

大规模卫星网络通算协同资源管理

鲍晨曦, 盛敏*, 周笛, 姬思敬, 史琰, 李建东

(西安电子科技大学空天地一体化综合业务网全国重点实验室, 陕西西安 710071)

摘要: 大规模卫星网络(Large-scale Satellite Networks, LSN)星载算力的显著提升,推动了星上自主资源管理的实现,是保障多样化业务端到端(End-to-End, E2E)服务时效性的关键手段。然而,LSN 拓扑的高动态变化使得星间通算资源难以高效协同,对满足各类业务差异化的时效性需求并确保高质量 E2E 服务提出了严峻挑战。为此,本文通过建立虚拟节点及链路映射模型,形成静态覆盖业务请求的虚拟网络,有效避免卫星高速运动对业务 E2E 服务的影响;通过建立融合 LSN 拓扑结构的网络状态信息提取模型,实时捕捉星间结构化通算资源与业务需求特征的动态演化关系,并通过设计参数共享的切片资源分配决策机制,实现星地协作智能切片资源管理及融合业务需求特征的网络通算资源切片;此外,通过设计区域资源管理模式并引入服务导向信息,为星上自主 E2E 服务决策提供局部拓扑感知和目标定位能力,实现动态 LSN 通算资源的按需高效协同,借助星载处理能力改善时延约束下多样化业务的 E2E 服务性能。仿真结果表明,提出的算法与非拓扑感知算法相比,在不同通算资源及业务到达数量下分别可提升 28%、25.2% 和 39.3% 的服务完成性能。

关键词: 大规模卫星网络;多样化业务;通算协同;资源管理;端到端服务

基金项目: 国家自然科学基金(No.62461160329, No.62422114, No.62371360)

中图分类号: TN927.23

文献标识码: A

文章编号: 0372-2112(2025)12-4199-17

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

DOI: 10.12263/DZXB.20250885

Communication and Computing Collaborative Resource Management for Large-Scale Satellite Networks

BAO Chen-xi, SHENG Min*, ZHOU Di, JI Si-jing, SHI Yan, LI Jian-dong

(The State Key Laboratory of Integrated Service Networks, Xidian University, Xi'an, Shaanxi 710071, China)

Abstract: The significant improvement in onboard computing capabilities of large-scale satellite networks (LSNs) has facilitated the realization of satellite autonomous resource management, which is a key means to ensure the timeliness of end-to-end (E2E) services for diversified services. However, the highly dynamic topology of LSNs makes it difficult to efficiently collaborate on inter-satellite communication and computing resources, posing severe challenges to meeting the differentiated timeliness requirements of various services and ensuring high-quality E2E services. To this end, this paper establishes a virtual node and link mapping model to form a virtual network that statically covers service requests, effectively avoiding the impact of high-speed satellite movement on E2E services. Furthermore, a network status information extraction model is designed that integrates the LSN topology, which captures the dynamic evolution relationship of inter-satellite structured communication and computing resources and service demand characteristics in real time. Leveraging a parameter-sharing slice resource allocation decision-making mechanism, satellite-ground collaborative intelligent slice resource management and network communication and computing resource slicing with service demand characteristics can be achieved. In addition, by designing a regional resource management mode and introducing service orientation information, local topology awareness and target positioning capabilities are provided for satellite autonomous E2E service decision-making. It achieves on-demand and efficient coordination of dynamic communication and computing resources, leveraging onboard processing capabilities to improve the E2E service performance of diversified services under latency constraints. Simulation results show that the proposed algorithm can improve the service completion performance by 28%, 25.2% and 39.3% respectively, under different communication and computing resources and service request numbers compared with the non-to-

pology-aware algorithm.

Key words: large-scale satellite networks; diversified services; communication and computing collaboration; resource management; end-to-end service

Foundation Item(s): National Natural Science Foundation of China (No.62461160329, No.62422114, No.62371360)

1 引言

更加多样化的业务需求和立体化的全球服务覆盖结构是第六代移动通信系统(6th-Generation, 6G)的典型特征^[1-3]. 未来, 6G有望进一步拓展第五代移动通信系统(5th-Generation, 5G)的三类业务场景, 支持包括高速率需求的超高数据业务、高连接密度需求的海量物联网业务, 以及其他即将推出的各类新兴业务^[4]. 显著差异化的服务质量(Quality of Service, QoS)导致其对6G网络中通信和计算资源的需求存在差异甚至相互矛盾. 例如, 全息通信、增强现实等^[4]超高数据业务需要海量通信资源来实现大容量数据传输, 并在端到端(End-to-End, E2E)服务期间通过数据压缩来缓解网络的传输压力^[5]. 物联网设备产生的海量物联网业务通常是间歇性的小数据传输需求, 且多为计算密集型业务^[6], 例如大规模生态环境监测、船舶远程信息处理等, 因此对计算资源的需求更高.

包含数百至数万颗卫星的大规模卫星网络(Large-scale Satellite Networks, LSN)被设想为地面网络的有效补充^[7], 并可以实现将地面通信网络延伸至太空, 其凭借覆盖广、容量大等优势, 被学术界和工业界视为6G的重要基础设施, 可为未来多样化业务提供按需的高性能服务^[8]. 然而, 仅依靠卫星网络规模的不断扩张, 资源和服务能力的提升始终有限, 且卫星的超密集部署可能带来更多不可控的干扰^[9]. 因此, 面对多样化的业务和差异化的通算资源需求, 高效协调LSN的通算资源, 确保各类业务都能获得满意的服务性能, 即保证多样化业务QoS的一致性, 具有重要意义.

然而, 在同一物理网络上提供多样化业务将显著增加管控的复杂性, 采用一刀切的网络架构来满足差异化的服务需求并不合理^[10]. 网络切片作为一种极具潜力的技术, 旨在通过在公共物理网络上创建多个E2E的虚拟网络, 实现为多样化业务高效分配网络资源^[11, 12]. 该技术得益于软件定义网络和网络功能虚拟化技术的发展, 已经在5G地面网络中发挥了重要作用. 然而, 将网络切片应用于具有动态拓扑的LSN中, 并通过高效协同LSN的通算资源来保障多样化业务E2E服务性能仍需进一步研究. 此外, 本文明确网络切片是从资源管理的角度实现整网资源分配的, 它通常具有长周期特性. 因此, 需要进一步从资源调度的角度为动态到达的业务请求分配节点资源, 并提供E2E服务.

综上所述, 本文关注LSN面向多样化业务的通算协同资源管理(Communication and Computing Collaborative Resource Management for Diversified Services, C3RM-DS), 以实现多样化业务的最佳综合服务性能. 然而, 设计求解C3RM-DS问题的框架与方法面临以下挑战: 首先, 鉴于星间链路(Inter-Satellite Links, ISLs)的广泛应用, C3RM-DS问题受到卫星网络动态拓扑结构的约束, 探索卫星网络拓扑结构特征, 并刻画网络节点资源和业务需求, 对实现高效通算资源管理以及确保多样化业务的服务性能至关重要; 其次, 为保障多样化业务QoS的一致性, 具备差异化通算资源需求的各类业务都应得到高性能服务, 如何制定C3RM-DS问题的目标函数, 既有效保证每个切片的服务性能, 又能缩小各切片服务性能之间的差异是需要解决的一个挑战; 最后, 卫星固有的轨道运动特性以及多样化业务的时空非均匀分布, 使网络资源和业务需求高动态变化, 这对LSN的资源管理的自主性和自适应能力提出了更高的要求.

为克服上述挑战, 本文设计了拓扑及业务特征感知的通算协同资源管理(Topology and Service Characteristics-Aware Communication and Computing Collaborative Resource Management, TSCA-C3RM)算法框架, 以有效求解制定的联合优化切片可用资源和服务提供策略, 最大化多样化业务综合服务满意度的C3RM-DS问题, 实现对LSN高动态通算资源的高效协同管理并保障多样化业务QoS的一致性. 主要贡献包括: (1)建立了虚拟节点及链路映射模型, 通过形成静态覆盖业务请求的虚拟网络, 有效避免由卫星与地面相对高速运动带来的覆盖目标区域卫星节点时变的问题; (2)设计了多样化业务综合服务满意度目标函数, 既能有效刻画各类业务服务性能的差异, 又能确保在各类业务请求具有较高服务性能时获得更优的综合服务满意度; (3)通过建立融合LSN拓扑结构的网络状态信息提取模型, 实时捕捉星间结构化通算资源与业务需求特征的动态演化关系, 并通过设计参数共享的切片资源分配决策机制, 实现星地协作智能切片资源管理, 提升对多样化业务的服务能力; (4)通过设计区域资源管理模式并引入服务导向信息, 为星上自主E2E服务决策提供局部拓扑感知和目标定位能力, 实现动态LSN通算资源的按需高效协同并保障时延约束下多样化业务的E2E服务性能; (5)通过大量仿真实验与算

法对比,从服务性能、适应性等角度验证了提出 TSCA-C3RM 算法的优越性。

2 相关工作

卫星网络资源管理一直是学术界和工业界的研究课题,对卫星网络高效利用有限资源,为用户提供高质量服务具有重要意义^[13-15],且将卫星作为边缘计算节点,通过联合优化卫星通算资源为地面用户提供高性能计算卸载、数据压缩等服务被广泛研究^[16-18]。具体而言,文献[16]构建了面向计算卸载服务的卫星通信网络联合通算资源管理问题,并提出了一种基于博弈论和多对一匹配理论的方案,以较低的时间复杂度获得了近似最优解。文献[17]关注单颗卫星在轨计算及数据卸载的联合通算资源管理问题,并通过在轨数据压缩提升了数据卸载效率,但其无法应用于现阶段采用 ISL 组网的卫星网络场景。文献[18]则研究了具备 ISL 的卫星网络在地球观测业务中的服务性能,依托 ISL 在数据卸载时效性方面的优势,通过联合优化业务传输路径及星载计算资源分配策略,有效提升了数据卸载效率并降低了服务成本。然而,文献[16-18]提出的方法主要集中于传统优化问题的静态求解思路,难以适应卫星网络高动态的资源及业务需求。

深度强化学习(Deep Reinforcement Learning, DRL) 凭借其在动态环境中的适应性以及在未知环境中解决问题的能力而得到广泛认可^[19]。文献[20]提出了基于深度确定性策略梯度算法的智能计算卸载方案,通过联合优化卸载决策及星载通算资源在不同业务需求到达率下均获得了最佳服务性能。文献[21]关注了缓存辅助的计算卸载场景,并提出应用深度图卷积强化学习方法来实现在高动态环境中学习通算存资源的联合最优策略。考虑到卫星重叠覆盖的影响,文献[22]提出了一种面向卫星网络的基于深度 Q 网络(Deep Q-Network, DQN)的动态用户关联与计算卸载联合优化方法,通过星间协作将业务卸载到具有足够剩余计算能力的卫星上,从而实现负载均衡并确保业务能够按需完成。然而,文献[20-22]提出的方法主要应用于类型单一且具有相似 QoS 需求的业务,不足以应对未来 6G 的多样化业务需求。

网络切片作为保障多样化业务需求的关键技术已被广泛应用于卫星网络^[2]。具体而言,文献[23]面向延迟容忍和延迟敏感业务建立了卫星无线电接入网(Radio Access Network, RAN)联合资源切片与调度问题,通过设计基于强化学习的两层联合资源切片与调度方法,实现了动态网络资源与业务需求的高效匹配。文献[24]则通过设计具有双时间尺度和资源粒度的卫星 RAN 切片框架,以及基于分层 DRL 的资源切片算法,分别从宏

观和微观的角度分配 RAN 的动态网络资源。文献[25]和文献[26]则关注两类差异化业务需求,通过将 LSN 中的卫星划分为多个簇,缓解为每颗卫星单独进行动态切片决策带来的高求解复杂度的挑战。然而,相比于卫星 RAN 切片资源分配,面向 E2E 业务的卫星承载网资源分配问题的研究相对较少。文献[27]考虑采用网络切片技术为多样化业务需求提供 E2E 服务的场景,并基于设计的联合网络切片和路由机制开发了一种多任务 DRL 算法框架,从服务满意度的角度验证了算法的有效性。文献[28]采用相似的求解思路,提出了一种用于卫星网络的自动网络切片框架,实现了路由计算和切片资源分配的双重目标。文献[27]和文献[28]为卫星网络提供 E2E 服务提供了良好的求解思路,但其算法设计忽略了卫星网络拓扑动态性对路由及切片资源分配策略的影响,这意味着其在拓扑高动态变化的网络环境中难以维持高服务性能甚至失效。

综上所述,现有卫星网络通算资源管理研究通常仅关注类型单一且具有相似 QoS 需求的业务,缺乏应对卫星网络高动态资源及多样化业务需求的能力,难以对多样化业务提供高质量综合服务性能。此外,现有针对卫星网络多样化业务需求的研究主要面向卫星 RAN 而非 E2E 业务,且面向多样化业务 E2E 服务的研究难以有效解决卫星网络动态拓扑结构对业务请求 E2E 路径及切片资源分配策略的影响。

3 系统模型

3.1 网络模型

本文考虑一个 LSN 为 6G 多样化业务提供服务的典型场景,其中,包括一组低轨卫星(Low Earth Orbit satellites, LEO),表示为 $LS = \{i | i = 1, 2, \dots, |LS|\}$, 一组地面站,表示为 $GS = \{g | g = 1, 2, \dots, |GS|\}$ 和一个网络控制中心。在该场景中,网络控制中心拥有强大的计算能力来管控 LSN 的全网资源,而 LEO 拥有常规计算能力可执行资源管理策略并可为业务请求提供数据处理服务。此外,分布在地球表面的不同类型的用户可以直接访问 LEO 以寻求服务,因此,与传统卫星网络将数据传输到地面站不同,本文关注 LSN 实现业务请求从源节点到目的节点的数据承载,而地面站负责接收来自 LEO 的资源和业务请求信息并汇总至网络控制中心以制定资源管理策略。此外,本文关注资源管理策略对 LSN 服务性能的影响,仅考虑业务请求到达 LEO 后的服务过程,并假设网络资源和业务请求信息的有效性能够得到保证。本文将为每类业务请求构建网络切片,表示为 $NS = \{n | n = 1, 2, \dots, |NS|\}$, 并通过切片隔离的方式确保每种类型的业务请求仅由其网络切片上的资源

提供服务. LSN 提供三种不同类型服务且共享整个 LSN 资源的示例如图 1 所示.

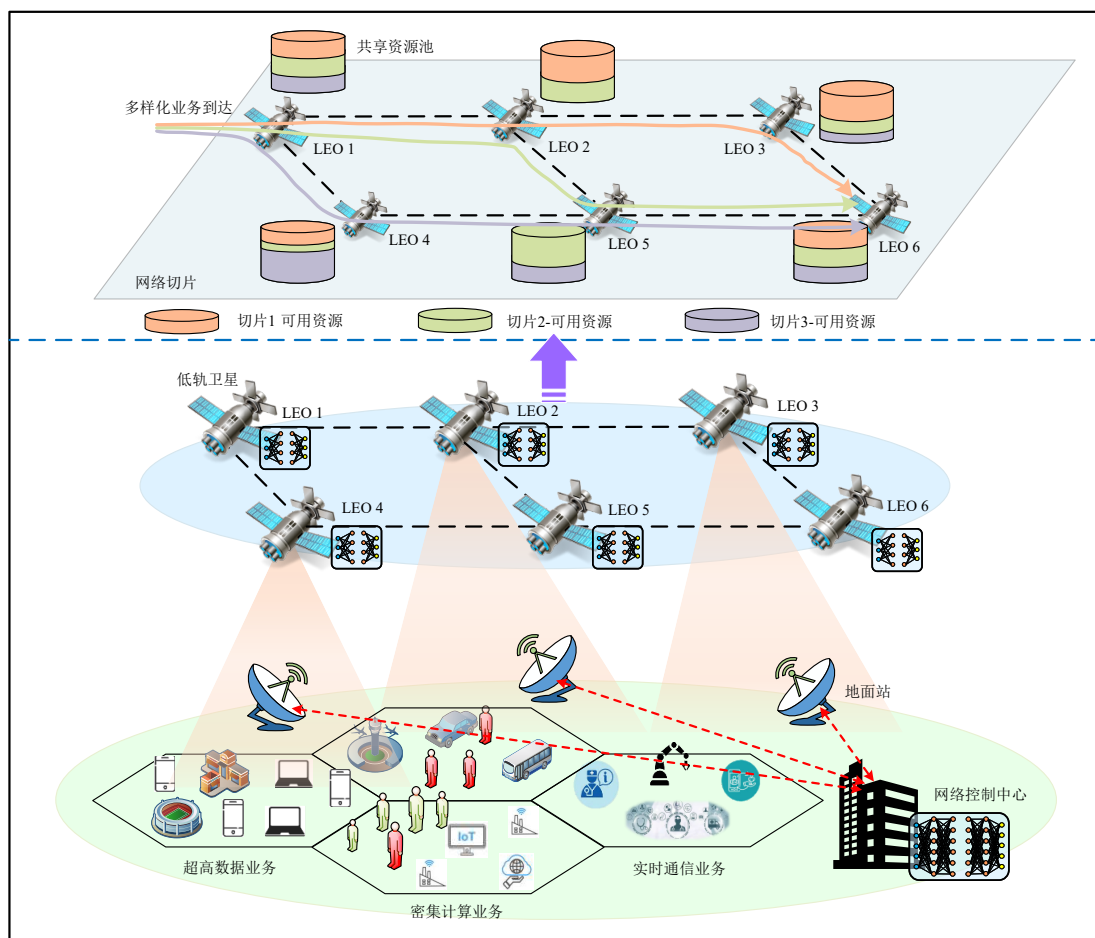


图 1 LSN 提供三种不同类型服务且共享整个 LSN 资源的示例图

本文根据视距可见性原则评估 LEO 间的 ISL 能否建立, 如果两颗 LEO 不在视距内, 则其 ISL 不存在, 即无法建立; 否则可以建立^[29]. 然而, 由于 LEO 收发信机数量有限, 其不可能与视距范围内的所有 LEO 建立 ISL, 因此, 本文采用广泛使用的“一星四链”模式建立 ISL, 即每颗 LEO 最多能够同时与 4 颗 LEO 建立 ISL^[30,31]. 此外, 鉴于卫星的轨道运动特性, 任意两颗 LEO 卫星建立的 ISL 是间歇性连通的, 这意味着 LSN 的拓扑结构是时变的. 考虑到网络资源切片和业务服务提供的时间尺度差异, 本文将资源管理的规划周期划分为一组大时间尺度时隙 (Large-Timescale Slots, LTSs), 表示为 $K = \{k | k = 1, 2, \dots, |K|\}$, 并进一步将每个 LTS 划分为一组小时间尺度时隙 (Small-Timescale Slots, STSs), 表示为 $T = \{t | t = 1, 2, \dots, |T|\}$. 其中, 每个 LTS 的间隔固定为 ζ 且每个 STS 的间隔固定为 τ . 此外, 本文假设 LSN 的拓扑结构是准静态的, 即网络拓扑结构在一个 LTS 内保持不变, 但在不同的 LTS 之间发生

变化.

3.2 虚拟节点及链路映射模型

在 LSN 为业务请求提供服务期间, 由于 LEO 固有的轨道运动特性, 不同 LTS 下覆盖同一地面区域的 LEO 可能存在差异, 从而导致将业务请求卸载至地面用户的 LEO 是动态变化的, 但实时获取业务请求的目标 LEO 并为其持续规划传输路径是不现实的. 为此, 虚拟节点映射被广泛采用以维持目标 LEO 与地面区域的静态覆盖关系^[28]. 本文采用基于 Voronoi 的虚拟节点生成与映射模型, 以初始 LTS 的 LEO 星下点 $Z(\phi_i^k, \varphi_i^k)_{k=1}$ 为生成器, 生成一个 Voronoi 图 VR, 其中, ϕ_i^k 和 φ_i^k 分别表示 LTS k 中 LEO i 的星下点所对应的经度和纬度, 且构成 VR 的每个 Voronoi 区域 VR_v 被称为虚拟节点, 表示为 $v \in \text{VN}, \text{VN} = \{v | v = 1, 2, \dots, |\text{VN}|\}$. 一旦虚拟节点被生成, 本文将应用就近原则在每个 LTS 完成 LEO 与虚拟节点的映射, 其映射关系表示为

$$m_v^k = \arg \min_{i \in LS} \frac{\sum_{o \in V(\text{VR}_i)} d_{(o,i)}^k}{|V(\text{VR}_i)|}, \forall v \quad (1)$$

其中, m_v^k 表示映射为虚拟节点 v 的 LEO; $V(\text{VR}_v)$ 表示 Voronoi 区域 VR_v 的顶点集; $d_{(o,i)}^k$ 表示顶点 o 和 LEO i 之间的距离. 以铱星系统为例的虚拟节点生成与映射示意图如图 2 所示, 图中的 Voronoi 区域将地球表面划分为与 LSN 中 LEO 数量相等的多边形, 并与 LEO 存在一一映射关系. 利用虚拟节点映射模型, 可以将 LSN 有效转换为与其等效的虚拟网络. 由于虚拟节点可以有效屏蔽 LEO 覆盖地面区域的动态性, 本文将基于虚拟网

络建立并求解 C3RM-DS 问题.

虚拟节点之间的连接关系可以通过 ISL 的连接关系进行映射, 从而构建虚拟网络拓扑. 有向 ISL 的集合表示为 $\text{ISL} = \{(i,j) | i,j \in \text{LS}\}$, 虚拟链路集合表示为 $\text{VE} = \{(v,u) | v,u \in \text{VN}\}$, 其中, i 和 v 为起始节点, j 和 u 为终止节点. 2 个 LTS, 6 颗 LEO 为例的网络拓扑映射关系如图 3 所示, 图中展示基于虚拟节点映射的虚拟链路与 ISL 的映射关系. 可以看出, 即使两个 LTS 中 ISL 的连接关系没有发生变化, 但由于 LEO 与虚拟节点之间的映射关系随时间变化且虚拟节点的相对位置不变, 导致虚拟网络的拓扑结构是不一致的, 这表明虚拟网络的拓扑结构仍然是动态的.

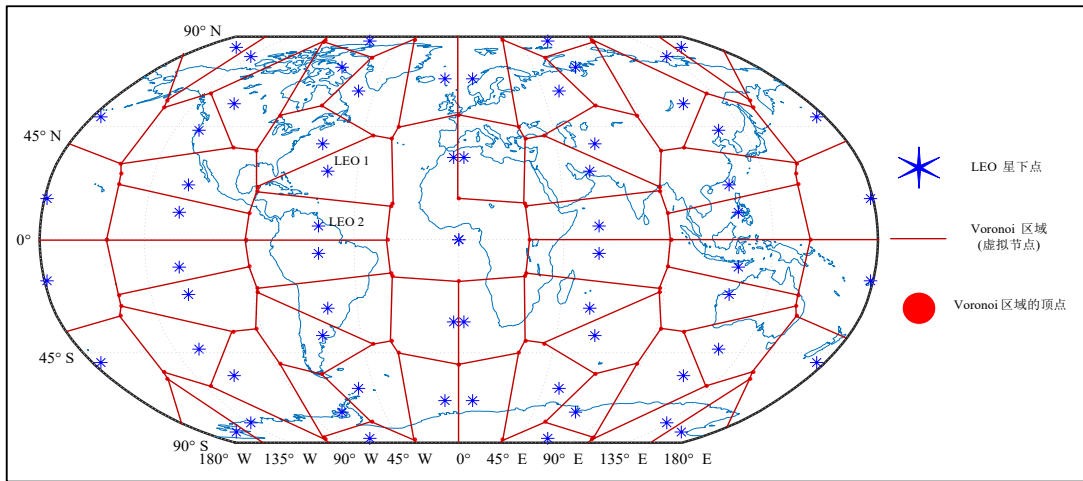


图 2 以铱星系统为例的虚拟节点生成与映射示意图

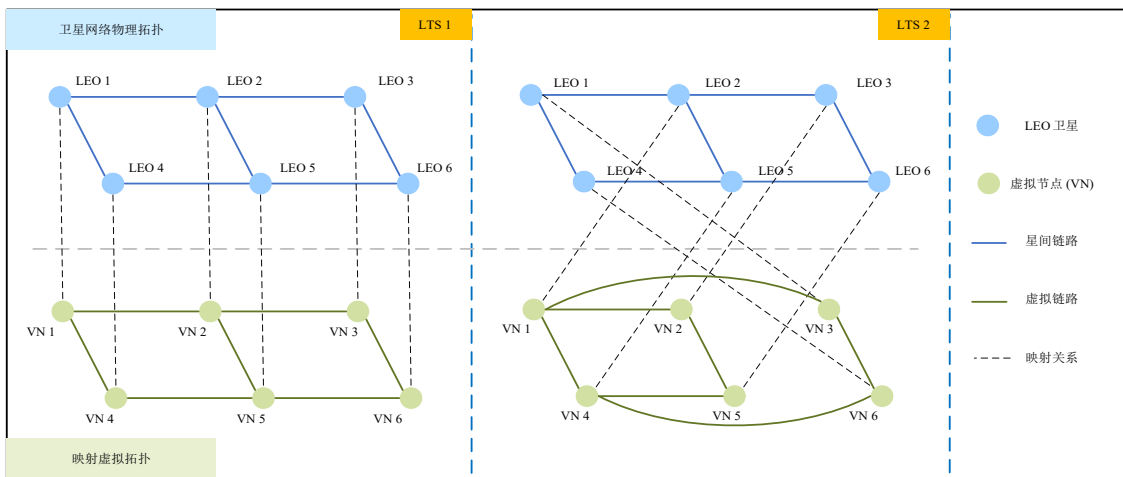


图 3 2 个 LTS, 6 颗 LEO 为例的网络拓扑映射关系图

3.3 业务请求模型

本文考虑业务请求的批量服务, 并将其批量服务周期设为一个 STS^[32]. 在每个服务周期开始时, 本文假设一批具有不同服务截止时间的业务请求到达 LEO,

并根据每个业务请求的到达时间和服务时延需求确定其服务截止时间. 此外, 本文考虑了星载存储的因果关系, 设置当前 STS 中到达的业务请求将在下一个 STS 中开始被服务. 业务请求的服务过程可能持续多个 STS,

跨 STS 的业务请求将与新到达的业务请求合并为一批进行服务。

进一步地, 本文为每个切片构建一个业务请求序列, 表示为 $\mathcal{Q}_n = \{q_n | q_n = 1, 2, \dots, |\mathcal{Q}_n|\}$. 业务请求到达 LEO 后, 将依据其源节点和目的节点明确所对应的虚拟节点用于后续服务提供. 具体而言, 本文将业务请求到达的 LEO 设置为源节点, 将业务请求到达时覆盖目的用户所在区域的 LEO 设置为目的节点, 并应用虚拟节点映射模型确定所对应的虚拟源节点 $VS(q_n)$ 和虚拟目的节点 $VD(q_n)$. 每个业务请求均由一个五元组组成, 表示为 $q_n = (VS(q_n), VD(q_n), AT(q_n), BR(q_n), DR(q_n))$, 其中, $AT(q_n)$ 表示业务请求的到达时间, $BR(q_n)$ 表示业务请求的数据传输需求, $DR(q_n)$ 表示业务请求的服务时延需求.

3.4 时延模型

在 LSN 中, 任意业务请求的 E2E 服务在每个 STS 中均可能经过多跳, 其单跳时延 $D_v^t(q_n)$ 由传输时延、传播时延、处理时延和排队时延组成. 具体而言, 传输时延与 ISL 的传输速率和业务请求的数据传输需求相关, 表示为

$$DT_{(v,u)}^t(q_n) = \frac{B_v^t(q_n)}{CT_{(v,u)}^t(n)} \quad (2)$$

其中, $B_v^t(q_n)$ 是虚拟节点 v 需要传输的业务请求 q_n 的数据量, 表示为

$$B_v^t(q_n) = (1 - \hat{\chi}_v^t(q_n)) \cdot BR(q_n) + \hat{\chi}_v^t(q_n) \cdot C_{\text{ratio}} \cdot BR(q_n) \quad (3)$$

其中, $\hat{\chi}_v^t(q_n) \in \{0, 1\}$ 表示业务请求 q_n 位于虚拟节点 v 时是否已完成数据处理, 若已完成则 $\hat{\chi}_v^t(q_n) = 1$, 否则 $\hat{\chi}_v^t(q_n) = 0$; C_{ratio} 表示压缩率. $CT_{(v,u)}^t(n) \leq CT_{(v,u)}^t$ 表示切片 n 在虚拟链路 (v, u) 上可用的传输速率, 即分配给切片 n 的虚拟链路 (v, u) 上的通信资源. $CT_{(v,u)}^t$ 是虚拟链路 (v, u) 的传输速率, 根据文献[33], 其可被表示为

$$CT_{(v,u)}^t = \frac{P_{\text{st}} \cdot G_{\text{tr}}(v) \cdot G_{\text{rc}}(u)}{\kappa \cdot T \cdot (E_b/N_0)_{\text{req}} \cdot M} \cdot \left(\frac{c}{4\pi \cdot SI_{(v,u)}^t \cdot F} \right)^2 \quad (4)$$

其中, P_{st} 表示 LEO 的恒定发射功率; $G_{\text{tr}}(v)$ 和 $G_{\text{rc}}(u)$ 分别表示发射和接收天线增益; κ 表示玻尔兹曼常数; T 为系统总噪声温度; $(E_b/N_0)_{\text{req}}$ 和 M 分别表示所需的每比特接收能量与噪声密度之比以及链路余量; $SI_{(v,u)}^t$ 表示发送节点和接收节点间的距离; F 和 c 分别表示通信中心频率和光速. 需要说明的是, 鉴于本文考虑 LSN 的拓

扑结构在不同的 LTS 之间发生变化, 对于任意 LTS k 中的每个 STS t 而言, 其传输速率是相同的, 即 $CT_{(v,u)}^t = CT_{(v,u)}^k$ 且每个切片可用的通信资源 $CT_{(v,u)}^t(n) = CT_{(v,u)}^k(n)$.

传播时延与发送节点和接收节点间的传播距离 $d_{(v,u)}^t$ 和传播速率光速 c 有关, 表示为

$$DP_{(v,u)}^t(q_n) = \frac{d_{(v,u)}^t}{c} \quad (5)$$

处理时延与可用的计算资源、业务请求的数据量及单位比特所需的处理周期 C_{pc} 有关, 表示为

$$DC_v^t(q_n) = \frac{BR(q_n) \cdot C_{\text{pc}}}{CP_v^t(n)} \quad (6)$$

其中, $CP_v^t(n) \leq CP_v^t$ 表示切片 n 在虚拟节点 v 上可用的计算资源, CP_v^t 表示在 STS t 中虚拟节点 v 上部署的总计算资源. 类似地, 对于任意一个 LTS k 中的每个 STS t 而言, 其总计算资源 $CP_v^t = CP_v^k$ 且每个切片可用的计算资源 $CP_v^t(n) = CP_v^k(n)$. 排队时延与业务请求的服务时间相关, 被表示为 $DQ_v^t(q_n)$.

4 问题建模

本节研究联合优化切片可用资源和服务提供策略, 最大化多样化业务综合服务满意度的 C3RM-DS 问题. 首先, 介绍了资源约束、链路使用约束以及服务提供约束, 而后建立了基于上述约束条件的 C3RM-DS 问题的数学模型, 最后, 本文介绍了 C3RM-DS 问题的 MDP 建模.

4.1 C3RM-DS 问题约束

4.1.1 资源约束

在执行网络资源切片时, 对于任意一个 LTS k 中的任意虚拟链路而言, 分配给每个切片的通信资源之和不能超过该虚拟链路的传输速率, 其计算公式为

$$\sum_{n \in \text{NS}} CT_{(v,u)}^k(n) \leq CT_{(v,u)}^k \quad (7)$$

类似地, 分配给每个切片的计算资源之和不能超过该虚拟节点部署的计算资源, 其计算公式为

$$\sum_{n \in \text{NS}} CP_v^k(n) \leq CP_v^k \quad (8)$$

在执行业务服务提供时, 对于任意切片而言, 任意虚拟链路上传输的业务请求的数据量之和不能超过分配给该切片的通信资源可承载的最大数据量, 表示为

$$\sum_{q_n \in \mathcal{Q}_n} B_v^t(q_n) \cdot \zeta_{(v,u)}^t(q_n) \leq CT_{(v,u)}^t(n) \cdot \tau \quad (9)$$

其中, $\zeta_{(v,u)}^t(q_n) \in \{0, 1\}$ 表示业务请求 q_n 是否在虚拟链路 (v, u) 上传输, 若传输则 $\zeta_{(v,u)}^t(q_n) = 1$, 否则 $\zeta_{(v,u)}^t(q_n) = 0$. 类似地, 对于任意切片而言, 业务请求在任意虚拟节点

上使用的计算资源之和不能超过分配给该切片的计算资源,表示为

$$\sum_{q_n \in Q_n} \text{BR}(q_n) \cdot C_{\text{pc}} \cdot \chi_v^t(q_n) \leq \text{CP}_v^t(n) \cdot \tau \quad (10)$$

其中, $\chi_v^t(q_n) \in \{0, 1\}$ 表示业务请求 q_n 在虚拟节点 v 上是否执行处理操作,若执行则 $\chi_v^t(q_n) = 1$, 否则 $\chi_v^t(q_n) = 0$. 此外,本文进一步明确数据处理操作主要包括数据压缩及计算服务,其中,数据压缩通常在星间通信资源难以满足超高数据业务传输服务需求时被执行,以降低其对星间通信资源的要求,实现该业务的高效传输并保障网络服务性能.但这并不意味着超高数据业务必须被压缩,也不意味着每种类型的业务均需要被压缩,例如,数据量小且时效性要求高的实时通信业务就不需要.计算服务则针对卸载到 LEO 的密集计算业务,但由于密集计算业务的单星到达数量较多,业务请求可能会被进一步传输至其他 LEO 进行服务.对于数据压缩而言,考虑到其可能会造成业务请求原始信息的损失,本文设置任意业务请求最多被压缩一次,表示为

$$\sum_{t \in T} \sum_{v \in \text{VN}} \chi_v^t(q_n) \leq 1 \quad (11)$$

根据式(11), $\widehat{\chi}_v^t(q_n)$ 可进一步被表示为

$$\widehat{\chi}_v^t(q_n) = \max_{u \in P_v^t(q_n)} (\chi_u^t(q_n)) \quad (12)$$

其中, $P_v^t(q_n)$ 表示在业务请求到达虚拟节点 v 之前其传输路径上经过的虚拟节点的集合.

4.1.2 链路约束

本文不考虑业务请求在服务过程中的数据拆分,因此,对于任意业务请求而言,在执行每次服务提供决策时,最多有一条 ISL 能够被选择用于业务传输,表示为

$$\sum_{u \in N_v} \xi_{(v,u)}^t(q_n) \leq 1 \quad (13)$$

其中, N_v 表示虚拟节点 v 的邻居虚拟节点集.

4.1.3 服务提供约束

对于任意切片的业务请求,其被成功服务需要满足以下三个条件.

(1) 起始节点为业务请求到达 LEO 后的虚拟源节点,表示为

$$\sum_{t \in T} \sum_{(v_s(q_n), u) \in \text{VE}} \xi_{(v_s(q_n), u)}^t(q_n) = 1 \quad (14)$$

(2) 终止节点为业务请求的虚拟目的节点,表示为

$$\sum_{t \in T} \sum_{(v, v_D(q_n)) \in \text{VE}} \xi_{(v, v_D(q_n))}^t(q_n) = 1 \quad (15)$$

(3) 必须在业务请求的服务截止时间前完成,即满足业务请求的服务时延需求,否则,将被视为服务失败并从星载存储器中删除,时延约束表示为

$$\sum_{t \in T} \left(\sum_{(v,u) \in \text{VE}} \left(\text{DT}_{(v,u)}^t(q_n) + \text{DP}_{(v,u)}^t(q_n) \right) \cdot \xi_{(v,u)}^t(q_n) + \sum_{v \in \text{VN}} \left(\text{DC}_v^t(q_n) \cdot \chi_v^t(q_n) + \text{DQ}_v^t(q_n) \right) \right) \leq \text{DR}(q_n) \quad (16)$$

4.2 C3RM-DS 问题建模

本文旨在通过 LSN 中通信和计算资源的高效协作,实现多样化业务的 QoS 一致性,即期望每种类型的业务都能获得高性能服务.与当前多样化业务的研究不同,本文考虑所有业务具有相同的服务优先级,并且不希望通过牺牲部分延迟容忍业务来提高延迟敏感业务的服务性能.因此,本文建立了一个新的综合服务满意度目标函数,衡量每个切片的服务满意度水平以及切片间服务满意度的差异.最大化多样化业务综合服务满意度的 C3RM-DS 问题建模为

$$\text{C3RM-DS: } \max_{\text{CT, CP, } \xi, \chi} \prod_{n \in \text{NS}} \left(U_n \cdot \frac{U_n}{\max_{n \in \text{NS}} (U_n)} \right) \quad (17)$$

s.t. (7)~(16)

其中, U_n 是切片 n 的业务请求服务完成率,表示为

$$U_n = \frac{\sum_{q_n \in Q_n} h(q_n)}{|Q_n|} \quad (18)$$

其中, $h(q_n)$ 为二进制变量,用于刻画业务请求是否被成功服务,若成功则 $h(q_n) = 1$, 否则 $h(q_n) = 0$.

$\text{CT} = \left\{ \text{CT}_{(v,u)}^k(n) \mid \forall n \in \text{NS}, (v,u) \in \text{VE}, k \in K \right\}$ 和 $\text{CP} = \left\{ \text{CP}_v^k(n) \mid \forall n \in \text{NS}, v \in \text{VN}, k \in K \right\}$ 分别表示切片通算资源分配的连续变量的集合; $\xi = \left\{ \xi_{(v,u)}^t(q_n) \mid \forall q_n \in Q_n, (v,u) \in \text{VE}, t \in T \right\}$ 和 $\chi = \left\{ \chi_v^t(q_n) \mid \forall q_n \in Q_n, v \in \text{VN}, t \in T \right\}$

分别表示用于为每个业务请求提供服务的整数变量的集合.因此, C3RM-DS 问题是一个混合整数非线性规划问题,属于 NP(Nondeterministic Polynomial time) 难问题.对于本文研究的 LSN 和海量多样化业务请求场景,传统基于模型的优化方法很难在多项式时间内完成计算.此外,高动态 LSN 资源、拓扑结构以及业务请求也促使求解 C3RM-DS 问题变得更具挑战性.

4.3 C3RM-DS 问题的 MDP 设置

如上文所述, C3RM-DS 问题的本质是网络资源切片与业务服务提供的耦合.在多样化业务 E2E 服务期间,无论是网络资源切片还是业务服务提供阶段,当前 LST/STS 选取的策略都将影响业务请求的服务结果,并改变下一 LST/STS 切片待服务的业务需求及可用通算资源状态,这是一个典型的马尔科夫决策过程(Markov Decision Process, MDP).为此,本文将 C3RM-DS 问题建

模为 MDP, 并分别设置对应于两个阶段的 MDP 核心要素. 求解 C3RM-DS 问题的 TSCA-C3RM 算法框架将在下一节进行详细介绍.

4.3.1 环境状态

在网络资源切片阶段, 本文关注 LSN 通算资源的高效协同, 并期望分配给每个切片的资源与该切片的业务请求相匹配, 以确保每个切片的服务性能, 因此, 本文将网络中 LEO 的星载通算资源及切片业务请求相关信息设置为环境状态. 在 LTS k 的每个虚拟节点 v 的状态被表示为

$$\mathbf{s}_v^k = \left[\overline{\text{CT}}_{(v,u)}^k \Big|_{u \in N_v}, \text{CP}_v^k, \left\{ Q_v^k(n), \overline{\text{RL}}_v^k(n), \overline{B}_v^k(n) \right\}_{n \in \text{NS}} \right] \quad (19)$$

其中, $Q_v^k(n)$ 表示在 LTS k 到达的切片业务请求的数量; $\overline{\text{RL}}_v^k(n)$ 表示平均剩余服务时间; $\overline{B}_v^k(n)$ 表示平均业务请求数据量.

对于业务服务提供阶段, 鉴于业务请求的服务过程可能经过多跳和跨 STS 才能够被完成, 且普遍采用的路径级资源管理决策模式难以有效应对动态网络拓扑环境下 E2E 传输路径变化的问题. 本文考虑采用多跳点到点的区域资源管理模式为业务请求的每一跳制定服务提供策略, 其实现细节将在下一节介绍. 基于该模式, 业务请求可在每个 STS 实现多跳传输, 这意味着智能体的状态转移不仅基于 STS, 也与当前服务的业务请求, 以及业务请求所在的虚拟节点相关. 对于任意位于虚拟节点 v 上的切片业务请求的 E2E 传输服务而言, 其环境状态主要由网络资源切片阶段分配给每个切片的可用通算资源以及切片业务请求的服务导向信息两个部分组成, 表示为

$$\mathbf{s}_v^t(q_n) = \left[\left\{ \overline{\text{CT}}_{(v,u)}^t(n), \Theta_{(v,u)}^t(q_n), \Delta_u^t(q_n), \Upsilon_u^t(q_n) \right\}_{u \in N_v}, \overline{\text{CP}}_v^t(n) \right] \quad (20)$$

其中, $\overline{\text{CT}}_{(v,u)}^t(n)$ 和 $\overline{\text{CP}}_v^t(n)$ 分别表示归一化的切片可用通信和计算资源; $\Theta_{(v,u)}^t(q_n) \in [0, 1]$ 表示虚拟链路 (v, u) 上成功传输业务请求 q_n 的概率; $\Delta_u^t(q_n)$ 表示服务导向信息, 用于刻画邻居虚拟节点 u 与业务请求 q_n 的虚拟目的节点 $\text{VD}(q_n)$ 之间的相对位置, 包括靠近、远离和到达; $\Upsilon_u^t(q_n)$ 表示邻居虚拟节点 u 上通信资源对业务请求

q_n 的可用性, 若邻居虚拟节点 u 为虚拟目的节点 $\text{VD}(q_n)$, 则可用性设置为 1.

4.3.2 智能体动作

基于网络资源切片阶段保障多样化业务高质量服务的优化目标, 该阶段每个虚拟节点的动作对应于分配给每个切片可用通算资源的占比, 表示为 $\mathbf{a}_v^k = \left\{ \widehat{\text{CT}}_{(v,u)}^k(n), \widehat{\text{CP}}_v^k(n) \Big|_{u \in N_v, n \in \text{NS}} \right\}$.

基于区域资源管理模式, 业务服务提供阶段的区域可行动作集与局部网络拓扑结构、服务需求和可用网络资源相关, 包括用于传输业务请求的邻居虚拟节点, 以及是否对业务请求执行数据处理操作, 表示为 $A_v^t(q_n) = \hat{N}_v^t \otimes \left\{ f_v^t(q_n) \right\}_{f_v^t(q_n) \in \{0,1\}} \cup (\text{None}, 0)$. 其中, \hat{N}_v^t 表示可与虚拟节点 v 建立虚拟链路的邻居虚拟节点的集合; \otimes 表示两个集合的笛卡尔积; $f_v^t(q_n)$ 表示数据处理标识; $(\text{None}, 0)$ 表示不执行任何操作.

4.3.3 即时奖励

即时奖励作为当前状态下选取动作的评价, 其设置与求解问题的优化目标有关. 本文的优化目标是由各类业务请求服务完成率计算得到的综合服务满意度, 其需要网络资源切片与业务服务提供两阶段策略均执行完成才能够获得. 具体而言, 每个 LTS 的综合服务满意度是衡量网络资源切片阶段策略有效性的指标, 但考虑到强化学习框架是通过最大化累积奖励实现的, 而本文建立的综合服务满意度目标函数式(17)是乘积的形式. 本文采用取对数的方式将乘积转换为求和, 奖励表示为

$$R(\mathbf{S}_k, \mathbf{A}_k) = \sum_{n \in \text{NS}} \log(U_k(n)) - |\text{NS}| \cdot \max_{n \in \text{NS}} (\log(U_k(n))) \quad (21)$$

其中, $\mathbf{S}_k = [\mathbf{s}_0^k \ \mathbf{s}_1^k \ \cdots \ \mathbf{s}_{|V_{\text{NS}}|}^k]$ 表示所有虚拟节点的状态矩阵; $\mathbf{A}_k = [\mathbf{a}_0^k \ \mathbf{a}_1^k \ \cdots \ \mathbf{a}_{|V_{\text{NS}}|}^k]$ 表示所有虚拟节点的动作矩阵; $U_k(n)$ 表示在 LTS k 中切片 n 的业务请求的服务完成率; $\log(\cdot)$ 表示对数操作.

对于业务服务提供阶段, 为保障多跳点到点决策期间业务请求能够获得到达虚拟目的节点的有效引导, 本文设计与服务导向信息相匹配的奖励函数, 逐步引导服务请求接近目的节点, 如式(22)所示. 其中, \emptyset 表示空集; $\mathbf{a}_v^t(q_n) \in A_v^t(q_n)$ 表示业务服务提供阶段的动作向量.

$$R(\mathbf{s}_v^t(q_n), \mathbf{a}_v^t(q_n)) = \begin{cases} 100, & \mathbf{a}_v^t(q_n) = (\text{VD}(q_n), f_v^t(q_n)) \\ \frac{\Delta_u^t(q_n) \cdot (f_v^t(q_n) + 1) \cdot \Upsilon_u^t(q_n)}{D_v^t(q_n)}, & \mathbf{a}_v^t(q_n) \neq (\text{VD}(q_n), f_v^t(q_n)), \text{VD}(q_n) \notin \hat{N}_v^t, \hat{N}_v^t \neq \emptyset \\ 0, & \text{otherwise} \end{cases} \quad (22)$$

5 TSCA-C3RM 算法设计

为应对 LSN 拓扑高动态变化造成星间通算资源协同效率低下的问题,并满足各类业务差异化的时效性需求确保高质量 E2E 服务,本文通过深度挖掘 LSN 拓扑结构演化特征并融合业务需求的星间结构化信息,

设计了 TSCA-C3RM 算法框架,如图 4 所示. 该算法框架由网络拓扑及业务需求特征深度提取助力的网络资源切片方法,与局部拓扑结构感知及目标定位赋能的业务服务提供方法构成,其通过设计网络状态信息提取模型,利用星间结构化特征的资源管理机制,并引入 Actor-Critic 强化学习框架实现.

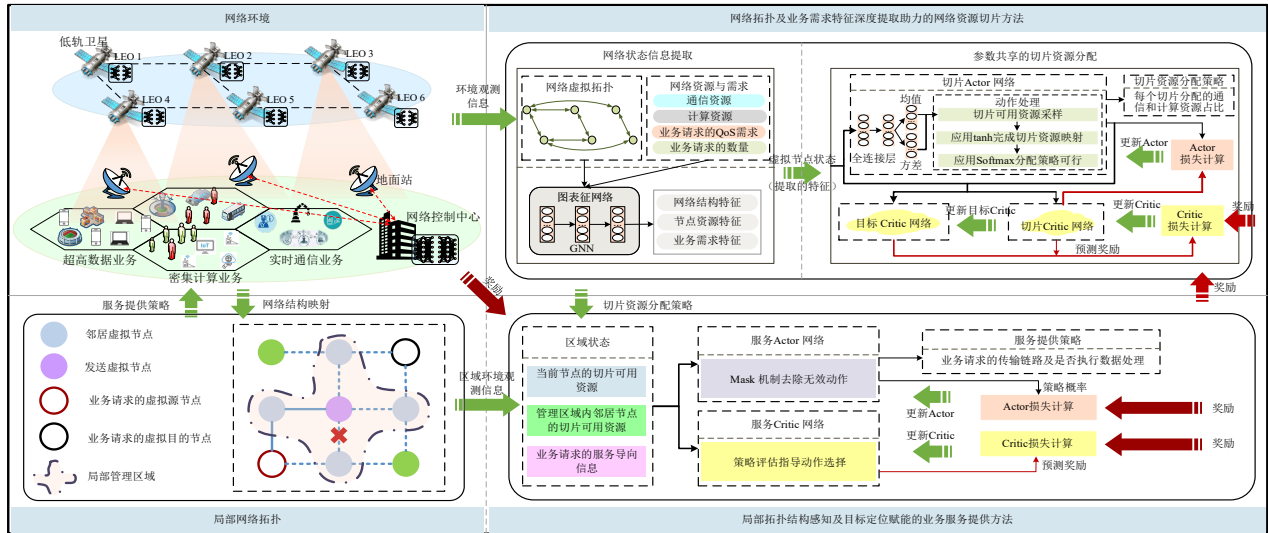


图 4 TSCA-C3RM 算法框架图

5.1 网络状态信息提取模型

ISL 的应用将 LSN 的单星通算资源及业务需求通过网络拓扑结构相耦合,使得各 LEO 在提供服务期间存在资源共享及服务共担的现象. 因此,为保障各类业务的 E2E 服务性能,网络切片资源分配策略需充分考虑 LSN 动态拓扑结构对网络通算资源及业务需求分布特征的影响. 本文通过建立融合 LSN 拓扑结构的网络状态信息提取模型,实时捕捉星间结构化通算资源与业务需求特征的动态演化关系,为 LSN 网络资源与切片业务需求的高效匹配提供信息支持.

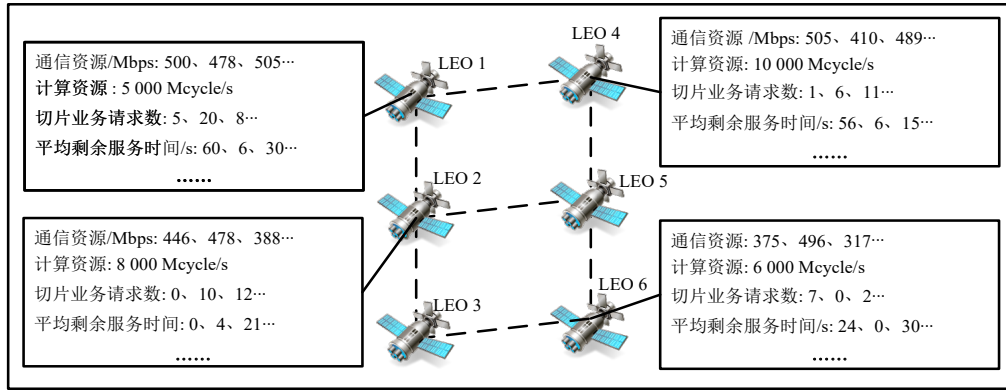
具体而言,本文首先建立了以虚拟节点为顶点,以任意两个虚拟节点间存在的虚拟链路为边的具有节点属性的网络资源与切片业务需求图表征模型,其中,图中的边是双向的,节点属性由网络状态信息 s_v^k 组成,用于刻画图中每个顶点的可用通算资源以及等待被服务的每个切片的业务需求. 图 5 展示了以 6 个 LEO 为例的基于 LTS 2 时刻网络虚拟拓扑的表征示例,其中,图 5(a) 给出了 6 个 LEO 的可用资源与切片业务需求示例. 图 5(a) 中 LEO 3 和 LEO 5 没有标注具体信息,表示在当前时隙这两个 LEO 上没有业务请求到达. 图 5(b) 则展示的是完成虚拟节点和链路映射后的表征示例和节点属性表. 图 5(b) 中节点属性表给出了每个虚拟节点对应的

LEO 的可用资源和切片业务需求,且 LEO 3 中没有业务请求到达,其与切片业务需求相关的属性信息均为 0.

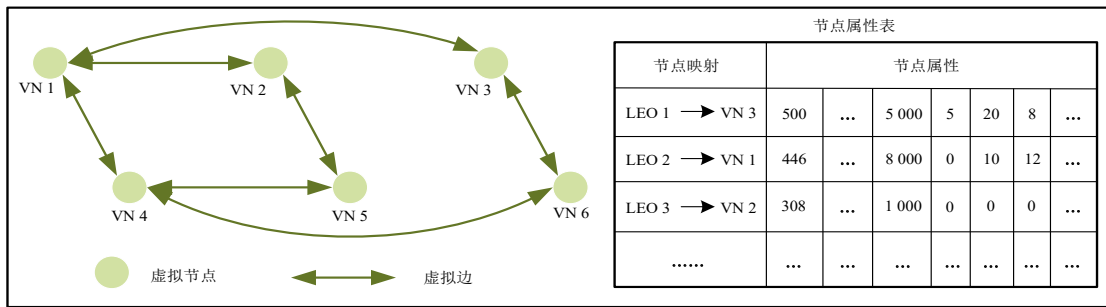
而后,应用图卷积神经网络在拓扑特征学习及信息聚合方面的优势,挖掘每个 LTS 构建的资源与切片业务需求图中虚拟节点间的潜在影响,捕捉内嵌网络拓扑结构信息的星间结构化通算资源与业务需求特征,为网络资源切片提供关键决策依据. 第 l 个图卷积层输出的特征提取结果被表示为

$$h_v^{(l)} = \sigma \left(\text{CAT} \left(W_{\text{hidden}_1}^{(l)} \cdot h_v^{(l-1)}, W_{\text{hidden}_2}^{(l)} \cdot h_{N_v}^{(l-1)} \right) \right).$$

其中, $\sigma(\cdot)$ 是激活函数; $\text{CAT}(\cdot)$ 是向量拼接函数; $W_{\text{hidden}_1}^{(l)}$ 和 $W_{\text{hidden}_2}^{(l)}$ 表示第 l 层神经网络的权重; $h_{N_v}^{(l-1)}$ 表示第 $l-1$ 层从虚拟节点 v 的邻居中聚合的特征提取结果. 输入层对原始网络状态信息进行特征提取,表示为 $h_v^{(0)} = \sigma(s_v^k \cdot W_{\text{Input}})$, 其中, W_{Input} 表示输入层神经网络的权重. 此外,卫星的轨道运动使 LSN 的拓扑结构具有时序演化的高动态特性,为确保网络状态信息特征提取能够有效捕捉拓扑结构的时序演化关系,并为每个虚拟节点的切片资源分配提供有效辅助,本文设计将特征提取网络分别用于切片 Actor 和切片 Critic 网络中,并通过时序决策不断学习网络拓扑的演化特征.



(a) 6个LEO的可用资源与切片业务需求示例



(b) LTS 2时刻6个虚拟节点的表征结果

图5 以6个LEO为例的基于LTS 2时刻网络虚拟拓扑的表征示例

5.2 利用星间结构化特征的资源管理机制

5.2.1 参数共享的切片资源分配机制

基于网络切片资源管理的非时效性敏感特点,本文设计在网络控制中心上构建全局切片资源管理实体,完成对LSN中所有虚拟节点的切片资源分配,通过充分获取LSN整网的拓扑结构、业务需求及通算资源信息,实现LSN切片资源分配模型的集中训练与优化;并设计采用参数共享的方式,应用统一的网络切片资源管理模型协调每个LEO上的切片资源分配策略,且得到的切片资源分配方案由LEO分布式执行.在协调切片资源时,由于切片资源分配的动作是连续的,本文设置采用与Soft Actor-Critic强化学习框架十分契合且被广泛使用的高斯分布来近似通信与计算资源动作的概率分布^[34],该分布不仅有助于加快训练收敛且简单有效.而后,采用tanh激活函数及Softmax函数完成对通算资源策略的映射,保障依据高斯分布采样的动作满足 $\sum_{n \in NS} \widehat{CT}_{(v,u)}^k(n) \leq 1$ 且 $\sum_{n \in NS} \widehat{CP}_v^k(n) \leq 1$ 的资源约束.通过设计参数共享的切片资源分配机制,网络中的任意LEO均可直接应用训练好的切片资源管理模型,并依据获取的星间结构化资源及业务需求信息,完成切片资源分配决策,从而实现星地协作的星上智能切片资源管理,以及融合LSN拓扑结构及网络业务需求特

征的网络资源切片.

5.2.2 区域决策的业务服务提供机制

为避免动态网络拓扑环境下可变业务请求E2E传输路径对算法适用性的影响,本文设计区域资源管理模式为服务决策提供统一的区域决策空间.具体而言,区域资源管理模式是指为一个业务请求提供从源节点到目的节点的E2E传输服务时采用多跳点到点传输方式进行多次资源管理决策的资源管理模式^[35].每一跳的资源管理策略是基于图4所示的由任意发送虚拟节点与其邻居虚拟节点构成的局部管理区域制定的.该局部管理区域作为资源管理决策的最小单元,是智能体观测到的区域环境,其可依据前文所述的“一星四链”的ISL建立规则和虚拟节点及链路映射模型确定.因此,局部管理区域中的邻居虚拟节点不超过4个,这意味着无论网络拓扑如何变化,可选择的邻居虚拟节点集合中最多包括4个节点,表明智能体的区域决策空间是一致的.进一步地,为保障时延约束下多样化业务的E2E服务性能,本文设计网络控制中心与全网所有的局部网络拓扑环境进行交互,收集一系列由(业务请求,虚拟节点,STS)构成的三维状态演化经验数据,提供丰富的局部网络拓扑特征,助力网络控制中心快速且全面地学习不断变化的网络环境.此外,由于本文采

用区域资源管理模式,网络控制中心感知的局部网络拓扑特征均是在每个LEO的视角下完成的,这意味着每个LEO可分布式部署相同的业务服务提供模型,并利用局部拓扑感知和目标定位能力实现星上自主E2E服务决策,保障动态LSN通算资源的按需高效协同。

5.3 TSCA-C3RM算法设置与训练

本文将Actor-Critic强化学习框架引入面向多样化业务的LSN通算协同资源管理场景中,以解决网络状态及切片资源分配动作连续性造成状态和动作空间无限大的问题。具体而言,如图4所示,本文应用深度神经网络构建了切片Actor和Critic网络,近似网络资源切片策略函数 $\pi_\theta(\mathbf{S}_k)$ 和 Q 函数 $Q_{\omega_b}(\mathbf{S}_k, \mathbf{A}_k)$,并构建服务Actor和Critic网络,近似业务服务提供策略函数 $\pi_\theta(\mathbf{s}_v^t(q_n))$ 和状态值函数 $V_\omega(\mathbf{s}_v^t(q_n))$ 。此外,为保障连续控制问题训练的稳定性,本文引入目标 Q 函数 $\hat{Q}_{\omega_b}(\mathbf{S}_k, \mathbf{A}_k)$ 并采用Soft Actor-Critic强化学习框架的软评估方式对选取的切片资源分配策略进行评价并提供指导。对于业务服务提供阶段,考虑到ISL连通性对业务传输的影响,本文在服务Actor网络的输出层设置采用Mask机制去除无效动作,确保选取策略的可行性。构建的神经网络均采用损失函数进行参数更新,网络资源切片阶段的损失函数分别被表示为

$$J_\pi(\theta) = \frac{1}{|M|} \cdot \sum_{\mathbf{S}_k \in M} \left(\alpha \sum_{v \in \text{VN}} \log \pi(\mathbf{a}_v^k | \mathbf{s}_v^k; \theta) - \min_{b \in \{1,2\}} (Q_{\omega_b}(\mathbf{S}_k, \mathbf{A}_k)) \right) \quad (23)$$

$$J_Q(\omega_b) = \frac{1}{2|M|} \cdot \sum_{(\mathbf{S}_k, \mathbf{A}_k) \in M} \left(Q(\mathbf{S}_k, \mathbf{A}_k; \omega_b) - \left(\hat{R}(\mathbf{S}_k, \mathbf{A}_k) - \alpha \sum_{v \in \text{VN}} \log \pi_\theta(\mathbf{a}_v^{k+1} | \mathbf{s}_v^{k+1}) \right) \right)^2, \forall b \in \{1,2\} \quad (24)$$

其中, M 是网络资源切片阶段训练所采用的Minibatch; $\hat{R}(\mathbf{S}_k, \mathbf{A}_k) = R(\mathbf{S}_k, \mathbf{A}_k) + \gamma \min_{b \in \{1,2\}} (\hat{Q}_{\omega_b}(\mathbf{S}_k, \mathbf{A}_k))$ 是预估的 Q 值; $\gamma \in [0,1)$ 是折扣因子; α 是温度参数,决定熵与奖励的相对重要性,从而控制最优策略的随机性,求解 α 的损失函数被定义为

$$J(\alpha) = \frac{1}{|M|} \cdot \sum_{\mathbf{S}_k \in M} \left(-\alpha \sum_{v \in \text{VN}} \log \pi_\theta(\mathbf{a}_v^k | \mathbf{s}_v^k) - \alpha H_0 \right) \quad (25)$$

其中, H_0 是目标熵。此外,目标 Q 函数 $\hat{Q}_{\omega_b}(\mathbf{S}_k, \mathbf{A}_k)$ 的神经网络参数更新是基于 Q 函数 $Q_{\omega_b}(\mathbf{S}_k, \mathbf{A}_k)$ 神经网络参数及软更新系数 η 实现的,表示为 $\bar{\omega}_b = \eta \omega_b + (1 -$

$\eta) \bar{\omega}_b$,其中, η 用于控制目标 Q 函数 $\hat{Q}_{\omega_b}(\mathbf{S}_k, \mathbf{A}_k)$ 更新的速度,保障训练的稳定性。

业务服务提供阶段的损失函数分别表示为

$$J_\pi(\vartheta) = -\frac{1}{|\mathcal{B}|} \cdot \sum_{\mathbf{s}_v^t(q_n) \in \mathcal{B}} \log \pi(\mathbf{a}_v^t(q_n) | \mathbf{s}_v^t(q_n); \vartheta) \cdot \mathcal{W}_v^t(q_n) \quad (26)$$

$$J_V(\omega) = \frac{1}{2|\mathcal{B}|} \cdot \sum_{\mathbf{s}_v^t(q_n) \in \mathcal{B}} \left(\hat{R}(\mathbf{s}_v^t(q_n), \mathbf{a}_v^t(q_n)) - V_\omega(\mathbf{s}_v^t(q_n); \omega) \right)^2 \quad (27)$$

其中, \mathcal{B} 是业务服务提供阶段训练所采用的Minibatch; $\mathcal{W}_v^t(q_n) = \hat{R}(\mathbf{s}_v^t(q_n), \mathbf{a}_v^t(q_n)) - V_\omega(\mathbf{s}_v^t(q_n))$ 是时序差分(Temporal Difference, TD)误差; $\hat{R}(\mathbf{s}_v^t(q_n), \mathbf{a}_v^t(q_n)) = R(\mathbf{s}_v^t(q_n), \mathbf{a}_v^t(q_n)) + \gamma \cdot V_\omega(\mathbf{s}_v^t(q_n))$ 表示估计状态值。

本文提出的用于求解C3RM-DS问题的TSCA-C3RM算法的伪代码如算法1所示。在该算法中,网络资源切片与业务服务提供两个阶段的决策均基于构建的虚拟网络拓扑,且网络资源切片阶段为所有虚拟节点制定的切片资源分配策略将作为业务服务提供阶段算法的输入,用于明确为各切片业务请求提供服务可用的通算资源情况。业务服务提供阶段算法的伪代码如算法2所示,其中, $Q_t(n)$ 表示在第 t 个STS中第 n 个切片上等待被服务的业务请求的集合。该算法为每个切片的业务请求依次提供E2E传输服务并通过设置业务请求完成标识 $\text{dn}_v^t(q_n)$ 明确业务请求是否被成功服务。

6 仿真实验

6.1 仿真参数设置

本文考虑在典型的铱星通信系统下对提出的TSCA-C3RM算法进行仿真实验,以验证其在多样化业务综合服务性能方面的有效性。具体而言,对于TSCA-C3RM算法的训练,铱星通信系统包括66颗均匀分布在6个高度为780 km、倾角为86.4°的轨道的LEO。此外,本文设置资源管理的规划周期为1 h,每个LTS的时间间隔 $\zeta = 120$ s且每个STS的时间间隔 $\tau = 10$ s。仿真关注三类具有差异化数据传输需求和服务时延需求的业务:(1)超高数据业务 $\text{BR}(q_n) \in [200, 500]$ Mbits, $\text{DR}(q_n) = 15$ s,且单星到达业务请求数为300;(2)实时通信业务 $\text{BR}(q_n) \in [0.2, 0.5]$ Mbits, $\text{DR}(q_n) = 1$ s,且单星到达业务请求数为100;(3)密集计算业务 $\text{BR}(q_n) \in [20, 50]$ Mbits, $\text{DR}(q_n) = 5$ s,且单星到达业务请求数为150。详细的仿真参数设置如表1所示。

算法 1 TSCA-C3RM 算法

输入: 虚拟网络拓扑, 切片业务请求 Q_n
 输出: 切片资源分配及服务提供方案

1. 随机初始化神经网络参数, 初始化训练周期 episode, Minibatch 尺寸 $|M|$, $M = \emptyset$, loop_num = 0
2. WHILE episode > 0
3. 获得网络初始状态 S_1
4. FOR $k = 1$ to $|K|$
5. 应用策略函数 $\pi_\theta(S_k)$ 获得当前 LTS 下所有虚拟节点的切片资源分配策略 A_k
6. 应用算法 2 依据当前 LTS 分配给每个切片的可用资源为到达的业务请求提供服务
7. 依据服务提供结果计算奖励 $R(S_k, A_k)$
8. 获取下一 LTS 网络状态信息 S_{k+1}
9. 存储经验信息 $(S_k, A_k, k, R(S_k, A_k), S_{k+1})$ 至经验回放缓冲区
10. 设置 $S_k = S_{k+1}$
11. loop_num = loop_num + 1
12. IF loop_num = $|M|$ THEN
13. 从经验缓冲区采样 Minibatch M
14. 计算估计 Q 值 $\hat{R}(S_k, A_k)$, 并使用损失函数更新策略函数及 Q 函数的神经网络参数 θ 和 ω
15. 基于参数 ω_b 及软更新系数 η , 采用 $\bar{\omega}_b = \eta\omega_b + (1-\eta)\bar{\omega}_b$ 更新目标 Q 网络的参数, 并设置 $M = \emptyset$, loop_num = 0
16. END IF
17. END FOR
18. episode = episode - 1
19. END WHILE

6.2 TSCA-C3RM 算法性能分析

本文从收敛性、服务性能以及在不同网络环境及业务请求配置中的适应性 3 个方面评估提出的 TSCA-C3RM 算法的优越性, 并将 TSCA-C3RM 算法与 3 个非拓扑感知算法进行比较.

(1) 随机切片资源分配资源管理算法 (Random Slice Resource Allocation-Resource Management, RSRA-RM): 该算法在提出的 TSCA-C3RM 算法框架下, 采用随机切片资源分配方式实现网络资源切片阶段的策略制定, 这表明其缺乏对 LSN 网络拓扑结构的感知, 在进行切片资源分配决策时无法关注 LEO 之间资源及业务需求的相互影响.

(2) 盲服务指导资源管理算法 (Blind Service Guidance-Resource Management, BSG-RM): 该算法在提出的 TSCA-C3RM 算法框架下, 仅关注服务资源的使用情况, 忽略用于指导服务提供策略制定的服务导向信息, 这使得其难以将局部网络拓扑特征与业务请求的 E2E 传输服务有效结合.

(3) 扩展双重 DQN 资源管理算法 (Extended Double-

算法 2 业务服务提供阶段算法

输入: 虚拟网络拓扑, 切片业务请求 Q_n , 切片可用资源
 输出: 服务提供方案

1. 随机初始化神经网络参数, 初始化训练周期 episode, Minibatch 尺寸 $|\mathcal{B}|$, $\mathcal{B} = \emptyset$, loop_num = 0
2. WHILE episode > 0
3. FOR $t = 1$ to $|T|$
4. FOR $n = 1$ to $|\text{NS}|$
5. FOR $q_n = 1$ to $|Q_t(n)|$
6. 获得初始状态 $s'_v(q_n)$ 并设置业务请求完成标识 $\text{dn}'_v(q_n) = 0$, $v = \text{VS}(q_n)$
7. WHILE $\text{dn}'_v(q_n) \neq 1$
8. 应用策略函数 $\pi_\theta(s'_v(q_n))$ 获得业务服务提供策略 $a'_v(q_n)$
9. 执行服务提供策略并获得奖励 $R(s'_v(q_n), a'_v(q_n))$ 及业务请求下一跳到达的虚拟节点 v'
10. IF $v' = \text{VD}(q_n)$ or $a'_v(q_n) = (\text{None}, 0)$ THEN
11. $\text{dn}'_v(q_n) = 1$
12. END IF
13. 获取下一状态信息 $s'_v(q_n)$
14. 存储经验信息 $(s'_v(q_n), a'_v(q_n), \text{dn}'_v(q_n), R(s'_v(q_n), a'_v(q_n)), s'_v(q_n))$ 至经验回放缓冲区
15. 设置 $s'_v(q_n) = s'_v(q_n)$
16. loop_num = loop_num + 1
17. IF loop_num = $|\mathcal{B}|$ THEN
18. 从经验缓冲区采样 Minibatch \mathcal{B}
19. 计算估计状态值 $\hat{R}(s'_v(q_n), a'_v(q_n))$, 并使用损失函数更新神经网络参数 θ 和 ω
20. 设置 $\mathcal{B} = \emptyset$, loop_num = 0
21. END IF
22. END WHILE
23. END FOR
24. END FOR
25. END FOR
26. episode = episode - 1
27. END WHILE

DQN-Resource Management, EDDQN-RM): 该算法在切片资源分配策略采用本文提出的算法进行决策的基础上, 采用 DDQN 算法框架来制定业务服务提供策略.

本文首先针对提出的 TSCA-C3RM 算法的收敛性进行分析, 如图 6 所示. 从图 6 中能够看到, TSCA-C3RM 算法与对比算法相比具有更好的综合服务性能, 且在训练过程中逐渐学习到更优的切片资源分配及业务服务提供策略. EDDQN-RM 算法的训练过程最差且无法获得有效的收敛结果, 表明其在应对具有更多不

表 1 仿真参数设置

参数描述	值	参数描述	值	参数描述	值
折扣因子 γ	0.99	训练周期 episode	300	切片阶段全连接层尺寸	256
ISL 传输速率 $CT'_{(v,u)}$	[360, 720] Mbps	切片 Actor 网络学习率	2×10^{-4}	服务 Actor 网络学习率	2×10^{-5}
星载计算资源 CP'_v	10 Gcycle/s	切片 Critic 网络学习率	5×10^{-4}	服务 Critic 网络学习率	5×10^{-5}
处理周期/bit C_{pc}	25 cycles	α 学习率	3×10^{-4}	Minibatch 尺寸 $ \mathcal{B} $	64
压缩率 C_{ratio}	0.5	Minibatch 尺寸 $ M $	32	服务阶段全连接层尺寸	64

确定性的局部网络拓扑环境时,难以有效学习 LSN 丰富的局部网络拓扑特征并做出正确的决策. 图 7 展示了不同算法训练收敛时各切片业务请求的服务完成率,结果表明 TSCA-C3RM 算法各切片的服务完成率显著优于对比算法,且三类切片的服务性能最为相似. 此外,本文明确除训练及特殊说明外,各切片业务请求的数据量分别设置为 200、0.2 及 20 Mbits.

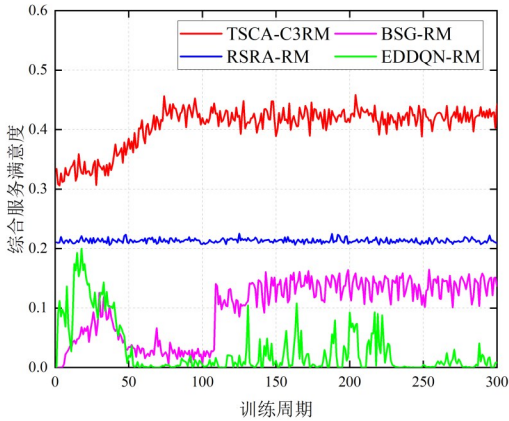


图 6 不同算法的训练收敛性

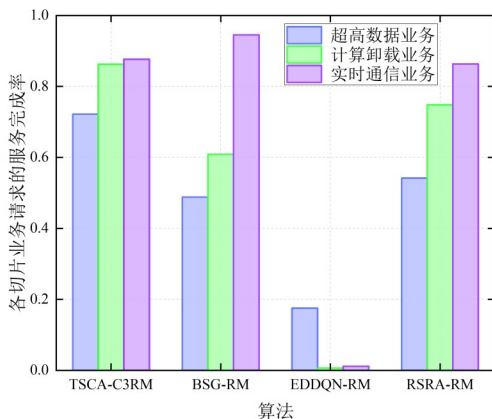


图 7 不同算法训练收敛时各切片业务请求服务完成率

进一步地,图 8 展示了不同 ISL 传输速率比例下各算法的综合服务性能,其中,实际的 ISL 传输速率由给定的比例与设置的仿真参数乘积得到,后续类似情况不再说明. 从图 8 中能够看到随着 ISL 传输速率的提升,各算法的综合服务性能均有所提升,且提出的

TSCA-C3RM 算法在各种 ISL 传输速率下均获得了最佳的综合服务性能. 在非常低的 ISL 传输速率下,提出的 TSCA-C3RM 算法仍然能够获得约 0.1 的综合服务满意度结果,显著优于 BSG-RM 算法. 此外,在 ISL 传输速率比例为 1.8 时, TSCA-C3RM 算法的综合服务满意度可达 0.64, 相比于 RSRA-RM 算法其相对服务性能提升了 28%. 需要说明的是,根据本文设置的综合服务满意度函数对三个切片的业务请求进行计算,综合服务满意度不低于 0.5 时,各切片的服务完成率超过 80%.




图 8 不同 ISL 传输速率比例下各算法的综合服务满意度

图 9 展示了不同计算资源比例下各算法的综合服务性能. 从图 9 中能够看出计算资源对各算法的综合服务性能影响显著,且 TSCA-C3RM 算法在各种计算资源配置下均获得了最佳的综合服务性能,表明其可实现根据业务需求制定更优的通算协同资源管理策略. 此外, TSCA-C3RM 算法在网络计算资源比例为 0.2 时获得了 BSG-RM 算法近 2 倍的综合服务性能,且在网络计算资源比例为 1.8 时,相比于 RSRA-RM 算法其相对服务性能提升了 25.2%.

图 10 给出了不同单星平均到达的超高数据业务的数量下各算法的综合服务性能. 结果表明,随着业务请求数量的增加, TSCA-C3RM 算法的综合服务满意度有所下降,但在单星平均到达业务请求数为 400 时,其综合服务满意度仍然超过 0.5,且与 RSRA-RM 算法相比其相对服务性能提升了 39.3%.




图9 不同计算资源比例下各算法的综合服务满意度

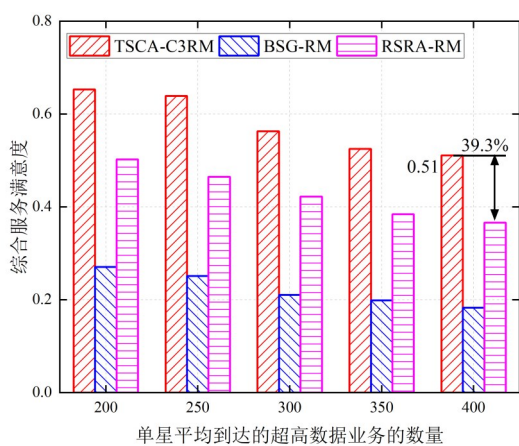


图10 不同单星平均到达的超高数据业务的数量下各算法的综合服务满意度

最后,本文在不同网络规模及业务请求配置下验证提出的TSCA-C3RM算法的灵活性和适应性.图11给出了不同网络规模下各切片业务请求的服务完成率以及整网的综合服务满意度,其中,每个卫星网络的参数配置如表2所示.从图11中能够发现网络配置对业务请求的E2E服务具有显著影响,例如,在348颗卫星的网络配置下,由于网络拓扑连通性较差,业务请求的E2E传输需要途经更多中间节点才能到达目的地,这使得服务完成需要花费更多的时间和资源,进而导致服务性能不佳.即便如此,TSCA-C3RM算法仍然实现了不低于43%的服务完成率,且各切片业务请求的服务完成性能相似.此外,TSCA-C3RM算法在网络拓扑连通性较好的情况下,可实现高达0.89的综合服务满意度且服务完成率超过96%.

鉴于LEO与地面的相对高速运动,业务请求通常仅需几跳即可到达目的节点^[36],因此,本文关注E2E路径长度从1~6变化时不同ISL传输速率比例下的综合服务满意度,如图12所示.结果表明,由于超高数据业务对通信资源需求更高,在ISL传输速率比例为0.2和

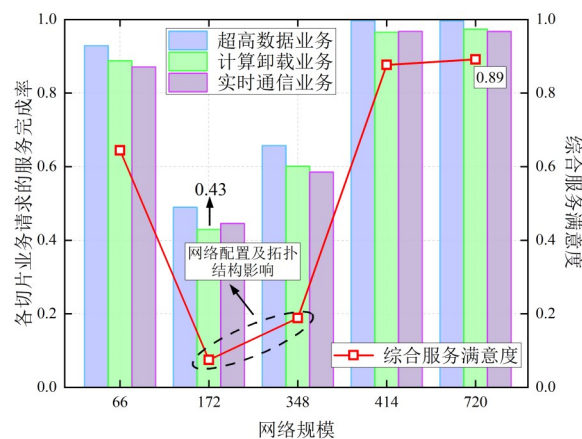


图11 不同网络规模下的切片服务完成率与综合服务满意度

表2 卫星网络参数设置

网络规模	172	348	414	720
星座构成	4 × 43	6 × 58	18 × 23	36 × 20
轨道高度/km	560	560	1 345	570
轨道倾角/(°)	97.6	97.6	85.0	70.0

0.4时难以保障其高性能服务,进而无法获得较高的综合服务满意度.此外,随着通信资源的增加,TSCA-C3RM算法可确保E2E路径长度不超过4时,获得高于0.5的综合服务满意度.

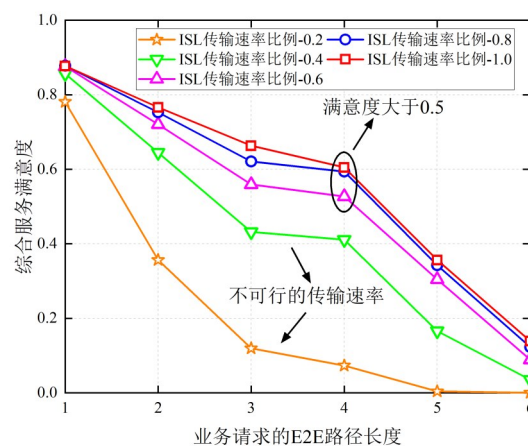


图12 不同E2E路径长度与ISL传输速率比例下的综合服务满意度

图13展示了各切片业务请求数据量方差对综合服务性能的影响,其中,实际业务请求的数据量分布的方差由给定比例与分布的均值(3类业务数据量的均值分别为200、0.2及20 Mbits)乘积得到.结果表明,TSCA-C3RM算法能够有效应对各类业务请求数据量的小范围波动,且在方差占比1.0的情况下仍然能够保障实时通信业务服务性能.此外,随着业务请求数据量的方差越来越大,超高数据业务对通信资源的需求过高导致服务性能有所下降,但在方差占比1.0的情况下,其服务完成率仍超过70%.

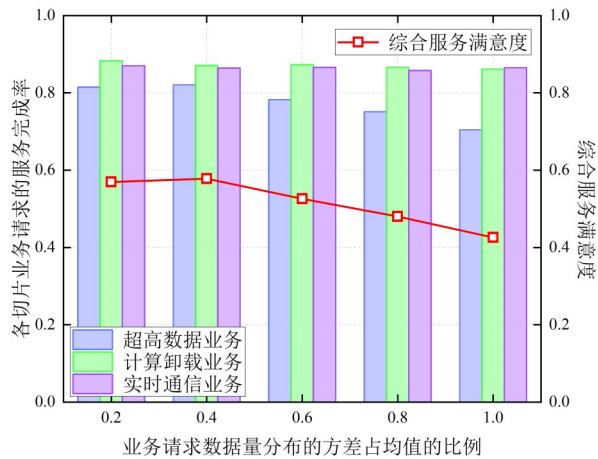


图 13 不同业务请求数据量分布方差占均值比例下的综合服务满意度

7 结论

本文研究了联合优化切片可用通算资源和服务提供策略的 C3RM-DS 问题,以实现最大化多样化业务的综合服务满意度.建立的虚拟节点及链路映射模型,有效避免了卫星与地面相对高速运动对业务请求 E2E 传输的影响;设计的 TSCA-C3RM 算法框架应用建立的融合 LSN 拓扑结构的网络状态信息提取模型,实时捕捉了星间结构化通算资源与业务需求特征的动态演化关系,并通过设计参数共享的切片资源分配决策机制,为 LSN 提供了自适应网络环境的智能切片资源管理;此外,区域资源管理模式为可变 E2E 传输路径提供了一致的区域决策空间,且通过引入服务导向信息,为星上自主 E2E 服务决策提供局部拓扑感知和目标定位能力,实现动态 LSN 通算资源的按需高效协同并保障时延约束下多样化业务的 E2E 服务性能.仿真结果从收敛性、服务性能及适应性 3 个方面验证了提出的 TSCA-C3RM 算法的优越性,且在不同通算资源、业务请求数量下分别获得了高于对比算法 28%、25.2% 及 39.3% 的服务完成性能.

参考文献

- [1] WANG C X, YOU X H, GAO X Q, et al. On the road to 6G: Visions, requirements, key technologies and testbeds[J]. IEEE Communications Surveys & Tutorials, 2023, 25(2): 905-974.
- [2] DING F, BAO C X, ZHOU D, et al. Toward autonomous resource management architecture for 6G satellite-terrestrial integrated networks[J]. IEEE Network, 2024, 38(2): 113-121.
- [3] 缪德山, 邓凌越, 孙建成, 等. 6G 星地融合无线网络及关键技术[J]. 中兴通讯技术, 2024, 30(4): 42-49.
- [4] SAAD W, BENNIS M, CHEN M Z. A vision of 6G wireless systems: Applications, trends, technologies, and open research problems[J]. IEEE Network, 2020, 34(3): 134-142.
- [5] QU Y B, ZHANG T T, FENG Y, et al. Computation offloading and resource allocation for E2E tasks in satellite edge computing networks[J]. Space: Science & Technology, 2024, 4: 144.
- [6] SHEN X, LIAO W R, YIN Q. A novel wireless resource management for the 6G-enabled high-density Internet of Things[J]. IEEE Wireless Communications, 2022, 29(1): 32-39.
- [7] AL HOMSSI B, DAKIC K, WANG K, et al. Artificial intelligence techniques for next-generation massive satellite networks[J]. IEEE Communications Magazine, 2024, 62(4): 66-72.
- [8] ZHOU D, SHENG M, LI J D, et al. Aerospace integrated networks innovation for empowering 6G: A survey and future challenges[J]. IEEE Communications Surveys & Tutorials, 2023, 25(2): 975-1019.
- [9] CIANCA E, ROSSI T, RUGGIERI M, et al. Space sustainability-by-design: Challenges and key-enablers[J]. IEEE Aerospace and Electronic Systems Magazine, 2025, 40(4): 4-17.
- [10] WEI F S, FENG G, SUN Y, et al. Network slice reconfiguration by exploiting deep reinforcement learning with large action space[J]. IEEE Transactions on Network and Service Management, 2020, 17(4): 2197-2211.
- [11] RAFIQUE W, RANI BARAI J, FAPOJUWO A O, et al. A survey on beyond 5G network slicing for smart cities applications[J]. IEEE Communications Surveys & Tutorials, 2025, 27(1): 595-628.
- [12] EBRAHIMI S, BOUALI F, HAAS O C L. Resource management from single-domain 5G to end-to-end 6G network slicing: A survey[J]. IEEE Communications Surveys & Tutorials, 2024, 26(4): 2836-2866.
- [13] CHEN Q, GUO Z, MENG W X, et al. A survey on resource management in joint communication and computing-embedded SAGIN[J]. IEEE Communications Surveys & Tutorials, 2025, 27(3): 1911-1954.
- [14] ALHASHIMI H F, HINDIA M N, DIMYATI K, et al. A survey on resource management for 6G heterogeneous net-

- works: Current research, future trends, and challenges[J]. *Electronics*, 2023, 12(3): 647.
- [15] LIANG H, YANG Z Q, ZHANG G B, et al. Resource allocation for space-air-ground integrated networks: A comprehensive review[J]. *Journal of Communications and Information Networks*, 2024, 9(1): 1-23.
- [16] ZHANG S H, CUI G F, LONG Y T, et al. Joint computing and communication resource allocation for satellite communication networks with edge computing[J]. *China Communications*, 2021, 18(7): 236-252.
- [17] OUYANG Q L, YE N, GAO J, et al. Joint in-orbit computation and communication for minimizing download time from LEO satellites[J]. *IEEE Transactions on Mobile Computing*, 2024, 23(5): 3950-3963.
- [18] VALENTE F, ERAMO V, LAVACCA F G. Optimal bandwidth and computing resource allocation in low earth orbit satellite constellation for earth observation applications[J]. *Computer Networks*, 2023, 232: 109849.
- [19] SUI X F, JIANG Z Q, LYU Y F, et al. Integrating convex optimization and deep learning for downlink resource allocation in LEO satellites networks[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2024, 10(3): 1104-1118.
- [20] ZHANG H Y, LIU R K, KAUSHIK A, et al. Satellite edge computing with collaborative computation offloading: An intelligent deep deterministic policy gradient approach[J]. *IEEE Internet of Things Journal*, 2023, 10(10): 9092-9107.
- [21] WANG D, BAI Y L, HUANG G, et al. Cache-aided MEC for IoT: Resource allocation using deep graph reinforcement learning[J]. *IEEE Internet of Things Journal*, 2023, 10(13): 11486-11496.
- [22] ZHANG H Y, ZHAO H B, LIU R K, et al. Dynamic user association and computation offloading in satellite edge computing networks via deep reinforcement learning[J]. *IEEE Transactions on Green Communications and Networking*, 2024, 8(4): 1888-1901.
- [23] WU H Q, CHEN J Y, ZHOU C H, et al. Learning-based joint resource slicing and scheduling in space-terrestrial integrated vehicular networks[J]. *Journal of Communications and Information Networks*, 2021, 6(3): 208-223.
- [24] LUO J, XIAO R Y, SUN P, et al. VLEO satellite radio access network slicing: A hierarchical deep reinforcement learning approach[C]//2023 IEEE Intl Conf on Parallel & Distributed Processing with Applications, Big Data & Cloud Computing, Sustainable Computing & Communications, Social Computing & Networking. Piscataway: IEEE, 2024: 229-236.
- [25] LIU Y R, MA T, TANG Z X, et al. Ultra-dense LEO satellite access network slicing: A deep reinforcement learning approach[C]//GLOBECOM 2023 - 2023 IEEE Global Communications Conference. Piscataway: IEEE, 2024: 5043-5048.
- [26] LIU Y R, MA T, QIN X H, et al. Reconfigurable RAN slicing for ultra-dense LEO satellite networks via DRL[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2025, 11(1): 566-580.
- [27] DONG T J, ZHUANG Z R, QI Q, et al. Intelligent joint network slicing and routing via GCN-powered multi-task deep reinforcement learning[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2022, 8(2): 1269-1286.
- [28] KAK A, AKYILDIZ I F. Towards automatic network slicing for the Internet of space things[J]. *IEEE Transactions on Network and Service Management*, 2022, 19(1): 392-412.
- [29] ZHU Q Y, TAO H C, CAO Y H, et al. Laser inter-satellite link visibility and topology optimization for mega constellation[J]. *Electronics*, 2022, 11(14): 2232.
- [30] CHEN Q, GIAMBENE G, YANG L, et al. Analysis of inter-satellite link paths for LEO mega-constellation networks[J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(3): 2743-2755.
- [31] SONG C L, HE S B, CUI Y H. Topological design of low orbit mega-constellations based on inter satellite visibility[C]//Proceedings of the 2024 3rd International Conference on Cryptography, Network Security and Communication Technology. New York: ACM, 2024: 560-564.
- [32] WANG G C, ZHOU S, ZHANG S, et al. SFC-based service provisioning for reconfigurable space-air-ground integrated networks[J]. *IEEE Journal on Selected Areas in Communications*, 2020, 38(7): 1478-1489.
- [33] LASO FERNÁNDEZ J L. Study, modelling and design of intersatellite links (ISL) in millimeter-wave band/estudio, modelado y diseño de enlaces intersatelitales (ISL) en bandas de milimétricas[EB/OL]. [2025-10-10]. https://oa.upm.es/62930/1/PFC_JOSE_LUIS_LASO_FERNANDEZ.pdf.
- [34] HAARNOJA T, ZHOU A, ABBEEL P, et al. Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor[EB/OL]. (2018-08-08)[2025-10-10]. <https://arXiv.org/abs/1801.01290>.

[35] BAO C X, ZHOU D, SHENG M, et al. Regional resource management for service provisioning in LEO satellite networks: A topology feature-based DRL approach[C]//2025 IEEE Global Communications Conference (GLOBECOM). Piscataway: IEEE, 2025: 1-6.

[36] BHATTACHERJEE D, SINGLA A. Network topology design at 27 000 km/hour[C]//Proceedings of the 15th International Conference on Emerging Networking Experiments and Technologies. New York: ACM, 2019: 341-354.

作者简介



鲍晨曦 女,1998年11月出生于黑龙江省佳木斯市。现为西安电子科技大学通信工程学院博士研究生。主要研究方向为卫星网络资源表征、大规模卫星网络资源管控技术。

E-mail: cxbao@stu.xidian.edu.cn



姬思敬 男,1993年7月出生于河南省郑州市。现为西安电子科技大学副研究员。主要研究方向为大规模卫星星座组网理论、星地通算协同技术。

E-mail: jisijing@xidian.edu.cn



盛敏 女,1975年8月出生于湖南省长沙市。现为西安电子科技大学教授、博士生导师、空天地一体化综合业务网全国重点实验室主任。主要研究方向为空地融合网络、智能无线网络和移动自组织网。

E-mail: msheng@mail.xidian.edu.cn



史琰 男,1975年1月出生于河南省洛阳市。现为西安电子科技大学教授、博士生导师。主要研究方向为空间信息网络、高性能通信与计算协同。

E-mail: yshi@xidian.edu.cn



周笛 女,1991年3月出生于陕西省西安市。现为西安电子科技大学教授、博士生导师。主要研究方向为空地融合网络、空间信息网络中的动态资源分配、任务规划和性能评估。中国电子学会会员编号:E190023060S。

E-mail: zhoudi@xidian.edu.cn



李建东 男,1962年10月出生于江苏省盐城市。现为西安电子科技大学教授、博士生导师。中国电子学会会士。主要研究方向为空间信息网络、智能无线网络、大规模自组织网络。

中国电子学会会员编号:E190012560F。

E-mail: jdli@mail.xidian.edu.cn