frac{\gamma_{m,u}^u(t) D_m(t) c}{f_u} \end{aligned} \quad (18)$$

依据动态电压频率调节下的 CMOS 功耗模型, 相应的计算能耗为:

$$\begin{aligned} E_m^{l,\text{cp}}(t) &= \kappa f_l^2 \gamma_m^l(t) D_m(t) c, \\ E_m^{i,\text{cp}}(t) &= \kappa f_i^2 \gamma_m^i(t) D_m(t) c, \\ E_{m,u}^{u,\text{cp}}(t) &= \kappa f_u^2 \gamma_{m,u}^u(t) D_m(t) c \end{aligned} \quad (19)$$

其中  $\kappa$  为芯片有效电容系数。计算时延随处理频率升高而缩短, 计算能耗则与处理频率的平方成正比。

#### 2.4.2 任务排队模型

卸载份额须先经无线链路上传, 再在边缘节点排队与执行。本文采用逐帧任务结算机制, 各帧任务独立排队与处理, 超出时延阈值的任务记为违约且不延续至下一帧。每帧新任务按照上传完成时刻

重新排序, 并采用先到先服务 (First-Come First-Served, FCFS) 规则依次执行。以基站路径为例, 车辆  $m$  的上传时延为:

$$T_m^{i,tx}(t) = \frac{\gamma_m^i(t)D_m(t)}{R_m^i(t)} \quad (20)$$

任务到达基站的时刻即其上传完成时刻。基站按 FCFS 规则依次执行到达的任务, 车辆  $m$  的任务在基站的服务时长为  $\gamma_m^i(t)D_m(t)c/f_i$ 。将当帧向基站卸载的任务按到达时刻升序排列, 记第  $j$  个任务的到达时刻为  $a_{(j)}$ 、服务时长为  $e_{(j)}$ , 则其开始服务时刻  $b_{(j)}$  与排队时延  $W_{(j)}$  满足递推:

$$b_{(j)} = \max\{a_{(j)}, b_{(j-1)} + e_{(j-1)}\}, \quad W_{(j)} = b_{(j)} - a_{(j)} \quad (21)$$

由此, 车辆  $m$  经基站路径的总时延为:

$$T_m^i(t) = T_m^{i,tx}(t) + W_m^i(t) + \frac{\gamma_m^i(t)D_m(t)c}{f_i} \quad (22)$$

无人机按照相同的 FCFS 规则处理已上传任务。对于车辆实际关联且可用的 V2U 路径, 其上传时延按照对应链路速率计算; 未关联或不可用的 V2U 路径不参与卸载, 其卸载比例置为 0, 也不计算相应的上传时延。卸载至无人机  $u$  的上传时延为  $T_{m,u}^{u,tx}(t) = \gamma_{m,u}^u(t)D_m(t)/R_{m,u}^u(t)$ , 其排队时延记为  $W_{m,u}^u(t)$ 。无人机子路径时延为:

$$T_{m,u}^u(t) = T_{m,u}^{u,tx}(t) + W_{m,u}^u(t) + T_{m,u}^{u,cp}(t) \quad (23)$$

车辆  $m$  的无人机路径时延为:

$$T_m^u(t) = \sum_{u \in \mathcal{U}} \alpha_{m,u}(t) T_{m,u}^u(t) \quad (24)$$

每辆车最多关联一架无人机, 式 (24) 实际取

$$\begin{aligned} \mathbf{P0}(t): \quad & \min \quad \omega_1 T_\Sigma(t) + \omega_2 E_\Sigma(t) + \omega_3 V_\Sigma(t) \\ \text{s.t. C1:} \quad & \sum_{m \in \mathcal{M}} x_{m,k,s}^i(t) + \sum_{m \in \mathcal{M}} \sum_{u \in \mathcal{U}} x_{m,u,k,s}^u(t) \leq 1, \forall k, s \\ \text{C2:} \quad & x_{m,k,s}^i(t), x_{m,u,k,s}^u(t) \in \{0, 1\}, \forall m, u, k, s \\ \text{C3:} \quad & 0 \leq P_m(t) \leq P_{\max}, \quad \forall m \\ \text{C4:} \quad & \gamma_m^l(t) + \gamma_m^i(t) + \sum_{u \in \mathcal{U}} \gamma_{m,u}^u(t) = 1, \forall m \\ \text{C5:} \quad & \gamma_m^l(t), \gamma_m^i(t), \gamma_{m,u}^u(t) \geq 0, \forall m, u \\ \text{C6:} \quad & \gamma_{m,u}^u(t) \leq \alpha_{m,u}(t), \forall m, u \\ \text{C7:} \quad & \text{式 (5)(6)(7)} \end{aligned} \quad (28)$$

其中  $\omega_1$ 、 $\omega_2$ 、 $\omega_3$  为尺度平衡权重, 用于协调系统总时延、总能耗和时延违约量三项指标的数值尺度与优化优先级。考虑到本文面向时延敏感任务, 权

关联无人机路径的时延。

### 2.4.3 系统总时延与总能耗

三条路径并行执行, 车辆  $m$  的任务完成时延取三者最大值:

$$T_m(t) = \max\{T_m^l(t), T_m^i(t), T_m^u(t)\} \quad (25)$$

相应的时延违约量为  $V_m(t) = \max\{0, T_m(t) - \tau_{\max}\}$ , 第  $t$  帧的总时延与总违约量分别为  $T_\Sigma(t) = \sum_{m \in \mathcal{M}} T_m(t)$  与  $V_\Sigma(t) = \sum_{m \in \mathcal{M}} V_m(t)$ 。

车辆  $m$  的任务处理能耗包括三处计算能耗与两路传输能耗:

$$\begin{aligned} E_m(t) = & E_m^{l,cp}(t) + E_m^{i,cp}(t) + \sum_{u \in \mathcal{U}} E_{m,u}^{u,cp}(t) \\ & + P_m^i(t)T_m^{i,tx}(t) + \sum_{u \in \mathcal{U}} P_{m,u}^u(t)T_{m,u}^{u,tx}(t) \end{aligned} \quad (26)$$

其中,  $P_m^i(t)$  和  $P_{m,u}^u(t)$  分别为 V2I 和 V2U 链路的等效平均发射功率, 由单 RB 实际功率及实际 RB 占用情况计算。两类链路共享车辆总功率预算, 并满足  $P_m^i(t) + \sum_{u \in \mathcal{U}} P_{m,u}^u(t) \leq P_m(t)$ 。

系统总能耗同时计入任务处理能耗与无人机飞行能耗, 即:

$$E_\Sigma(t) = \sum_{m \in \mathcal{M}} E_m(t) + \sum_{u \in \mathcal{U}} E_u(t) \quad (27)$$

## 2.5 问题构建

本文以系统总时延、总能耗与时延违约量的加权和为优化目标, 联合优化各帧的无人机三维轨迹  $\{\mathbf{q}_u(t)\}$ 、RB 分配  $\{x_{m,k,s}^i(t), x_{m,u,k,s}^u(t)\}$ 、车辆总发射功率  $P_m(t)$  与任务卸载比例  $\{\gamma_m^l(t), \gamma_m^i(t), \gamma_{m,u}^u(t)\}$ , 问题建模为:

重设置在平衡时延与能耗的同时, 优先保障任务截止期。此外,  $C_1$ 、 $C_2$  为资源块正交分配约束,  $C_3$  为车辆总发射功率约束,  $C_4 \sim C_6$  保证任务拆分的可

行性,  $C_7$  为无人机机动性与飞行安全约束。

问题 P0 同时包含离散与连续决策变量, 属于混合整数非凸规划; 速率与排队过程使目标函数与决策变量之间存在跨层非线性耦合。为此, 第 3 章提出分层求解框架, 将原问题分解为轨迹控制、资源分配与任务卸载三个子问题, 逐层高效求解。

### 3 基于流匹配模型的协同资源调度方法

本章针对问题 P0 提出分层求解框架。3.1 节阐述分层依据与框架构成, 3.2 节至 3.4 节分别给出轨迹层、资源层与卸载层的求解方法, 3.5 节给出整体算法流程并分析计算复杂度。

#### 3.1 分层求解框架

问题 P0 同时包含连续轨迹变量、离散资源变量与排队耦合, 难以在单帧时限内整体求解。无人机位置首先确定覆盖范围与信道状态, 资源分配随后确定链路速率, 任务卸载最终依据速率和排队先验确定拆分比例。据此, 本文构建三层顺序求解框架, 以获得 P0 的可执行近似解。该分层过程并非将 P0 分解为三个独立子问题, 而是依据无人机轨迹、链路速率与任务卸载之间的依赖关系逐层固定变量。P1 是针对轨迹变量构造的可解代理问题。其中, 任务负载加权覆盖促使无人机优先服务需求较高的车辆, 飞行高度用于权衡覆盖范围与链路质量, 机动代价则限制无人机位移和升降带来的飞行开销。P1 得到的无人机位置将更新覆盖关系和信

道状态, 资源层据此确定链路速率, 卸载层再结合链路速率与节点队列完成任务拆分, 最终共同作用于 P0 中的时延、能耗和截止期违约量。

整体流程如图 2 所示。轨迹层将部署子问题凸化为二阶锥规划 (second-order cone programming, SOCP) 并逐机求解。资源层采用 FlowRA 生成候选动作, 经确定性解码得到功率与整数资源变量, 再择优选定执行动作。卸载层在选定资源方案下, 通过 MILP 与排队反馈迭代修正任务拆分比例。

#### 3.2 无人机轨迹优化求解

轨迹层在每帧开始时, 依据当前车辆分布与任务负载为每架无人机决策新的三维位置。无人机位置通过覆盖关系与信道增益影响后续两层, 因此轨迹层加权覆盖效用、飞行高度和机动代价为目标。

首先, 由于覆盖指示与机间安全距离使轨迹优化问题呈现非凸性。对此采取两项凸化处理。其一, 将覆盖指示松弛为连续变量  $s_j \in [0, 1]$ , 并为覆盖约束引入非负松弛量  $\epsilon_j$ 。其二, 将机间距约束在上一帧可行位置处线性内近似, 以切平面  $\mathbf{n}_{u,u'}^T (\mathbf{o}_u - \mathbf{o}_{u'}) \geq d_{\min}$  替代原非凸约束, 其中  $\mathbf{o}_u = (x_u, y_u)$  为水平位置,  $\mathbf{n}_{u,u'}$  为由参考位置  $\mathbf{o}_{u'}$  指向  $\mathbf{o}_u$  的单位向量,  $\mathbf{o}_{u'}$  表示上一帧取值。机动代理代价定义为:

$$C_u^{\text{mv}} = \|\mathbf{o}_u - \mathbf{o}_{u'}\|^2 + \mu_a [z_u - z_{u'}]^+ + \mu_d [z_{u'} - z_u]^+ \quad (29)$$

其中  $[ \cdot ]^+ = \max \{ \cdot, 0 \}$ , 对爬升的惩罚高于下降 ( $\mu_a > \mu_d$ )。由此, 无人机  $u$  的轨迹优化目标为:




图2 分层联合优化算法流程

$$\begin{aligned}
\text{P1: } \min_{x_u, y_u, z_u, \{s_j\}, \{\epsilon_j\}} & -\lambda_c \sum_{j \in \mathcal{M}_u} w_j s_j + \lambda_h z_u \\
& + \lambda_e C_u^{\text{mv}} + \lambda_\epsilon \sum_{j \in \mathcal{M}_u} \epsilon_j \\
\text{s.t.} & \left\| \mathbf{p}_j - \mathbf{o}_u \right\| \leq z_u \tan \theta + C_B (1 - s_j) \\
& + \epsilon_j, \forall j \in \mathcal{M}_u \\
& \mathbf{n}_{u,u'}^T (\mathbf{o}_u - \mathbf{o}_{u'}) \geq d_{\min}, \forall u' \neq u \\
& 0 \leq s_j \leq 1, \epsilon_j \geq 0, \forall j \in \mathcal{M}_u
\end{aligned} \tag{30}$$

式 (5)(6)

其中  $\mathcal{M}_u$  为待覆盖车辆集合,  $w_j$  为随任务负载递增的覆盖权重,  $C_B$  为充分大常数。目标函数由加权覆盖、飞行高度、机动代价和覆盖松弛惩罚。各组约束分别描述松弛覆盖关系、机间安全距离的线性内近似、变量范围以及式(5)(6)给出的机动与高度限制,  $\epsilon_j$  用于保持可行性。经上述处理, P1 构成小规模 SOCP, 可以使用内点求解器直接求解。

多机联合轨迹优化采用顺序求解策略。按固定编号依次求解各机的 P1, 求解第  $u$  架无人机时将  $u-1$  前架已覆盖的车辆从  $\mathcal{M}_u$  中剔除, 使各机分工于尚未覆盖的区域。同时以线性约束将各机水平位置限定于预划分的责任区内, 避免多机聚集。

### 3.3 基于流匹配的资源分配模型

资源层为车辆确定发射功率和资源块-时隙单元。本文以连续向量表征逐车资源决策, 由 FlowRA 学习低代价动作的条件分布并确定资源方案。

#### 3.3.1 资源动作表征与代价评价

系统状态记为  $\mathbf{s} \in \mathbb{R}^{4M}$ 。每辆车对应四维特征, 依次为归一化任务负载、V2I 大尺度链路质量、关联无人机对应的 V2U 大尺度链路质量以及 V2U 可连接指示。所有车辆特征按固定编号拼接后输入 FlowRA。基站和无人机队列不作为速度场的条件输入, 而是在在线评价中直接用于候选排序。在任务和链路状态相同而队列状态不同时, FlowRA 的条件候选分布保持不变, 但候选排序和最终卸载结果随队列先验调整。车辆编号仅用于确定各车辆特征的输入顺序, 当前考虑固定的车辆数。

FlowRA 为每辆车生成一个功率分量和一个资源权重分量, 动作定义为:

$$\mathbf{a} = (a_m^p, a_m^\rho)_{m \in \mathcal{M}} \in [0, 1]^{2M} \tag{31}$$

动作解码为:

$$\begin{aligned}
\bar{P}_m &= P_{\min} + a_m^p (P_{\max} - P_{\min}), \\
P_m &= 10^{(\bar{P}_m - 30)/10}, \\
\rho_m &= \max\{\rho_{\min}, a_m^\rho\},
\end{aligned} \tag{32}$$

其中  $\bar{P}_m$  的单位为 dBm,  $P_m$  的单位为 W,  $P_m$  为 FlowRA 为车辆  $m$  生成的总发射功率。完成 RB 分配后, 车辆总功率在同一时隙占用的全部 V2I 和 V2U RB 之间等分。因此, FlowRA 只需为每辆车输出一个功率分量。

记当前帧活跃链路集合为  $\mathcal{L}$ , 链路  $\ell \in \mathcal{L}$  继承所属车辆  $m(\ell)$  的权重, 即  $\rho_\ell = \rho_{m(\ell)}$ 。资源单元总数为  $KN_s$ , 链路配额写为:

$$\begin{aligned}
b &= \mathbb{I}(|\mathcal{L}| \leq KN_s), \quad N_r = KN_s - b|\mathcal{L}|, \\
n_\ell &= b + \left\lfloor N_r \frac{\rho_\ell}{\sum_{\ell' \in \mathcal{L}} \rho_{\ell'}} \right\rfloor + \delta_\ell, \quad \ell \in \mathcal{L},
\end{aligned} \tag{33}$$

其中  $b$  表示保底配额,  $\delta_\ell \in \{0, 1\}$  用于补齐取整余量, 并满足  $\sum_{\ell \in \mathcal{L}} n_\ell = KN_s$ 。

记资源集合为  $\Omega = \{(k, s) \mid 1 \leq k \leq K, 1 \leq s \leq N_s\}$ ,  $\pi_t(j)$  表示第  $t$  帧固定排列中的第  $j$  个资源单元。链路按任务负载和资源权重降序编号为  $\ell_1, \dots, \ell_{|\mathcal{L}|}$ , 令  $q_0 = 0$ , 其具体分配为:

$$\begin{aligned}
q_r &= \sum_{p=1}^r n_{\ell_p}, \\
\Omega_{\ell_r} &= \{\pi_t(j) \mid q_{r-1} < j \leq q_r\}, \\
x_{\ell_r, k, s} &= \mathbb{I}((k, s) \in \Omega_{\ell_r}).
\end{aligned} \tag{34}$$

为降低动作维度和在线生成开销, FlowRA 采用逐车动作表示, 同一车辆的 V2I 与 V2U 链路共享发射功率和资源权重, 但两类链路的速率仍根据各自获得的 RB 及实际信道增益分别计算。式 (34) 中的资源单元顺序在每帧内固定, 并对所有候选动

作保持一致,从而避免在高维动作空间中直接搜索组合规模较大的逐RB分配。该简化适用于各RB统计特性相近的场景。动作解码后即可计算V2I与V2U速率。资源层使用当前排队先验 $\bar{\mathbf{Q}}$ 求解一次排队感知卸载问题P3,以所得时延、任务能耗和违约束量构造候选评价价值:

$$\tilde{J}(\mathbf{a}; \mathbf{s}, \bar{\mathbf{Q}}) = \sum_{m \in \mathcal{M}} [\omega_1 \tilde{T}_m(\mathbf{a}) + \omega_2 \tilde{E}_m(\mathbf{a}) + \omega_3 \tilde{V}_m(\mathbf{a})] \quad (35)$$

据此,资源动作选取问题写为:

$$\mathbf{P2}: \min_{\mathbf{a} \in [0,1]^{2M}} \tilde{J}(\mathbf{a}; \mathbf{s}, \bar{\mathbf{Q}}) \quad (36)$$

P2即在连续动作空间内搜索低评价价值资源动作。

### 3.3.2 面向资源动作的条件速度场建模

基于上述动作空间与评价函数,FlowRA以系统状态 $\mathbf{s}$ 为条件,学习低代价资源动作的分布。设 $\mathbf{x}_0 \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$ 为源噪声, $\mathbf{a}^*$ 为经式(35)筛选的低代价资源动作。对于随机流时间 $\tau \in [0,1]$ ,构造从噪声到目标动作的线性路径及其目标速度<sup>[10]</sup>:

$$\mathbf{x}_\tau = (1 - \tau)\mathbf{x}_0 + \tau\mathbf{a}^*, \quad \mathbf{u}_\tau = \mathbf{a}^* - \mathbf{x}_0, \quad \tau \in [0,1] \quad (37)$$

其中 $\mathbf{x}_\tau$ 是噪声向目标动作演化过程中的路径中间变量, $\mathbf{u}_\tau$ 为目标演化方向。条件速度场 $\mathbf{v}_\theta(\mathbf{x}_\tau, \tau, \mathbf{s})$ 拟合 $\mathbf{u}_\tau$ ,从而学习在状态 $\mathbf{s}$ 下将噪声逐步流向至低代价资源动作的方向。

速度场由残差多层感知机(multilayer perceptron, MLP)实现。状态 $\mathbf{s}$ 与路径中间变量 $\mathbf{x}_\tau$ 分别经全连接层、层归一化和SiLU激活编码,流时间 $\tau$ 经正弦位置编码与两层MLP处理。三路特征拼接后输入残差全连接模块,线性输出层给出 $2M$ 维速度,分别描述各车辆功率分量和资源权重分量的演化方向。

速度场采用线性输出,动作边界在数值积分结束后统一处理。网络训练目标为:

$$\mathcal{L}_{\text{FM}}(\theta) = \mathbb{E}_{(\mathbf{s}, \mathbf{a}^*), \mathbf{x}_0, \tau} \left[ \left\| \mathbf{v}_\theta(\mathbf{x}_\tau, \tau, \mathbf{s}) - (\mathbf{a}^* - \mathbf{x}_0) \right\|_2^2 \right] \quad (38)$$

式(38)使速度场逼近式(37)给出的目标演化方向。

### 3.3.3 FlowRA模型训练与在线资源决策

训练阶段在多种任务负载下采集状态集合 $\mathcal{S}$ 。每个状态首先生成若干随机动作,经式(32)至式(35)评价后保留代价较低的 $N_p$ 个动作,组成目标集

合 $\mathcal{A}_s$ 。速度场采用小批量随机梯度法训练。每次从 $\mathcal{D} = \{(\mathbf{s}, \mathbf{a}) \mid \mathbf{s} \in \mathcal{S}, \mathbf{a} \in \mathcal{A}_s\}$ 抽取 $B$ 个样本,对目标动作加入幅度为 $\varepsilon_a$ 的高斯扰动并投影至 $[0,1]^{2M}$ ,再按式(37)(38)计算批均值损失并反向传播。参数由AdamW更新,梯度范数截断至 $c_g$ ,权重衰减系数为 $\lambda$ ,学习率按 $\eta_g = \eta_0[1 + \cos(\pi g/G)]/2$ 余弦衰减。

每轮训练后,FlowRA生成新候选并更新目标集合,使生成分布逐轮向低代价区域集中,具体流程如算法1所示。

#### 算法1 FlowRA训练算法

输入 训练状态集合 $\mathcal{S}$ 、训练轮数 $N_r$ 、每状态候选数 $N_c^r$ 、动作集合容量 $N_p$ 、回归步数 $G$ 、小批量大小 $B$ 、初始学习率 $\eta_0$ 、权重衰减系数 $\lambda$ 、动作扰动幅度 $\varepsilon_a$ 、梯度截断阈值 $c_g$

输出 速度场参数 $\theta$

- 1) for 每个状态 $s \in \mathcal{S}$  do
- 2) 随机生成 $N_c^r$ 个候选资源动作
- 3) 按式(32)至式(35)评价候选,保留评价价值最小的 $N_p$ 个构成 $\mathcal{A}_s$
- 4) end for
- 5) for  $r = 1, 2, \dots, N_r$  do
- 6)  $\mathcal{D} \leftarrow \{(\mathbf{s}, \mathbf{a}) \mid \mathbf{s} \in \mathcal{S}, \mathbf{a} \in \mathcal{A}_s\}$
- 7) for  $g = 0, 1, \dots, G - 1$  do
- 8) 抽取 $B$ 个样本,对目标动作施加 $\varepsilon_a$ 高斯扰动并投影
- 9) 采样 $X_0$ 和 $\tau$ ,按式(37)构造 $\mathbf{x}_\tau$ 与 $\mathbf{u}_\tau$
- 10) 按式(38)计算损失并反向传播
- 11) 按余弦衰减设置 $\eta_g$ ,裁剪梯度至 $c_g$ ,以AdamW( $\lambda$ )更新 $\theta$
- 12) end for
- 13) for 每个状态 $s \in \mathcal{S}$  do
- 14) 由当前FlowRA生成 $N_c^r$ 个候选动作
- 15) 评价新动作,与 $\mathcal{A}_s$ 合并后保留评价价值最小的 $N_p$ 个
- 16) end for
- 17) end for

训练完成后固定速度场参数 $\theta$ ,每帧资源决策时,FlowRA根据当前状态 $\mathbf{s}_t$ 生成 $N_c$ 个资源候选。每个候选从独立高斯噪声出发,沿速度场执行 $N_f$ 步显式欧拉积分,第 $k$ 步更新为:

$$\begin{aligned} \mathbf{x}_{k+1} &= \mathbf{x}_k + \Delta\tau \mathbf{v}_\theta(\mathbf{x}_k, k\Delta\tau, \mathbf{s}_t), \\ \Delta\tau &= \frac{1}{N_f}, \quad k = 0, \dots, N_f - 1 \end{aligned} \quad (39)$$

积分结束后, 通过逐元素区间投影得到满足动作范围的资源向量:

$$\begin{aligned} \mathbf{a}^{(n)} &= \Pi_{[0,1]^{2M}}(\mathbf{x}_{N_f}^{(n)}), \\ \left[ \Pi_{[0,1]}(x) \right]_j &= \min \{ 1, \max \{ 0, x_j \} \} \end{aligned} \quad (40)$$

各候选经式(32)至式(35)映射和评价后, 选取

$$\text{P3}(\mathbf{Q}): \min_{\substack{\{\gamma_m\}, \{T_m\}, \{\xi_m\}, \\ \{\beta_m^i\}, \{\beta_{m,u}^u\}}} \sum_{m \in \mathcal{M}} (\omega_1 T_m + \omega_2 \hat{E}_m + \omega_3 \xi_m)$$

s.t.

$$T_m \geq \frac{\gamma_m^l D_m c}{f_l}, \quad \forall m,$$

$$T_m \geq \gamma_m^i \left( \frac{D_m}{R_m^i} + \frac{D_m c}{f_i} \right) + \beta_m^i Q_m^i, \quad \forall m,$$

$$T_m \geq \gamma_{m,u}^u \left( \frac{D_m}{R_{m,u}^u} + \frac{D_m c}{f_u} \right) + \beta_{m,u}^u Q_{m,u}^u, \quad \forall m, u, \quad (42)$$

$$T_m \leq \tau_{\max} + \xi_m, \quad \xi_m \geq 0, \quad \forall m,$$

$$\gamma_m^l + \gamma_m^i + \sum_{u \in \mathcal{U}} \gamma_{m,u}^u = 1, \quad \forall m,$$

$$0 \leq \gamma_m^i \leq \beta_m^i, \quad \forall m,$$

$$0 \leq \gamma_{m,u}^u \leq \beta_{m,u}^u, \quad \forall m, u,$$

$$\beta_{m,u}^u \leq \alpha_{m,u}, \quad \forall m, u,$$

$$\gamma_m^l \geq 0, \quad \beta_m^i, \beta_{m,u}^u \in \{0, 1\}, \quad \forall m, u.$$

$$\bar{\mathbf{Q}}^{(i+1)} = (1 - \eta) \bar{\mathbf{Q}}^{(i)} + \eta \Phi(\boldsymbol{\gamma}^{(i)}) \quad (43)$$

P3 的目标函数由任务完成时延、任务处理能耗和时延超限惩罚组成。二元变量  $\beta_m^i$  和  $\beta_{m,u}^u$  分别表示基站路径和无人机路径是否被激活。约束  $\gamma_m^i \leq \beta_m^i$  和  $\gamma_{m,u}^u \leq \beta_{m,u}^u$  保证正的卸载比例只能出现在激活路径上。当 V2U 路径不可用或未被激活时, 其卸载比例为 0, 相应的上传与排队时延项不参与任务完成时延计算; 仅对实际关联且激活的 V2U 路径, 根据其正的链路速率计算上传时延和排队时延。固定排队先验后, P3 为包含少量路径激活变量的混合整数线性规划。

P3 的解依赖排队先验, 拆分同时决定 FCFS 结算得到的排队时延。本文采用有限轮排队反馈迭代协调二者。记  $\Phi(\boldsymbol{\gamma})$  为拆分方案  $\boldsymbol{\gamma}$  经 FCFS 结算后得到的路径排队时延, 以历史排队时延统计量为初值  $\bar{\mathbf{Q}}^{(0)}$ 。第  $i$  轮求解  $\boldsymbol{\gamma}^{(i)} = \text{P3}(\bar{\mathbf{Q}}^{(i)})$  后, 更新排队时延:

评价值最小的动作:

$$\mathbf{a}_t = \arg \min_{\mathbf{a} \in \{\mathbf{a}^{(1)}, \dots, \mathbf{a}^{(N_c)}\}} \tilde{J}(\mathbf{a}; \mathbf{s}_t, \bar{\mathbf{Q}}^{(0)}) \quad (41)$$

### 3.4 排队感知的任务卸载决策

在轨迹与资源动作给定后, 资源块、功率与链路速率均已确定。为保证排队时延仅作用于实际使用的卸载路径, 引入基站路径激活变量  $\beta_m^i$  和无人机路径激活变量  $\beta_{m,u}^u$ 。将 FCFS 排队时延固定为先验参数  $\mathbf{Q} = \{Q_m^i, Q_{m,u}^u\}$ , 得到混合整数线性规划 P3:

其中  $\eta \in (0, 1]$  为阻尼系数, 共迭代  $I_q$  轮。由于任务拆分比例可能改变上传完成时刻及 FCFS 服务顺序, 本文保留各轮可行解, 并根据实际 FCFS 结算后的目标值选取最优方案。

### 3.5 整体算法流程与复杂度分析

综合以上三层, 所提算法的单帧执行流程如算法 2 所示。

**算法 2** 基于流匹配的分层联合优化算法

输入 上一帧无人机位置、历史排队时延统计量、速度场参数  $\theta$

输出 本帧部署位置、资源分配、卸载比例

1) 更新车辆位置, 生成任务负载  $D_m(t)$

2) for  $u = 1, 2, \dots, U$  do // 轨迹层

3) 剔除已被前序无人机覆盖的车辆, 求解 P1 得  $q_u(t)$

4) end for

5)更新信道增益与覆盖指示  $\alpha_{m,u}(t)$

6)构造状态  $s_t$ , 按式(39)(40)生成  $N_c$  个 FlowRA 动作 // 资源层

7)for 每个候选动作 do

8)按式(32)至式(34)解码并计算链路速率

9)用  $\bar{Q}^{(0)}$  求解一次 P3, 按式(35)计算评价值

10)end for

11)按式(41)选择资源动作并固定功率与 RB

12)for  $i = 0, 1, \dots, I_q - 1$  do // 卸载层

13)求解 P3( $\bar{Q}^{(i)}$ )得  $\gamma^{(i)}$ , FCFS 结算得  $\Phi(\gamma^{(i)})$

14)按式(43)更新  $\bar{Q}^{(i+1)}$

15)end for

16)在各轮拆分方案中按结算目标值择优执行

17)更新跨帧排队统计

计算复杂度方面, 设单次求解 P1 和 P3 的复杂度分别为  $C_{\text{SOCP}}$  与  $C_{\text{MILP}}$ 。轨迹层顺序求解  $U$  个 P1, 复杂度为  $O(UC_{\text{SOCP}})$ 。资源层生成  $N_c$  个候选需要  $N_c N_f$  次速度场前向传播, 并对各候选求解一次 P3, 复杂度为  $O(N_c N_f d_h^2 + N_c C_{\text{MILP}})$ 。卸载层执行  $I_q$  轮排队反馈迭代, 复杂度为  $O(I_q C_{\text{MILP}})$ 。因此, 总复杂度为  $O(UC_{\text{SOCP}} + N_c N_f d_h^2 + (N_c + I_q)C_{\text{MILP}})$ 。

## 4 实验分析

本章验证所提方法的有效性。首先介绍仿真场景、参数设置与基线算法, 然后依次从无人机覆盖、系统总体性能与任务卸载行为三个层面展开分析。

### 4.1 实验设置

仿真场景如图3所示, 部署1个位于区域中央的基站与5架旋翼无人机, 50辆车沿车道行驶并随机产生计算任务。评估时, 系统总任务负载在30-50 Mb间变化以考察不同拥塞程度下的性能。设置39、42和45三个独立随机种子, 每个种子在各档负载下仿真20帧, 不同随机种子独立产生车辆轨迹、信道衰落与任务到达过程, 因此测试结果同时覆盖了不同车辆空间分布和任务状态, 而非针对单一固定车流快照进行评估。所有算法在相同随机种子下共享车辆轨迹、信道衰落与任务到达序列, 以保证对比公平性。目标函数权重通过独立验证场景上的粗粒度网格搜索确, 最终保留在时延、任务成功率和时延积 (energy-delay product, EDP) 之间综合表现较优的组合, 具体参数取值汇总于表1。




图3 仿真环境示意

为全面评估所提方法, 采用如下的对比算法:

□ LVM (large vision model, LVM) 智能体, 采用未经微调的 Qwen2.5-VL-72B-Instruct 通过任务提示与历史决策信息进行上下文引导, 以车辆分布和无人机覆盖状态快照作为输入, 输出各无人机的三维部署位置, 资源分配层采用 DDPG, 卸载层采用 MILP 求解, 该方法用于评估云端视觉语义信息辅助轨迹规划的决策效果; □ MADRL 轨迹规划, 将轨迹层替换为 MADQN, 每架无人机依据局部观测选择离散移动动作; □ MADRL 任务卸载, 将卸载层替换为 MADDPG, 由各车辆智能体输出三路连续分配比例; □ 全 MADRL 轨迹层采用 MADQN、卸载层采用多智能体深度确定性策略梯度 (multi-agent deep deterministic policy gradient, MADDPG); □ 贪心卸载, 均匀分配资源块并以最大功率发射, 每辆车选择当前速率最优的单一路径全量卸载; □ 随机分配, 对资源块优先级、发射功率与卸载比例均随机赋值; □ 本地计算, 全部任务由车载处理器执行。

### 4.2 无人机部署与覆盖分析

图4给出了负载30 Mb、随机种子为42下无人机三维部署与覆盖快照。轨迹层求解后, 车流密集区域的无人机降低高度以获得更优的视距信道, 车流稀疏区域的无人机则升高以扩大覆盖半径。该帧中50辆车中有46辆处于至少一架无人机的覆盖范围内, 覆盖率达到了92%。这表明变高度联合优化能够使空中计算资源随车流空间分布自适应配置。

### 4.3 系统总体性能对比

#### 4.3.1 时延与任务成功率

图5与图6分别给出各算法在五档负载下的系

表1 主要仿真参数

| 参数                                                      | 数值                   |
|---------------------------------------------------------|----------------------|
| 仿真区域/m × m                                              | 300 × 300            |
| 无人机飞行高度范围 $z_{\min} \sim z_{\max}$ /m                   | 50~100 (初始60)        |
| 无人机最大飞行速度 $v_{\max}/(\text{m} \cdot \text{s}^{-1})$     | 15                   |
| 无人机覆盖半张角 $\theta/(\circ)$                               | 42.44                |
| 单车任务量/Mb                                                | {0.5, 1, 2}          |
| 系统总任务负载/Mb                                              | {30, 35, 40, 45, 50} |
| 任务时延阈值 $\tau_{\max}/\text{s}$                           | 1                    |
| 系统总带宽/MHz                                               | 10                   |
| 资源块数量 $K$                                               | 55                   |
| 每帧传输时隙数 $N_s$                                           | 2(时隙长度0.5 s)         |
| 瑞利衰落平均信道增益/dB                                           | 2                    |
| 莱斯因子/dB                                                 | 7                    |
| 本地计算频率 $f_m/\text{GHz}$                                 | 0.5                  |
| 无人机计算频率 $f_u/\text{GHz}$                                | 5                    |
| 基站计算频率 $f_0/\text{GHz}$                                 | 9                    |
| 每比特所需CPU周期数 $c_m/(\text{cycles} \cdot \text{bit}^{-1})$ | 1000                 |
| 目标函数权重 $\omega_1, \omega_2, \omega_3$                   | 1, 0.001, 20         |
| FlowRA速度网络隐藏层维度                                         | 512                  |
| 在线候选数 $N_c$                                             | 12                   |
| 初始学习率                                                   | $3 \times 10^{-4}$   |
| 训练轮数 $N_r$                                              | 20                   |
| 批量大小 $B$                                                | 256                  |
| 目标动作扰动幅度 $\varepsilon_a$                                | 0.01                 |
| 权重衰减系数 $\lambda$                                        | $1 \times 10^{-5}$   |
| 梯度截断阈值 $c_g$                                            | 1.0                  |
| FlowRA欧拉积分步数 $N_f$                                      | 8                    |
| 排队反馈迭代轮数 $I_q$                                          | 3                    |
| 阻尼系数 $\eta$                                             | 0.5                  |
| 随机种子                                                    | 39, 42, 45           |

统总时延与任务成功率。所提方法在全部负载下时延最低：负载30 Mb时总时延为18.47 s，较最优的对比算法（MADRL 轨迹规划，21.85 s）降低15.50%；负载50 Mb时为39.05 s，较最优对比算法（MADRL 任务卸载，47.96 s）降低18.57%。任务成功率呈现相同趋势：所提方法从负载30 Mb时的98.50%缓降至50 Mb时的86.39%，而最优对比算法在50 Mb时已降至74.38%。




图4 无人机三维部署与覆盖快照




图5 系统总时延对比




图6 任务成功率对比

值得注意的是，所提方法相对对比算法的优势随负载增加而扩大：时延降幅从15.50%扩大至18.57%，成功率领先幅度扩大12.01%。随着负载升高，资源竞争加剧且可行资源组合更为复杂，所提方法的相对优势进一步扩大。这与FlowRA通过多候选采样覆盖不同资源方案的设计动机相一致。

#### 4.3.2 能耗分析

图7给出各算法的系统总能耗。由于本地计算策略的任务成功率极低，难以满足系统服务质量要求，因此后续能耗对比仅考察能够提供有效卸载服

务的方案。在提供有效卸载服务的方法中,所提方法能耗位于第三位。在负载 50 Mb 时为 1295 J,略高于 MADRL 轨迹规划 (1160 J) 与 LVM 智能体 (1198 J),但较 MADRL 任务卸载、全 MADRL、随机分配与贪心卸载分别降低 24.64%、27.43%、29.19% 与 62.68%。所提方法以更高比例将任务卸载至高频率的边缘节点以压缩时延,属于加权目标下以少量能耗换取大幅时延与违约改善的合理权衡。




图7 系统总能耗对比

#### 4.3.3 综合性能

为进一步分析算法的任务完成效率,图 8 给出 EDP,即逐帧总时延与总能耗之积的均值。EDP 是刻画时延—能耗折中的标准指标,EDP 越低表明时延—能耗综合代价越低。所提方法在全部负载下 EDP 最低:负载 30 Mb 时为  $1.91 \times 10^4$  J·s,较次优方案低 14.08%;负载 50 Mb 时为  $5.04 \times 10^4$  J·s,较次优方案低 12.01%,较贪心卸载 ( $3.13 \times 10^5$  J·s) 低 83.91%。这说明所提方法在所比较方法中取得最佳的时延—能耗综合效率。




图8 能耗-时延积EDP对比

图 9 进一步给出系统总目标值。所提方法在全部负载下总目标值最低:负载 30 Mb 时较最优对比算法降低 22.76%;负载 50 Mb 时较最优对比算法

降低 69.87%。该结果表明所提方法的优势并非来自单项指标,而是整体决策质量的提升,且负载越高优势越显著,表明在面临密集的时延感性任务时,本文的方法做出更优的资源分配方案和卸载决策。




图9 系统总目标值对比

#### 4.3.4 资源分配层消融分析

为验证 FlowRA 资源分配模块的有效性,在保持轨迹优化模块 P1 和任务卸载模块 P3 不变的条件下,分别以 DDPG 和随机候选资源分配替换 FlowRA。三种方法采用相同的动作空间、动作维度、RB 解码规则和评价函数;FlowRA 与随机候选方法采用相同的候选数量和评价预算。由图 10 (a) 和图 10 (b) 可见,FlowRA 在各负载下均具有最低的平均总时延和最高的任务成功率。在 50 Mb 负载下,相较于 DDPG 和随机候选资源分配,时延分别降低 25.27% 和 52.33%,任务成功率达到 86.39%,分别提高 15.48% 和 43.32%。

由图 10 (c) 和图 10 (d) 可见,FlowRA 在各负载下也具有最低的平均总能耗和系统总目标值。在 50 Mb 负载下,其平均总能耗为 1295 J,较两种消融方案分别降低 23.38% 和 48.61%;系统总目标值为 64.47,分别降低 58.84% 和 86.90%,且相对优势随负载升高而扩大。

#### 4.4 任务卸载行为分析

为解释 4.3 节中各算法的性能差距,本节在负载 30 Mb、随机种子为 42 下对各算法的卸载决策行为进行分析,依次考察任务在三条计算路径上的分配比例与分路时延和各计算节点的负载分布。

##### 4.4.1 卸载比例与分路时延

图 11 给出各算法的任务三路分配比例。所提方法将 26.92%、28.87% 与 44.21% 的任务分别分配至本地、基站与无人机;无人机承担最大份额,因




图10 资源分配层消融分析

为无人机的覆盖优化使多数车辆拥有近距离视距V2U链路,且5架无人机提供了并行的计算容量;基站与本地则吸收其余负载,避免单一路径拥塞。LVM智能体与MADRL轨迹规划的分配结构相近,差异主要源于轨迹层:其覆盖质量欠佳使部分车辆缺少优质V2U链路,任务被迫回退本地。相比之下,贪心卸载放弃本地计算,将87.17%的任务集中卸载至基站,这是由于其逐车独立选择当前最优路径而不感知队列状态,导致所有车辆涌向同一节点;全MADRL与随机分配则分别将36.59%与35.46%的任务留在本地,未能充分利用边缘资源。




图11 算法任务三路分配比例

图12给出三条路径的平均分路时延,分路时延的最大值为任务完成的总时延。所提方法三路时延为0.43 s、0.38 s与0.38 s,在所有算法中最低且

最均衡。LVM智能体与MADRL轨迹规划同样呈现均衡形态,但整体高于所提方法约0.05~0.11 s。而贪心卸载的基站路径时延高达1.36 s,本地计算的单路时延为1.59 s,均超过1 s的时延阈值。




图12 算法平均分路时延

#### 4.4.2 计算节点负载分布

图13给出各算法中基站与5架无人机平均每帧承担的计算负载。所提方法的配置最为均衡且对空中资源利用最充分。LVM智能体的无人机间分布同样较均匀,但无人机合计仅11.25 Mb,低于所提方法约15%。MADRL轨迹规划与全MADRL虽然基站负载与所提方法相近,但无人机间负载明显失衡。贪心卸载最为极端:基站负载高达26.15 Mb,约占系统总负载的87%,节点负载的失衡直接转化为排队时延的增长。




图13 算法计算节点负载分布

#### 4.5 运行时间分析

为评估各算法的在线计算开销,所有方法均在同一硬件环境下测试。当前的实验平台配置为Intel Xeon Gold 5218R CPU、NVIDIA RTX 3090 GPU、128 GB 内存和Ubuntu 20.04 操作系统;LVM智能体则单独统计商业云端API的端到端时钟时间。图14给出了系统总任务负载为30~50 Mb时的单帧运行时间,折线和误差棒分别表示均值与标准差。




图14 算法运行时间分析

本文以帧为决策周期, 每帧包含  $N_s = 2$  个长度为  $T_s = 0.5s$  的时隙, 因此帧长为  $1s$ , 无人机轨迹、资源分配与任务卸载决策均在每帧执行一次。所提方法的单帧运行时间为  $423.6 \sim 552.8ms$ , 低于  $1s$  帧周期, 表明 P1 轨迹优化、FlowRA 多候选生成与评价以及 P3 卸载组成的分层流程具备在线执行条件。LVM 智能体的 API 墙钟时间为  $4.26 \sim 5.83s$ , 超过  $1s$  帧周期。

## 5 结束语

本文面向多无人机辅助车联网中的动态资源匹配与时延敏感任务保障, 提出基于流匹配模型的协同资源调度方法, 将无人机三维轨迹、无线资源分配与计算任务卸载纳入统一框架。所提方法通过轨迹—资源—卸载三层协同求解, 实现资源候选生成与排队感知任务拆分。仿真结果表明, 该方法在所比较方案中取得了最低的系统总时延、最高的任务成功率和最低的 EDP。

## 参考文献:

- [1] DAI X X, XIAO Z, JIANG H B, et al. UAV-assisted task offloading in vehicular edge computing networks[J]. IEEE Transactions on Mobile Computing, 2023, 23(4): 2520-2534.
- [2] MAO Y Y, YOU C S, ZHANG J, et al. A survey on mobile edge computing: the communication perspective[J]. IEEE Communications Surveys & Tutorials, 2017, 19(4): 2322-2358.
- [3] LI B, XIE W C, YE Y H, et al. FlexEdge: digital twin-enabled task offloading for UAV-aided vehicular edge computing[J]. IEEE Transactions on Vehicular Technology, 2023, 72(8): 11086-11091.
- [4] WU Q Q, ZENG Y, ZHANG R. Joint trajectory and communication design for multi-UAV enabled wireless networks[J]. IEEE Transactions on Wireless Communications, 2018, 17(3): 2109-2121.
- [5] 邝祝芳, 郭宇敬, 邓晓衡. 基于李雅普诺夫的 RIS 辅助无人机边缘计算网络中任务卸载与资源分配研究[J]. 通信学报, 2024, 45(9): 258-273.
- KUANG Z F, GUO Y J, DENG X H. Research on task offloading and

resource allocation in edge computing network of RIS assisted UAV based on Lyapunov[J]. Journal on Communications, 2024, 45(9): 258-273.

- [6] 曾锋, 张政, 陈志刚. 基于深度强化学习的计算卸载与资源分配策略[J]. 通信学报, 2023, 44(7): 124-135.
- ZENG F, ZHANG Z, CHEN Z G. Computation offloading and resource allocation strategy based on deep reinforcement learning[J]. Journal on Communications, 2023, 44(7): 124-135.
- [7] PENG H X, SHEN X M. Multi-agent reinforcement learning based resource management in MEC- and UAV-assisted vehicular networks[J]. IEEE Journal on Selected Areas in Communications, 2020, 39(1): 131-141.
- [8] 谭国平, 易文雄, 周思源, 等. 无人机辅助 MEC 车辆任务卸载与功率控制近端策略优化算法[J]. 电子与信息学报, 2024, 46(6): 2361-2371.
- TAN G P, YI W X, ZHOU S Y, et al. Proximal Policy Optimization Algorithm for UAV-assisted MEC Vehicle Task Offloading and Power Control[J]. Journal of Electronics & Information Technology, 2024, 46(6): 2361-2371.
- [9] DU H Y, ZHANG R C, LIU Y Q, et al. Enhancing deep reinforcement learning: a tutorial on generative diffusion models in network optimization[J]. IEEE Communications Surveys & Tutorials, 2024, 26(4): 2611-2646.
- [10] LIPMAN Y, CHEN R T Q, BEN-HAMU H, et al. Flow matching for generative modeling[C]//Proceedings of the 11th International Conference on Learning Representations. Kigali, Rwanda: OpenReview, 2023: 1-28.
- [11] ZENG Y, XU J, ZHANG R. Energy minimization for wireless communication with rotary-wing UAV[J]. IEEE Transactions on Wireless Communications, 2019, 18(4): 2329-2345.
- [12] CUI F Y, CAI Y L, QIN Z J, et al. Multiple access for mobile-UAV enabled networks: joint trajectory design and resource allocation[J]. IEEE Transactions on Communications, 2019, 67(7): 4980-4994.
- [13] JEONG S, SIMEONE O, KANG J. Mobile edge computing via a UAV-mounted cloudlet: optimization of bit allocation and path planning[J]. IEEE Transactions on Vehicular Technology, 2017, 67(3): 2049-2063.
- [14] ZHOU F H, WU Y P, HU R Q, et al. Computation rate maximization in UAV-enabled wireless-powered mobile-edge computing systems[J]. IEEE Journal on Selected Areas in Communications, 2018, 36(9): 1927-1941.
- [15] HU Q Y, CAI Y L, YU G D, et al. Joint offloading and trajectory design for UAV-enabled mobile edge computing systems[J]. IEEE Internet of Things Journal, 2018, 6(2): 1879-1892.
- [16] ZHANG J, ZHOU L, TANG Q, et al. Stochastic computation offloading and trajectory scheduling for UAV-assisted mobile edge computing[J]. IEEE Internet of Things Journal, 2018, 6(2): 3688-3699.
- [17] HE Y, ZHAO N, YIN H X. Integrated networking, caching, and computing for connected vehicles: a deep reinforcement learning approach[J]. IEEE Transactions on Vehicular Technology, 2017, 67(1): 44-55.
- [18] TAN L T, HU R Q. Mobility-aware edge caching and computing in vehicle networks: a deep reinforcement learning[J]. IEEE Transactions on Vehicular Technology, 2018, 67(11): 10190-10203.
- [19] NING Z L, DONG P R, WANG X J, et al. Deep reinforcement learning for vehicular edge computing: an intelligent offloading system[J]. ACM Transactions on Intelligent Systems and Technology, 2019, 10(6): 1-24.

- [20] LIU Y, YU H M, XIE S L, et al. Deep reinforcement learning for offloading and resource allocation in vehicle edge computing and networks[J]. IEEE Transactions on Vehicular Technology, 2019, 68(11): 11158-11168.
- [21] WANG L, WANG K Z, PAN C H, et al. Multi-agent deep reinforcement learning-based trajectory planning for multi-UAV assisted mobile edge computing[J]. IEEE Transactions on Cognitive Communications and Networking, 2020, 7(1): 73-84.
- [22] ZHAO N, YE Z Y, PEI Y Y, et al. Multi-agent deep reinforcement learning for task offloading in UAV-assisted mobile edge computing [J]. IEEE Transactions on Wireless Communications, 2022, 21(9): 6949-6960.
- [23] SEID A M, BOATENG G O, MARERI B, et al. Multi-agent DRL for task offloading and resource allocation in multi-UAV enabled IoT edge network[J]. IEEE Transactions on Network and Service Management, 2021, 18(4): 4531-4547.
- [24] LI X L, QIN Y H, HUO J H, et al. Computation offloading and trajectory planning of multi-UAV-enabled MEC: a knowledge-assisted multiagent reinforcement learning approach[J]. IEEE Transactions on Vehicular Technology, 2023, 73(5): 7077-7088.
- [25] LI B, YANG R R, LIU L, et al. Robust computation offloading and trajectory optimization for multi-UAV-assisted MEC: a multiagent DRL approach[J]. IEEE Internet of Things Journal, 2023, 11(3): 4775-4786.



刘新秀（2002—），男，河北唐山人，北京邮电大学博士生，主要研究方向为边缘网络的资源调度、服务保障等。



喻鹏（1986—），男，湖北随州人，博士，北京邮电大学副教授、博士生导师，主要研究方向为 5G/6G 网络智能管控。



方宏林（1998—），男，河南南阳人，博士，西南交通大学助理教授，主要研究方向为边缘智能管控、服务保障等。