



专题：低空物联网与低空安全

面向低空物联网的无人机网络切片资源管理机制研究

陈鸿杰¹, 郭昱甫², 吴凡², 张科², 熊凯²

(1. 中国西南电子技术研究所, 四川 成都 610036;

2. 电子科技大学信息与通信工程学院, 四川 成都 611731)

摘 要: 在低空物联网中, 无人机作为空中通信基站、数据传输中继节点和移动网络终端的重要组成部分, 凭借其卓越的机动性和适应性, 广泛应用于扩展网络覆盖和支持多种业务服务。然而, 由于低空物联网面临着网络拓扑动态变化、空域资源稀缺以及多样化业务需求等挑战, 实现有限资源的高效编排和管理仍然是一项艰巨任务。为解决这一问题, 通过对无人机网络进行端到端切片, 构建满足特定需求的逻辑无人机网络架构。首先, 设计了一种分群轨迹预测模型, 用于确定分群接入节点的位置, 为网络切片的资源预留与优化提供支持。基于此, 提出了一种双时间尺度的资源管理框架: 在大时间尺度上, 采用非线性规划方法将切片资源配置问题转化为约束优化问题, 优化整体切片效益并合理预留资源; 在小时间尺度上, 通过针对切片内业务需求的资源调度策略, 满足具体业务的传输服务质量 (quality of service, QoS) 需求。仿真结果表明, 该方法增强了低空无人机智能网络在动态环境中的适应性与服务质量, 为低空物联网复杂场景下的资源管理和业务保障提供了有效支持。

关键词: 无人机网络; 网络切片; 资源预留; 双时间尺度

中图分类号: TN915.5

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025053

Research on UAV network slicing resource management for low-altitude intelligent network

CHEN Hongjie¹, GUO Yufu², WU Fan², ZHANG Ke², XIONG Kai²

1. Southwest China Institute of Electronic Technology, Chengdu 610036, China

2. School of Information and Communication Engineering, University of Electronic Science and Technology of
China, Chengdu 611731, China

Abstract: In low-altitude intelligent networks, unmanned aerial vehicles (UAV) play a crucial role as aerial communication base stations, data relay nodes, and mobile network terminals. Leveraging their exceptional mobility and adaptability, UAV can extend network coverage and support a wide range of service applications. However, the challenges of dynamic network topology, constrained airspace resources, and diverse service demand pose significant difficulties

收稿日期: 2025-01-24; 修回日期: 2025-03-05

通信作者: 吴凡, wufan@uestc.edu.cn

基金项目: 国家自然科学基金青年项目 (No.62201122)

Foundation Item: The National Natural Science Foundation of China Youth Project (No.62201122)

in achieving efficient resource orchestration and management. To address these challenges, an end-to-end slicing approach for UAV network was introduced, enabling the construction of logical network architectures tailored to specific requirements. A cluster trajectory prediction model was developed to identify the positions of clustered access nodes, providing essential support for resource reservation and optimization in network slicing. Building on this, a dual time-scale resource management framework was proposed. At a larger time scale, the slice reconfiguration problem was transformed into a constrained optimization task by a nonlinear programming approach, maximizing overall slice efficiency and ensuring rational resource reservation. At a finer time scale, intra-slice resource scheduling strategies were implemented to meet the QoS requirements of specific services. Simulation results demonstrate that the proposed method significantly improves the communication performance of low-altitude dynamic intelligent networks. It enhances the adaptability and service quality of UAV network slicing in dynamic environments, offering effective support for resource management and service assurance in complex scenarios.

Key words: UAV network, network slicing, resource reservation, dual time-scale

0 引言

低空智联网是指在低空空域中,通过连接各类智能终端(如无人机、传感器、监控设备等)形成的一种新型物联网生态系统。随着低空场景在物流配送、环境监测、灾害救援、城市治理等领域的应用逐步深入,低空智联网需要满足多样化的业务需求,如超低时延、大带宽等。传统网络架构通常采用集中式资源管理,并在固定的拓扑结构下进行通信,这使得其难以灵活应对低空智联网中无人机节点的高动态性和业务需求的多样化,尤其是在频繁变化的网络拓扑和流量需求下,表现出明显的局限性。因此,网络切片技术作为 5G 及后续网络技术的核心创新之一,最初是为提升传统网络架构的资源管理和灵活性而设计的。随着低空智联网在物流配送、环境监测等领域的迅速发展,网络切片展现了为低空智联网提供服务的巨大潜力。

无人机作为低空智联网的主要载体,凭借其空中作业能力,在物流配送、农业监测、公共安全和应急响应等场景中发挥着重要作用。在自然灾害或紧急情况下,无人机可快速部署^[1-3],为受灾区域提供临时通信服务;在环境监测中,无人机不仅能够高效采集数据,还能将数据传回地面站或云端进行分析。然而,基于无人机的低空

智联网仍面临若干挑战:(1)双时间尺度(dual time-scale)动态性强,低空设备(如无人机)高移动性导致网络拓扑随时变化,对网络动态管理能力要求极高;(2)业务多样化,低空智联网业务包括实时视频流、物联网监测数据传输和控制信号等,不同业务有不同的服务质量(quality of service, QoS)需求;(3)资源受限,低空设备的计算、存储和通信资源有限,且受限于能耗和载重能力;(4)空域资源稀缺,低空频谱资源和通信链路的共享和竞争问题尤为突出。

为应对这些挑战,网络切片技术应运而生。通过虚拟化物理网络设备,网络切片技术能够在共享物理网络上构建多个逻辑隔离的网络,从而允许单架无人机集成多种任务并灵活适配不同的业务需求。在软件定义网络(software defined network, SDN)和网络功能虚拟化(network functions virtualization, NFV)的支持下,网络切片能够根据不同的通信需求灵活定制和优化切片资源,并通过动态创建、调整和释放操作满足特定的服务质量需求^[4]。

近年来,无人机网络切片技术因其在提升多样化通信服务成本效率方面的潜力,已成为研究热点。无人机业务流量需求由无人机节点发起,任务类型及外部环境的变化会导致这些需求波动,目的地通常是地面站或云端。随着无人机在



任务中的动态移动，业务流量需求随着任务的进展和外部环境的变化而波动。因此，网络切片必须能够灵活应对这些波动，以确保服务质量和连续性。已有研究表明，切片技术不仅能实现无人机有效载荷切片与控制切片的隔离，还能优化能耗与服务公平性之间的权衡。例如，文献[5]评估了无人机通信的切片性能，文献[6]提出了基于深度强化学习的算法以优化无人机轨迹设计和带宽分配，而文献[7]提出了一种资源分配策略以最大化物理节点和链路的剩余资源利用率。

然而，在传统架构中，自组网切片技术遭遇了一系列挑战和限制。首先，随着网络节点和业务种类的增加，当所有业务在同一自组网上运行时，管理和维护网络切片变得复杂。这种复杂性源于对不同网络传输需求的满足，要求网络切片能够适应多变的业务环境和传输特性。其次，业务分群接入位置或网络拓扑的动态变化对网络切片提出了更高的灵活性要求^[8]。传统网络切片在适应这些变化时显示出局限性，导致网络资源的灵活配置能力受限，难以迅速响应需求的波动。为了维持服务的连续性和满足性能要求，必须能够灵活调整切片资源配置。此外，由于切片资源调整存在时间尺度上的差异，传统网络切片的周期性重配置可能导致服务中断或转换时延，进而影响网络的稳定性和用户体验。综上，低空物联网对网络切片提出了以下3个需求。(1) 高可靠性与低时延：如实时控制与灾害监测业务需要端到端时延低于10 ms的服务。(2) 灵活性与可扩展性：网络架构需要能够灵活扩展，以支持多样化的业务负载。(3) 智能化切片编排：切片需要动态调度网络资源，实现资源利用率与QoS保障的动态平衡。

为应对网络切片资源部署的挑战，需协同配置跨切片资源部署与内部调度。文献[9]提出基于时槽的无线电接入网（radio access network, RAN）切片框架，含长期时槽（LTS）和短期时

槽（STS），以提升云无线电接入网（cloud access network, C-RAN）服务多路复用效率和运营商收入。文献[10]的双时间尺度切片重配置框架，优化运营收益，降低重配置开销，平衡即时需求与长期规划。文献[11]构建双时间尺度混合整数非线性规划（mixed integer nonlinear programming, MINLP）问题，优化资源分配，保障服务质量，应对传统RAN切片挑战。现有研究多聚焦于优化网络切片的长期和短期运营效益，却忽略了切片资源和拓扑变化对业务持续性的影响。在接入点频繁变化的环境下，网络切片的重构需求增多，增加了管理复杂性和运维成本。为此，切片所有者需在大时间尺度上准确预测并申请资源预留，基础设施提供商的中央控制系统基于这些请求，灵活虚拟化资源并分配物理链路，确保资源合理预留和初步配置。在此基础上，切片所有者在小时间尺度上进行细致的资源分配，由本地控制器执行，以最小化业务流间的干扰，保障服务质量。

为降低频繁片间重构对业务流的干扰，需平衡资源预留成本与网络切片重构开销，优化长期收益。人工智能（artificial intelligence, AI）和机器学习（machine learning, ML）技术在此过程中发挥关键作用，助力网络运营商高效管理资源并提升网络性能。文献[12]提出基于分布式放置的动态网络服务重配置（DNSR-DP）模型，通过在线学习策略适应服务功能链动态变化，降低重配置成本，实现稳定学习。文献[13]介绍一种ML模型，能预测网络切片流量并动态调整计算资源，确保服务质量，但未充分考虑重切片过程中的迁移和配置成本。文献[14]提出分层端到端网络切片智能资源管理框架，使用强化学习方法为每个租户定制网络切片，优化长期收益并保障QoS，但未明确展示架构是否满足性能标准，也未具体说明租户定制切片时需提供的信息。文献[15]提出结合在线学习的深度强化学习模型，降低重配置成本并适应动态服务需求。文献[16]将深

度分布式强化学习与生成对抗网络 (generative adversarial network, GAN) 结合, 提出基于生成对抗网络的深层分布式 Q 网络 (generative adversarial network-powered deep distributional Q network, GAN-DDQN) 算法优化资源管理。文献[17]通过强化学习方法优化 5G 核心网切片的准入控制和资源分配。文献[18]设计多智能体深度确定性策略梯度 (multi-agent deep deterministic policy gradient, MADDPG) 算法, 用于无人机网络中跨层资源分配和负载均衡。最后, 文献[19]定义 4 种网络切片类型, 包括 QoS 切片等, 以满足不同服务质量需求, 但实际部署效果仍需进一步研究。

结合上述文献面临的问题、动态切片管理的复杂性, 本文利用机器学习和深度强化学习的优势, 提出了一种基于预测的资源预留与切片重配置框架。在切片间自适应资源分配过程中, 本文通过预测未来网络接入拓扑和业务需求变化, 对切片资源进行适度冗余配置, 使切片能够适应接入拓扑和业务需求的动态变化, 从而降低切片重配置的频率与开销。具体而言, 通过适当降低当前网络服务质量, 保障切片未来的资源调度灵活性和业务适配性; 同时, 在小时间尺度上针对具体业务 QoS 需求对切片内资源进行精细调度, 提升切片内资源利用率并优化传输性能。

1 系统模型

1.1 骨干集群网络模型

在由多架有/无人机构成的骨干自组织网络中, 骨干集群网络起着至关重要的作用, 作为连接不同业务集群的通信枢纽。骨干集群机载网关节点被划分为 3 个主要功能: 无人机集群的通信接入、数据包的中继与处理、中央控制节点通过专用控制信道进行资源分配和网络管理。构建集群连接时自组织网络资源有限, 节点的数据处理容量和链路的带宽容量都存在限制, 因此骨干集群网络被拟建模为一个加权有向图 $\mathcal{G}(\mathcal{N}, \mathcal{E}, \mathbf{B})$ 。这

里 $\mathcal{N}$ 为骨干集群网络的节点集, $\mathcal{E}$ 为节点间链路集, $\mathbf{B} = (B_{e_{i,j}})_{e_{i,j} \in \mathcal{E}}$ 为链路的转发带宽。

1.2 集群切片模型

骨干集群网络的切片部署如图 1 所示, 在骨干集群网络边缘分布着 J 个移动的源到目的集群对, 集群切片是服务集群业务的数据平面切片 $s \in \mathcal{S}$, 包括对应集群传输业务的构成元素, 如节点、链路、节点资源和通信容量。一个集群切片 s 可以涵盖多个节点和链路, 同一个节点和链路也可以被多个切片所覆盖。服务于集群间的网络切片 s 构建在骨干集群网络节点和链路的子集上, $s \in \mathcal{S}$ 。切片 s 的资源描述可以表示为 $\mathcal{G}_s(t)(\mathcal{N}_s(t), \mathcal{E}_s(t), B_s(t))$ 。这里 $\mathcal{N}_s(t)$ 和 $\mathcal{E}_s(t)$ 表示切片 s 所使用的节点子集和链路子集, $B_s(t) = (B_{e_{i,j},s}(t))_{e_{i,j},s \in \mathcal{E}_s}$ 为切片 s 链路集的转发带宽请求。




图1 骨干集群网络的切片部署

单个切片上存在多条业务流进出, 切片流量需求会随着业务流的到达和离开动态波动。单个切片的通信业务流表示为 $F_s = \{f_s^1, \dots, f_s^K\}$, 这里 K 为请求业务的个数, 假设系统中有两种服务质量需求的业务流: 高吞吐量型和低时延型。高吞吐量型业务请求可以表示为 $\{\bar{r}_{f_s^k}^{\max}, \bar{r}_{f_s^k}^{\text{guar}}\}$ 。其中



$\bar{r}_{f_s^k}^{\max}$ 为业务 f_s^k 速率上限, $\bar{r}_{f_s^k}^{\text{guar}}$ 为业务 f_s^k 速率下限 (保证速率)。低时延型业务请求可以表示为 $\{\bar{\tau}_{f_s^k}^{\min}, \bar{\tau}_{f_s^k}^{\text{guar}}\}$ 。其中 $\bar{\tau}_{f_s^k}^{\text{guar}}$ 为业务 f_s^k 保证时延, $\bar{\tau}_{f_s^k}^{\min}$ 为业务 f_s^k 最低时延。

假设邻接矩阵 $\mathbf{E}_s = (e_{ij}) \in C^{|\mathcal{N}_s| \times |\mathcal{N}_s|}$ 表示切片 s 的拓扑结构, 其中 $e_{ij}=1$ 表示节点 i 与节点 j 之间有直接链路 $e_{i,j}$, 否则 $e_{ij}=0$, $|\mathcal{N}_s|$ 为节点个数。可达性矩阵 $\mathbf{R}_s = (r_{ij}) \in C^{|\mathcal{N}_s| \times |\mathcal{N}_s|}$ 用于表示从源节点到目的节点是否存在有效路径: $\mathbf{R}_s = \mathbf{E}_s^T \sum_{h=0}^{H-1} \mathbf{E}_s^h$, 其中 T 为矩阵转置运算符, $\mathbf{E}_s^T$ 表示邻接矩阵 $\mathbf{E}_s$ 的转置, $\mathbf{E}_s^h$ 表示邻接矩阵 $\mathbf{E}_s$ 的 h 次幂, H 表示路径跳数上限。因此, 切片连通性约束可以表示为:

$$r_{ij} \geq 1, \forall i, j \in \mathcal{N}_s \quad (1)$$

在将集群切片映射到物理网络的过程中, 假设骨干集群网络上的机载网关节点和链路资源是有限且固定的。如果用 $B_{e_{i,j}}$ 表示链路 $e_{i,j}$ 的带宽容量, 则带宽约束可以表述为链路 $e_{i,j}$ 上可用的总带宽不能超过该链路的最大带宽容量:

$$\sum_{s \in \mathcal{S}} B_{e_{i,j},s}(t) \leq B_{e_{i,j}}(t), e_{i,j} \in \mathcal{E} \quad (2)$$

同时, 机载网关节点的发射功率可以表述为

它所参与的所有链路的发射功率之和: $p_n^o(t) = \sum p_{e_n}^o(t)$ 。除发射功率外, 定义无人机 n 固有功率消耗为 p_n^c , 则无人机 n 总功耗约束可以表示为:

$$p_n^{\text{tot}}(t) = p_n^o(t) + p_n^c \leq p_n, n \in \mathcal{N} \quad (3)$$

其中, p_n 为无人机 n 最大瞬时总功率的上界。

1.3 大小时间尺度协调模型

针对不同时间尺度下的网络切片管理需求, 本文提出了一种双时间尺度切片编排机制, 以保障端到端可靠传输服务, 双时间尺度切片重配置如图2所示。在大时间尺度上, 业务集群接入关系稳定, 切片间资源分配进行初始配置并预留冗余, 允许切片内资源动态调整, 但重配置开销较大。在小时间尺度上, 业务 QoS 需求动态变化, 切片内资源调度需低开销且灵活。为此, 采用集群轨迹与流量预测实现精准资源重配置, 并在小时间尺度下运用灵活权值匹配方案满足业务流需求变化, 实现高效资源调度与切片编排。大时间尺度上, 节点和链路资源切分在每个时隙 $t_x \in \{t_0, t_1, \dots, t_x\}$ 执行, 决策时刻进行片间重配置, 决策周期被划分为多个小时间尺度的子时隙 $t \in \{t_x^0, t_x^1, \dots, t_x^Y\}$, 子时隙为切片内资源调度的基本单位, 每个决策时刻执行切片内资源调度。




图2 双时间尺度切片重配置

2 大时间尺度切片重配置

为了确保无人机分群通信的实时性和有效性, 以增强分群通信切片的可靠性和延长其生命周期, 首先, 提出了一种基于分群位置依赖性的移动性预测框架。其次, 基于资源预留为网络切片重配置问题进行数学建模, 并提出了最小化资源开销和最大化切片效益的优化问题。最后, 提出了基于深度确定性策略梯度 (DDPG) 算法的解决方法。

2.1 基于分群位置依赖性的移动性预测

由于分群位置访问具有一定的时间周期性和规律性, 停留时间与下一个地方的返回趋势相关。利用该特性, 选用了马尔可夫预测器作为位置依赖模型的核心组件, 从分群的运动历史 $\mathcal{H}$ 中提取位置 l_j , $\mathcal{H}_j = (l_j, t_1^a, \tau_1), \dots, (l_j, t_j^a, \tau_k)$ 的历史访问序列。从 $\mathcal{H}_j$ 出发, 在 l_j 的返回概率 R_j 采用时间周期集 $\{d_\chi | d_\chi = t_\chi^a + 1 - (t_\chi^a + \tau_\chi)\}$ 的离散直方图分布形式, 其中 $1 \leq \chi \leq k-1$, $(t_\chi^a + \tau_\chi)$ 为出发时间。然后, R 生成位置 l_i 的驻留时间分布 Γ , 定义为:

$$\Gamma_i = \sum_{j=1}^m p_{ij} (\Gamma_{ij} \times R_j) \quad (4)$$

其中, $p_{ij} = \Pr(l_{\chi+1} = l_j | l_\chi = l_i)$, $\sum_{j=1}^m p_{ij} = 1$, Γ_{ij} 是驻留时间集合 $\{\tau_\chi | l_\chi, l_{\chi+1} = l_i, l_j\}$ 的离散直方图分布形式。 $\int_0^\infty \Gamma_i(t) dt = \int_0^\infty \Gamma_{ij}(t) dt = 0$ 或 1 , $\int_0^\infty R_j(t) dt = 0$ 或 1 。马尔可夫预测器通过匹配最近的 k 个位置序列来提取历史模式。因此, 当分群在时间周期之后返回下一个位置时, R 为时隙分配了高供应概率。

在获得停留时间分布 Γ 之后, 进一步探讨了如何利用该分布对移动性模型的预测准确性进行量化评估。基于 Γ , 定义了位置预测准确度 f_a , 以衡量预测模型的表现。

首先, 正确供应 f_c 表明了停留时间分布的形状, 即 f_c 是实际停留时间周围的预测概率。生成的停留时间分布 Γ_i 中停留时间 τ_i 的 f_c 定义如下:

$$f_c(\tau_i, \Gamma_i) = \int_{\tau_i - \varphi}^{\tau_i + \varphi} \Gamma_i(t) dt \quad (5)$$

其中, φ 是给定的时间阈值。最优模型生成 $f_c = 1$, 即模型在停留时间的真值附近分配所有概率。

位置预测准确度 f_a 是下一个实际位置的预测概率与 f_c 的比值。在 Γ_i 中停留时间 τ_i 的 f_a 定义如下:

$$f_a(\tau_i, \Gamma_i) = p_{ij} \int_{\tau_i - \varphi}^{\tau_i + \varphi} \Gamma_i(t) dt / f_c(\tau_i, \Gamma_i) \quad (6)$$

其中, f_a 与给定出发时间下的位置预测直接相关。最优模型生成 $f_a = 1$, 即移动性模型正确预测了实际出发时刻的下一个位置。否则, 低 f_a 的模型缺乏位置预测。

2.2 切片开销模型

为适应网络切片中流量需求的动态性, 需自适应重配置网络切片, 以最小化资源消耗, 其资源消耗包括服务集群业务的资源和重配置中的数据迁移、流量定向等资源, 分别定义为重配置开销和运行开销。切片重配置开销涉及切片与基板网络之间的资源调整, 即允许调整虚拟链路/节点的容量。 $(\mathbf{n}(t_0), \mathbf{e}(t_0))$ 为重构前 t_0 时刻的状态, $I(\cdot)$ 为指示函数, 即若 $x \neq 0$, $I(x) = 1$; 否则 $I(x) = 0$ (如果 $I(\cdot)$ 作用于向量 x , 结果也是一个向量)。链路带宽分配的变化 $(\mathbf{e}(t) - \mathbf{e}(t_0))$ 考虑了控制信令的成本, 如在转发节点上进行流量重路由和执行调度策略。因此, 在 t 时刻切片重配置作用下, 切片的总重构代价 ϕ_r 为:

$$\phi_r(\mathbf{e}(t)) = \rho_e^T \cdot I(\mathbf{e}(t) - \mathbf{e}(t_0)) = \rho_e \cdot \sum_{e_{ij} \in \mathcal{E}} |B_{e_{ij},s}(t) - B_{e_{ij},s}(t_0)| \quad (7)$$

其中, ρ_e^T 是重构成本和流程处理成本价格向量。当 $B_{e_{ij},s}(t) < B_{e_{ij},s}(t_0)$ 时, 链路回收资源 $|B_{e_{ij},s}(t) - B_{e_{ij},s}(t_0)|$, 反之则再为切片分配 $|B_{e_{ij},s}(t) - B_{e_{ij},s}(t_0)|$ 的资源。单条物理链路 e_{ij} 上资源变化量为 $\Delta B_{e_{ij}}(t) = \sum_{s \in \mathcal{S}} |B_{e_{ij},s}(t) - B_{e_{ij},s}(t_0)|$, 假设每



个单位资源变化量产生的控制信令成本为 ρ_e 。则单条物理链路中开销为 $\rho_e \cdot \Delta B_{e_{ij}}(t)$ ，链路总开销为 $\sum_{e_{ij} \in \mathcal{E}} \Delta B_{e_{ij}}(t)$ 。

切片总开销由切片调整、运行开销（带宽资源开销和功率资源开销）组成，由式（8）给出：

$$\begin{aligned} \phi(\mathbf{n}(t), \mathbf{e}(t)) &= \phi_r(\mathbf{e}(t)) + \phi_B(\mathbf{e}(t)) + \phi_p(\mathbf{n}(t)) \\ \phi_B(\mathbf{e}(t)) &= \rho_B \cdot \sum_{e_{ij} \in \mathcal{E}} |B_{e_{ij},s}(t)| \\ \phi_p(\mathbf{n}(t)) &= \rho_p \cdot \sum_{n \in \mathcal{N}} p_n^{\text{tot}}(t) \end{aligned} \quad (8)$$

2.3 切片效益模型

信道衰落随着无人机（unmanned aerial vehicle, UAV）的移动而变化。为了考虑这一动态性，基于上述UAV位置预测，第 i 架UAV和第 j 架UAV在相关联的切片 s 上的通信链路 e_{ij} 的信道衰落 $h_{e_{ij},s}$ 遵循一个线性信道模型^[20]。据此，通道系数 $g_{e_{ij},s}$ 可计算为：

$$\begin{aligned} g_{e_{ij},s}(t) &= h_{e_{ij},s}(t) [d_{e_{ij},s}(t)]^{-\alpha} = \\ & h_0 [d_{e_{ij},s}(t)]^{-\alpha} \left| \sqrt{\frac{R}{R+1}} + \sqrt{\frac{1}{R+1}} \tilde{h}_{e_{ij},s}(t) \right|^2 \end{aligned} \quad (9)$$

其中， h_0 表示参考距离为1 m时的平均信道功率增益； α 为路径损耗指数； R 为莱斯衰落衰减因子； $\tilde{h}_{e_{ij},s}(t) \sim \text{CN}(0, 1)$ 表示非视距分量； $d_{e_{ij},s}(t)$ 为UAV i 与UAV j 的链路距离。

进一步，本文定义了基于第 i 架UAV和第 j 架UAV下通信链路 e_{ij} 的功率分配 $p_{e_{ij},s}(t)$ ，则 t 时刻通信链路 e_{ij} 在相关联的切片 s 上的SNR和数据速率可计算为：

$$\gamma_{e_{ij},s} = \frac{p_{e_{ij},s}(t) g_{e_{ij},s}(t)}{B_{e_{ij},s}(t) N_0} \quad (10)$$

$$r_{e_{ij},s} = B_{e_{ij},s}(t) \ln \left[1 + \frac{p_{e_{ij},s}(t) g_{e_{ij},s}(t)}{B_{e_{ij},s}(t) N_0} \right] \quad (11)$$

其中， N_0 为加性高斯白噪声（AWGN）的功率谱密度。 $B_{e_{ij},s}(t)$ 为切片 s 上通信链路 e_{ij},s 的可用带宽大小。

切片整体传输速率受限于链路中速率最低的环节，因此，切片 s 的瓶颈链路速率 $r_{e_{ij},s}^{\min}(t)$ 可建模为：

$$r_{e_{ij},s}^{\min}(t) = \min \left\{ \frac{r_{e_{ij},s}(t)}{k_{e_{ij},s}(t)} \right\} \quad (12)$$

其中， $k_{e_{ij},s}(t)$ 是切片 s 中的业务流通过链路 e_{ij},s 的次数。

由于切片增益与速率提升并非线性关系，假设遵循边际效益递减原则，切片效益函数可建模为：

$$u_s(t) = \text{lb} \left(1 + r_{e_{ij},s}^{\min}(t) \right) \quad (13)$$

本文目标是对整个网络的通信链路进行带宽配置，包括各类型切片的拓扑生成、资源映射，并优化无人机在整个网络通信的发射功率，实现节能和公平的切片服务。因此，无人机网络切片重配置问题表述为如下所示的多阶段决策问题：

$$\begin{aligned} & \text{Maximize} \quad \sum_{t_x \in \{t_0, t_1, \dots, t_X\}} \sum_{s \in \mathcal{S}} f_a^s(t_x) u_s(t_x, B_s(t_x)) \\ & \text{s.t.} \quad \mathcal{N}_s(t_x) \supseteq \mathcal{N}_{s,a}(t_x) \\ & \quad m_{ij} = 1, \forall e_{ij} \in \mathcal{E}_s, i, j \in \mathcal{N}_s(t_x) \\ & \quad r_{ij} \geq 1, \forall i, j \in \mathcal{N}_{s,a}(t_x) \\ & \quad \sum_{s \in \mathcal{S}} B_{e_{ij},s}(t_x) \leq B_{e_{ij}}(t_x), e_{ij} \in \mathcal{E} \\ & \quad p_n^o(t_x) + p_n^c \leq p_n, n \in \mathcal{N} \end{aligned} \quad (14)$$

其中，预测准确度 $f_a^s(t_x)$ 用来描述 t_x 时刻切片 s 资源配置是否准确，因实时获取精确真实位置信息难，虽位置预测有误差，但能提前指导资源分配、降低实时决策时延。 $\mathcal{N}_{s,a}(t_x)$ 为切片 s 的源目分群（即源节点到目的节点的分群对）在 t_x 时刻接入骨干节点集合。

2.4 基于DDPG的切片重配置求解

网络切片资源分配被视为决策问题，强化学习与深度强化学习（deep reinforcement learning, DRL）适用于此类决策，能学习环境动态规律，依此规律最优决策，优化能耗开销。在马尔可夫转移链模型中，智能体（agent）据流量需求变化完成片间重配置，大时间尺度决策时刻基于小时时间尺度事件驱动而非固定间隔，下一次重配置 t_x 时刻在业务服务质量需求降至一定水平时定义为：

$$t_x = \inf_{\tau} \left\{ \tau \left| \int_{t_0}^{\tau} \left[\sum_{k \in K} \left| \frac{\ell_{f_s^k}(\psi) - \ell_{f_s^k}(t_0)}{\ell_{f_s^k}(t_0)} \right| \right] d\psi \leq (\tau - t_0) \cdot g_{th} \right. \right\} \quad (15)$$

其中, $\ell_{f_s^k}(t_0)$ 为业务 f_s^k 在 t_0 时刻的流量, $\ell_{f_s^k}(\psi)$ 为业务 f_s^k 在 ψ 时刻的流量, g_{th} 为流量波动阈值。

在本问题中, 因为每个切片覆盖多条链路和多个节点, 且每条链路、每个节点可能被多个切片覆盖, 链路为其上的各切片分配带宽, 节点为其上的各切片分配处理资源, 当对单个节点进行优化时 n 为定值, s 表示链路和节点上所覆盖的切片, 所以定义切片 s 在 t_x 时刻的状态 $s_s(t_x)$ 为:

$$s_s(t_x) = \left\{ \mathcal{N}_{s,a}(t_x); B_s(t_{x-1}); \{p_n^o(t_{x-1}) | n \in \mathcal{N}\} \right\} \in \mathcal{S} \quad (16)$$

其中, $\mathcal{N}_{s,a}(t_x)$ 表示切片 s 的源目分群在 t_x 时刻接入骨干节点集合, $B_s(t_{x-1})$ 指切片 s 在 t_{x-1} 时刻重配置后带宽分配的结果, $\{p_n^o(t_{x-1}) | n \in \mathcal{N}\}$ 为 t_{x-1} 时刻重配置后无人机功率分配集合。

在每个大时间尺度时隙下, 定义切片 s 在 t_x 时刻的系统动作 $a_s(t_x)$ 为:

$$a_s(t_x) = \left\{ \mathcal{N}_s(t_x); \mathcal{E}_s(t_x); B_s(t_x); \{p_n^o(t_x) | n \in \mathcal{N}\} \right\} \in \mathcal{S} \quad (17)$$

其中, $\mathcal{N}_s(t_x)$ 、 $\mathcal{E}_s(t_x)$ 和 $B_s(t_x)$ 分别表示切片 s 在 t 时刻的节点集合、链路集合和链路带宽, $\{p_n^o(t_x) | n \in \mathcal{N}\}$ 为无人机功率分配集合。为了简化动作空间大小, 将切片的节点集合和链路集合映射为该切片候选路径组合。即用 $\mathcal{P}_s(t_x)$ 表示该切片 s 内的所有有效路径集合, 并满足源节点到目的节点的路径连通性约束条件。因此, 动作 $a_s(t_x)$ 可以表示为:

$$a_s(t_x) = \left\{ \mathcal{P}_s(t_x); B_s(t_x); \{p_n^o(t_x) | n \in \mathcal{N}\} \right\} \in \mathcal{S} \quad (18)$$

状态转移是随机的, 因为下一个状态不仅取决于所选动作, 还取决于不受 agent 控制的外部因素, 例如随机的流量需求变化和分群位置变化。

切片 s 大时间尺度资源重配置问题的奖励函数表述为每一次动作获得的所有切片效益之和:

$$R(t_x) = \sum_{s \in \mathcal{S}} f_s^s(t_x) \cdot u_s(t_x, B_s(t_x)) - \phi(B_s(t_x)) \quad (19)$$

其中, $f_s^s(t_x)$ 是切片 s 在 t_x 决策时刻的预测准确度, $u_s(t_x, B_s(t_x))$ 为预测切片效益, $\phi(B_s(t_x))$ 为重配置开销。奖励函数的设计旨在大时间尺度上对网络切片进行策略性重配置, 以提升经济效益并降低重配置开销, 同时与小时间尺度切片内资源优化形成闭环, 下节将介绍重配置后的端到端可靠传输服务保障。

3 小时间尺度切片内资源优化

小时间尺度切片内资源优化的目标是设计一种实时、在线优化的带宽分配方案, 以实现在动态需求和动态环境中为每条业务流分配链路资源, 并采用粒子群算法 (PSO) 作为求解策略。

3.1 切片内业务效益模型

由于小时间尺度下的切片自适应调整是在各切片下的所有业务流之间进行的, 只需在单个切片上考虑小时间尺度优化问题。这里定义切片 s 的业务流集合为 $F_s = \{f_s^1, f_s^2, \dots, f_s^K\}$, 将切片 s 内资源池描述为 $\{B_{e_{i,j},s}(t_x) | e_{i,j} \in \mathcal{E}_s\}$ 。业务 f_s^k 通过最短路径路由算法确定传输路径 $P_{f_s^k} = \{\dots, e_{i,j}, \dots\}$, 其中该路径由多条链路构成。随后, 系统向切片资源池申请相应的链路资源, 对于链路 $e_{i,j}$ 存在切片内容量约束:

$$\sum_k B_{e_{i,j},s}(f_s^k, t) \leq B_{e_{i,j},s}(t_x) \quad (20)$$

其中, $B_{e_{i,j},s}(f_s^k, t)$ 是指 t 时刻切片 s 在链路 $e_{i,j}$ 上



给业务流 f_s^k 分配的带宽资源。

业务流 f_s^k 经由多条速率各异的链路时，其整体传输速率受限于链路中速率最低的环节，这一现象被称为瓶颈效应。因此，业务流 f_s^k 的传输速率 $r^{f_s,k}$ 由速率最低的链路决定：

$$r^{f_s,k}(t) = \min_{e_{i,j} \in P_{f_s^k}} r_{e_{i,j}}^{f_s^k}(t) = \min_{e_{i,j} \in P_{f_s^k}} B_{e_{i,j},s}(f_s^k, t) \ln \left[1 + \frac{p_{e_{i,j}}(t) g_{e_{i,j},s}(t)}{B_{e_{i,j},s}(t) N_0} \right] \quad (21)$$

业务流 f_s^k 需要传输的数据包大小记为 $q_{f_s^k}$ ，则业务流 f_s^k 的传输时延 $\tau_t^{f_s^k}$ 可以表示为：

$$\tau_t^{f_s^k} = \sum_{e_{i,j} \in P_{f_s^k}} \frac{q_{f_s^k}}{r_{e_{i,j}}^{f_s^k}(t)} \quad (22)$$

由于无人机的高移动特性，在业务请求过程中，当无人机分群位置发生变化时，原有的骨干网络接入节点不足以支持业务流传输。若转换后的接入节点及链路资源满足分群传输要求，那么业务流的中断时延 $\tau_t^{f_s^k} = 0$ 。若分群位置移动后，该切片无法满足流的传输要求，业务中断时延 $\tau_t^{f_s^k}$ 描述为切片重配置决策时延 τ_W 、切片分配资源时间 τ_A ：

$$\tau_t^{f_s,k} = \tau_W + \tau_A \quad (23)$$

其中， $\tau_W = t_x - t$ ，表示下一次重配置决策到当前中断的时间差； τ_A 表示切片由中断到恢复的时间，与切片重配置开销大小相关，即 $\tau_A = \lambda_r \phi_r$ ， λ_r 为单位重配置开销带来的时延代价。

因此，业务流 f_s^k 的时延 $\tau^{f_s,k}$ 可以表示为：

$$\tau^{f_s,k} = \tau_t^{f_s,k} + \tau_i^{f_s,k} \quad (24)$$

为了最大化业务流服务质量，需要对切片 s 中的业务流进行资源配置，找到一个最优的带宽和功率分配方案，使切片内业务效益最大化，是每种业务获得成功传输数据包的数量除以到达的数据包总数。定义业务 f 从源节点 n_f^s 发送数据包大小为 q_f 到目标节点 n_f^d ，取决于实际的通信需求

模式。对于高吞吐量型业务，定义一个变量 $x(q_f^H)$ ：

$$x(q_f^H) = \begin{cases} 1, & r_f \geq \bar{r}_f^{\max} \\ 0, & r_f < \bar{r}_f^{\text{guar}} \\ \frac{r_f}{\bar{r}_f^{\max}}, & \text{其他} \end{cases} \quad (25)$$

其中， $x(q_f^H) = 1$ 表示数据包成功被接受，同时满足下行数据速率。因此，当且仅当 $r_f \geq \bar{r}_f^{\max}$ 时， $x(q_f) = 1$ 。

对于低时延型业务，定义一个变量 $x(q_f^L)$ ：

$$x(q_f^L) = \begin{cases} 1, & \tau_f \leq \bar{\tau}_f^{\min} \\ 0, & \tau_f > \bar{\tau}_f^{\text{guar}} \end{cases} \quad (26)$$

其中， $x(q_f^L) = 1$ 表示数据包成功被接受，同时满足时延约束要求。

因此，切片内优化模型可以建模为最大化切片内业务效益之和：

$$\begin{aligned} & \text{Maximize } \beta_{f_s^k} \cdot \sum_{f_s^k \in F_s} \sum_{f_s^k \in Q_{f_s^k}} \frac{x(q_{f_s^k}^{H,L})}{|Q_{f_s^k}|} \\ & \text{s.t. } \sum_{f_s^k \in F_s} B_{e_{i,j},s}(f_s^k) \leq B_{e_{i,j},s}, \forall e_{i,j} \in \mathcal{E}_s \\ & \quad \tau_t^{f_s^k} \geq 0, \forall f_s^k \in F_s \end{aligned} \quad (27)$$

其中， $\beta_{f_s^k}$ 是不同类型业务重要性权重占比； $|Q_{f_s^k}|$ 是业务 f_s^k 从源节点 $n_{f_s^k}^s$ 到目标节点 $n_{f_s^k}^d$ 的发送数据包数量。

3.2 基于PSO的切片内优化问题求解

粒子群算法通过模拟鸟群觅食的行为来优化问题求解。每个粒子代表一个可能的带宽分配解，其位置表示当前的资源分配方案：

$$p(t) = \left\{ B_{e_{i,j},s}(f_s^k) \mid f_s^k \in F_s, e_{i,j} \in \mathcal{E}_s \right\} \quad (28)$$

速度表示粒子在解空间中每次迭代对带宽分配方案的调整量：

$$v(t) = \left\{ \Delta B_{e_{i,j},s}(f_s^k) \mid f_s^k \in F_s, e_{i,j} \in \mathcal{E}_s \right\} \quad (29)$$

粒子群通过个体最优解和全局最优解的信息共享,逐步逼近最优解。通过更新粒子的速度和位置,粒子群在多代迭代中逐步寻找最优的带宽分配方案。

为了处理约束条件,本研究结合了粒子群算法和罚函数法。通过在适应度函数中加入惩罚项,粒子在不满足约束条件时会受到惩罚,从而引导粒子避开不可行区域。适应度函数用于衡量粒子当前位置对应解的优劣性,即:

$$F\left(\mathbf{y},\left\{\varepsilon_{e_{i,j},s}^1\right\}\right)=-f\left(\mathbf{y}\right)+\zeta_m\frac{1}{g_s\left(\mathbf{y},\left\{\varepsilon_{e_{i,j},s}^1\right\}\right)} \quad (30)$$

其中, $g_s\left(\mathbf{y},\left\{\varepsilon_{e_{i,j},s}^1\right\}\right) \geq 0$ 表示优化问题中的约束条件。该算法的时间复杂度主要由以下因素决定:粒子数量 (m)、优化问题的维度 (n)、迭代次数 (t) 以及适应度函数的计算复杂度。综合考虑这些因素,算法的时间复杂度可表示为 $O(m \cdot n \cdot t)$ 。

4 仿真分析

本文场景首先构建了一个 $[-200 \text{ m}, 200 \text{ m}]$ 的节点活动区域,其中业务节点随机在 $[-200 \text{ m}, -50 \text{ m}]$ 与 $[50 \text{ m}, 200 \text{ m}]$ 的区域活动,骨干节点在 $[-50 \text{ m}, 50 \text{ m}]$ 的区域随机生成,且骨干节点的位置一旦生成不再变化。机载网关节点(骨干无人机节点)数为 16 个,子网无人机节点数为 200 个,各类切片业务数为 2~4 条,最小时隙长为 1 ms,单位资源量重配置开销为 10^{-4} J/bit ,低时延型和高吞吐量型业务发包数量为 $\{1\ 000, 10\}$,业务包大小分别为 $\{65\ 535 \text{ byte}, 512 \text{ byte}\}$,骨干节点间传输功率上界为 30 dBm,骨干节点间信道数量上限为 8。

4.1 预测性能分析

分群轨迹预测准确度如图 3 所示,可以看出,随着时间和历史数据量的增加,马尔可夫模型能够逐步学习更多的历史规律和位置依赖关系,从而提高预测准确度。这表明系统随着训练数据的

积累,预测模型逐渐趋于稳定,并且能够更精确地反映位置变化的趋势。然而,由于分群的高移动随机性,预测曲线仍然存在一定的波动。当缺乏精准的位置预测时,系统需要进行频繁的重配置,以修正预测准确度。




图3 分群轨迹预测准确度

4.2 大时间尺度分析

可变时间尺度切片间重配置策略训练收敛如图 4 所示,随着训练的进行,模型逐渐优化切片重配置策略,累积奖励趋于平稳。训练初期曲线波动较大,但随着模型利用记忆回放池,策略逐渐成熟,波动减小,并在约 7 000 回合时收敛,表明模型成功平衡了收益最大化与随机性影响。重配置开销训练收敛如图 5 所示,显示了模型在训练中逐步减少重配置开销的过程。训练初期开销较高,但随着策略优化,开销快速下降并趋于稳定,证明算法能有效最小化重配置成本,同时保持面对随机业务的鲁棒性。




图4 可变时间尺度切片间重配置策略训练收敛





图5 重配置开销训练收敛

为验证可变时间尺度切片重配置策略在复杂动态网络中的优越性,本文提出了基于可变时间尺度的资源预留切片重配置策略,并设计了两个对比算法,基于可变时间尺度的无资源预留策略和基于固定时间尺度的无资源预留策略,旨在突出所提策略在复杂场景中的潜在优势。


基于可变时间尺度的无资源预留策略通过动态调整切片资源,专注于当前传输需求以快速响应网络变化,提升了通信效率和鲁棒性。而固定时间尺度的无资源预留策略虽然简化了资源配置流程,但在面对智能交通网络中频繁变化的需求时,缺乏灵活性和适应性。相比之下,基于可变时间尺度的资源预留策略不仅可以灵活调整资源分配,还通过前瞻性地预留资源减少重配置次数和业务中断,从而保障通信的连续性和稳定性,同时增强了网络的适应性和扩展性。

子网集群个数-指标算法对比如图6所示,展示了3种算法在不同子网集群规模下的性能,包括累积奖励值、重配置开销和重配置次数。在累积奖励值上,随着子网集群规模扩大,3种算法的奖励值均提升,但可变时间尺度的资源预留策略始终最优,尤其在资源充足时表现突出。资源紧张时,其增长放缓,差距缩小,而固定时间尺度的资源预留策略表现最差,资源利用率最低。在重配置开销上,可变时间尺度的资源预留策略在小规模网络中开销最低,随着规模增加,其增长速度减缓,但仍保持最低开销。固定时间尺度的


资源预留策略在大规模网络下的开销显著增加,显示出对动态需求的适应性不足。在重配置次数上,可变时间尺度的资源预留策略表现最优,始终保持最低重配置次数,特别是在小规模网络中效率明显。固定时间尺度的资源预留策略由于周期性触发机制,重配置次数始终不变,但灵活性不足;可变时间尺度的无资源预留策略在规模增大时重配置次数显著增加,效率下降。



(a) 累积奖励值对比



(b) 重配置开销对比



(c) 重配置次数对比

图6 子网集群个数-指标算法对比

4.3 小时间尺度分析

小时间尺度切片内资源调度策略训练收敛如图7所示。训练初期,模型探索链路资源分配策略,导致波动较大,但在200回合后迅速收敛,业务达标率显著提升。拟合曲线清晰展示了模型性能的持续优化,表明算法在动态业务需求下最终能实现高效的资源分配策略学习与应用。





图7 小时间尺度切片内资源调度策略训练收敛


本文通过仿真验证了高吞吐量型和低时延型两种业务类型的服务质量需求,并通过对比算法验证了本文算法的有效性。下文分别对小时间尺度端到端传输中所有业务的丢包率、低时延型业务的时延和高吞吐量型业务的吞吐量进行仿真对比。

业务服务质量分析对比如图8所示,对比了3种算法在不同条件下的性能,包括业务传输成功率、业务完成率和平均业务吞吐量。在传输成功率方面,随着路由跳数增加,3种算法的传输成功率均下降,但可变时间尺度的资源预留策略在路由跳数不超过6时保持了超过95%的成功率,而固定时间尺度的无资源预留策略在路由跳数超过4后显著下降。在业务完成率方面,随着传输时延放宽,各算法的业务完成率均提升,可变时间尺度的资源预留策略在5 ms以内保持较高完成率,可变时间尺度的无资源预留策略在10 ms时超越固定时间尺度的无资源预留策略。在平均业务吞吐量方面,可变时间尺度的资源预留策略始终最优,固定时间尺度的无


资源预留策略在小规模网络中表现尚可,但随着子网集群增多,吞吐量显著下降,可变时间尺度的无资源预留策略在资源竞争加剧时吞吐量下降更明显。



(a) 路由跳数-传输成功率对比



(b) 传输时间-业务完成率对比



(c) 子网集群个数-平均业务吞吐量对比

图8 业务服务质量分析对比



5 结束语

低空智联网通过连接无人机、传感器等智能终端,广泛应用于物流配送、灾害救援、环境监测等领域。然而,其网络环境因拓扑结构的动态变化、空域资源稀缺以及业务需求多样化,对资源管理提出了严峻挑战。针对低空智联网动态性强、业务多样化和资源受限等问题,本文提出了一种基于未来网络接入拓扑和业务需求预测的切片间自适应资源分配方法。通过在切片内引入适度的资源冗余配置,使切片具备适应拓扑动态变化和多样化业务需求的能力,并在适度降低当前网络服务质量的前提下,提升未来资源调度的灵活性和业务适配性,从而有效减少切片重配置的频率和开销。在此基础上,本文结合小时间尺度的精细化资源调度策略,显著提升了切片内资源利用率,并优化了业务 QoS 需求。仿真结果表明,该方法在动态低空智联网环境中具有显著的优势,为低空智联网复杂场景下的资源管理和业务保障提供了有效支持。

参考文献:

- [1] BORODIN V, KOLESNICHENKO V, KOVALKINA N. Assessment of indicators for updating adjacency matrix of self-organizing flying ad hoc network[J]. *Journal of Aerospace Technology and Management*, 2024, 16(1): 1-15.
- [2] YANG J, SUN K X, HE H S, et al. Dynamic virtual topology aided networking and routing for aeronautical ad-hoc networks[J]. *IEEE Transactions on Communications*, 2022, 70(7): 4702-4716.
- [3] ZHAO J Y, FANG Z, GE J T, et al. A survey on identification of critical nodes in ad hoc network[C]//*Proceedings of the 2023 IEEE 6th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*. Piscataway: IEEE Press, 2023: 1770-1774.
- [4] MANDAR D, EITAN A, HÉLÈNE L C. Strategic resource pricing and allocation in a 5G network slicing Stackelberg game[J]. *IEEE Transactions on Network and Service Management*, 2023, 20(1): 502-520.
- [5] YUAN Z H, MUNTEAN G M. AirSlice: a network slicing framework for UAV communications[J]. *IEEE Communications Magazine*, 2020, 58(11): 62-68.
- [6] 吴思雷. 基于深度强化学习的多无人机轨迹联合调控方法研究[D]. 北京: 北京邮电大学, 2022.
WU S L. Research on joint trajectory control method of multi-UAV based on deep reinforcement learning[D]. Beijing: Beijing University of Posts and Telecommunications, 2022.
- [7] 罗娟, 徐岳阳, 李仁发. 网络虚拟化中动态资源分配算法研究[J]. *通信学报*, 2011, 32(7): 64-70.
LUO J, XU Y Y, LI R F. Dynamical resource allocation algorithm research in network virtualization[J]. *Journal on Communications*, 2011, 32(7): 64-70.
- [8] DHANIK S, VIJAI C, REDDY Y M, et al. Ad hoc networks: adaptable connectivity for contemporary business needs[C]//*Proceedings of the 2023 10th IEEE Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON)*. Piscataway: IEEE Press, 2023: 1694-1698.
- [9] TANG J H, SHIM B, QUEK T Q S. Service multiplexing and revenue maximization in sliced C-RAN incorporated with URLLC and multicast eMBB[J]. *IEEE Journal on Selected Areas in Communications*, 2019, 37(4): 881-895.
- [10] WANG G, FENG G, QUEK T Q S, et al. Reconfiguration in network slicing: optimizing the profit and performance[J]. *IEEE Transactions on Network and Service Management*, 2019, 16(2): 591-605.
- [11] ZHANG H, WONG V W S. A two-timescale approach for network slicing in C-RAN[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(6): 6656-6669.
- [12] CHEN X J, NI W, CHEN T Y, et al. Multi-timescale online optimization of network function virtualization for service chaining[J]. *IEEE Transactions on Mobile Computing*, 2019, 18(12): 2899-2912.
- [13] CAMARGO J S, CORONADO E, RAMIREZ W, et al. Dynamic slicing reconfiguration for virtualized 5G networks using ML forecasting of computing capacity[J]. *Computer Networks*, 2023(236): 110001.
- [14] GUAN W Q, ZHANG H J, LEUNG V C M. Customized slicing for 6G: enforcing artificial intelligence on resource management[J]. *IEEE Network*, 2021, 35(5): 264-271.
- [15] TOKUDA K, SATO T, OKI E. Network slice reconfiguration with deep reinforcement learning under variable number of ser-

- vice function chains[J]. Computer Networks, 2023(224): 109636.
- [16] HUA Y X, LI R P, ZHAO Z F, et al. GAN-powered deep distributional reinforcement learning for resource management in network slicing[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(2): 334-349.
- [17] HUANG R L, GUO M, GU C J, et al. Toward scalable and efficient hierarchical deep reinforcement learning for 5G RAN slicing[J]. IEEE Transactions on Green Communications and Networking, 2023, 7(4): 2153-2162.
- [18] TU H Y, BELLAVISTA P, ZHAO L Q, et al. Priority-based load balancing with multiagent deep reinforcement learning for space-air-ground integrated network slicing[J]. IEEE Internet of Things Journal, 2024, 11(19): 30690-30703.
- [19] ZHANG S L. An overview of network slicing for 5G[J]. IEEE Wireless Communications, 2019, 26(3): 111-117.
- [20] BASAR E, YILDIRIM I. Reconfigurable intelligent surfaces for future wireless networks: a channel modeling perspective[J]. IEEE Wireless Communications, 2021, 28(3): 108-114.

[作者简介]



陈鸿杰 (1982-), 男, 现就职于中国西南电子技术研究所, 主要研究方向为通信与数据链。



郭昱甫 (2002-), 男, 电子科技大学信息与通信工程学院硕士生, 主要研究方向为无线网络资源管理与优化、智能无线网络技术。



吴凡 (1978-), 男, 博士, 电子科技大学信息与通信工程学院副教授, 主要研究方向为边缘智能网络、无线网络资源管理与优化、智能无线网络技术。



张科 (1978-), 男, 博士, 电子科技大学信息与通信工程学院副教授, 主要研究方向为移动边缘计算调度、下一代无线网络设计与优化、智能电网、物联网等。



熊凯 (1991-), 男, 博士, 电子科技大学信息与通信工程学院副研究员、在站博士后, 主要研究方向为车联网资源分配、移动边缘计算和机器学习。