中国科学 : 信息科学 2026 年 第 56 卷 第 11 期: 2825–2842
SCIENTIA SINICA Informationis
Agentic AI 赋能的 6G 融合通信专题 • 评述

面向卫星边缘人工智能的智能体架构与关键技术

石远明[1], 朱敬阳[1*], 周勇[1], 王廷[2], 姜春晓[3]

1. 上海科技大学信息科学与技术学院, 上海 201210
2. 华东师范大学软件工程学院, 上海 200062
3. 清华大学北京信息科学与技术国家研究中心, 北京 100084
* 通信作者. E-mail: zhujy2@shanghaitech.edu.cn

收稿日期: 2026–04–29; 修回日期: 2026–08–09; 接受日期: 2026–09–22; 网络出版日期: 2026–11–09

国家自然科学基金 (批准号: 62522117, 62271318, 62432007, 62325108, 62341131) 资助项目

摘要 随着天基算力网络的发展, 以卫星为端侧节点的卫星边缘人工智能正经历从 “天感地算” 至 “天感天算” 范式的深刻变革. 然而, 卫星网络中时变的拓扑结构, 受限的能源供给, 异构的算力分布, 以及受太空粒子辐射影响的复杂计算环境, 使得传统基于静态场景的计算架构难以满足在轨训练与推理的高效协同需求. 为突破以上瓶颈, 本文提出一种智能体驱动的分层卫星边缘协同计算架构. 该架构在天基算力网络提供的通信与计算资源之上引入智能体机制, 使卫星节点能够根据任务需求和环境状态进行感知、规划、执行与反馈调整. 针对分布式在轨模型训练问题, 本文设计了分层智能体驱动的卫星联邦学习机制, 并利用基于时间窗与聚合感知的有向最小生成树路由算法缓解星地协同分布式模型训练的通信瓶颈. 针对星间协同推理问题, 本文提出了智能体卫星边缘推理架构, 结合网络功能虚拟化与微服务概念, 构建了基于服务功能链的星间协同推理机制, 并利用多智能体强化学习实现了复杂推理任务的实时路由与动态编排. 所提架构将静态处理流水线方法扩展为可根据任务状态进行调整的闭环任务流, 为动态卫星网络中的异构资源协调和复杂任务协同提供了一种框架性方案.

关键词 天基算力网络, 智能体人工智能, 卫星联邦学习, 卫星边缘推理

1 引言

随着全球低地球轨道 (low-earth-orbit, LEO) 卫星星座的规模化部署和星间激光通信技术的持续演进, 卫星网络正由传统的基于中地球轨道 (medium-earth-orbit, MEO) 和地球同步轨道 (geostationary-earth-orbit, GEO) 主导的 “通信 – 导航 – 遥感” 分离式管道逐步向集 “通导遥” 能力于一体, 高速互连的空间信息基础设施转型. 作为这一空间信息基础设施转型的核心基石, 运行于 300~2000 km 近地轨道的 LEO 卫星星座近年来迎来了爆发式增长. 在通信方面, 以星链 (Starlink) 为代表的超大规模 LEO 星座通过密集的星地与星间链路, 实现了全球范围的低时延, 宽带数据传输, 极大拓宽了天基信息传输的管道 [1]; 在遥感方面, LEO 卫星广泛搭载了光学相机、合成孔径雷达、红外探测器等多样化传感载荷, 能够提供极高的对地观测空间分辨率, 更能依托星座群的大规模部署获取海量的多模态、多视角与高频次观测数据 [2]. 这种通信与感知能力的深度融合, 使得各类 LEO 卫

引用格式: 石远明, 朱敬阳, 周勇, 等. 面向卫星边缘人工智能的智能体架构与关键技术. 中国科学: 信息科学, 2026, 56: 2825–2842, doi: 10.1360/SSI-2026-0188
Shi Y M, Zhu J Y, Zhou Y, et al. Satellite edge artificial intelligence with agents: architectures and technologies. Sci Sin Inform, 2026, 56: 2825–2842, doi: 10.1360/SSI-2026-0188

© 2026《中国科学》杂志社

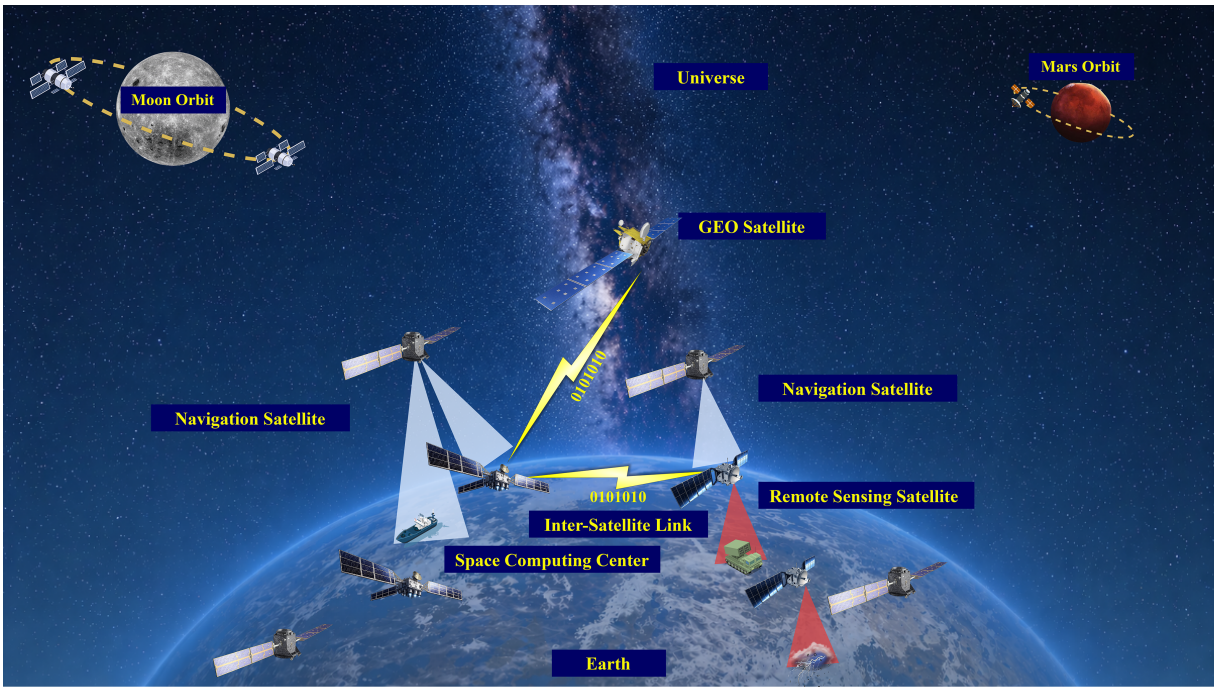

图 1　(网络版彩图) 天基算力网络示意图.

Figure 1　(Color online) Space computing networks.

星星座跃升为天基系统中最核心的多模态数据源, 从而全面赋能土地覆盖分类、云层识别、降水估算、海上溢油检测和森林火灾监测等诸多典型下游任务, 为面向各类任务的人工智能 (artificial intelligence, AI) 模型提供了坚实的数据支撑 [3]. 传统的遥感数据处理模式通常需要将其传输至地面信关站 (gateway station, GS), 然后在地面云计算中心进一步处理, 即 “天感地算” [4]. 然而, 随着数据量的急剧增加以及卫星与地面之间稀缺的频谱资源限制, 这种方法带来了难以承受且日益增长的通信成本.

得益于卫星在轨计算硬件的快速发展, 利用卫星边缘的计算能力进行在轨数据预处理乃至机器学习模型训练和推理正在成为一项重要趋势, 即 “天感天算” [5,6]. 如图 1 所示, 天基算力网络依托先进的边缘 AI 技术、成熟的卫星通信体系以及新兴的在轨计算载荷, 能够整合包括 LEO, MEO 和 GEO 卫星在内的多层卫星通信与计算资源, 实现在轨算力的统一编排与协同调度 [7,8]. 在天基算力网络提供的通信与计算资源之上, 卫星边缘 AI 面向遥感数据开展在轨模型训练与推理 [9,10]. 通过减少原始数据回传并将部分计算过程部署至卫星节点, 卫星边缘 AI 可为自然灾害险情的实时监测、快速安全的情报分析等任务提供实时的近源处理能力 [11]. 鉴于其巨大的应用潜力与战略价值, 国内外顶尖科技企业与政府科研机构已积极展开了卫星边缘 AI 的前瞻性布局与在轨技术验证. 例如, 2025 年 11 月, 美国初创公司 StarCloud 与英伟达 (NVIDIA) 合作, 将一颗搭载 NVIDIA H100 图形处理器 (graphics processing unit, GPU) 的 LEO 卫星送入轨道, 并完成了包括 nanoGPT 在内的大语言模型 (large language model, LLM) 的在轨训练与推理验证 [12]. Google 紧随其后发布轨道数据中心计划 Project Suncatcher, 通过地面辐射模拟测试, 拟将搭载自研张量处理单元 (tensor processing unit, TPU) 加速芯片部署至 LEO 卫星分布式集群, 由大量小型、模块化的 LEO 卫星组成紧密编队进行协同计算 [13]. 2025 年 11 月, 北京市科学技术委员会也宣布拟在 700~800 km 晨昏轨道建设运营超过吉瓦 (gigawatt, GW) 功率的集中式大型数据中心系统, 以实现将大规模 AI 算力搬上太空 [14]. 2026 年 1 月, 中国国星宇航成功将 Qwen3 大模型部署至 “星算” 计划 01 组太空计算中心, 并完成端到端在轨 AI 推理验证 [15].

然而, 当前卫星边缘 AI 仍面临如下几点挑战. 首先是卫星边缘 AI 计算任务方面, 不同任务在算力、时间尺度和资源消耗方面有着显著差异性和复杂性. 例如, 训练任务通常需要高达数十至数百个 TOPS (每秒万亿次运算) 的算力来处理大规模数据集, 而推理任务则通常只需数十个 TOPS 的算力执行模型计算. 当计算资源有限

而计算任务规模较大时, 可以把计算任务拆分成多个串行运行的小计算任务. 反之, 当计算任务运行时间长, 可以将任务拆分成短任务且并行运行在不同计算资源上, 减少总体计算时间. 具体而言, 在轨 AI 模型训练任务的分解方式存在数据并行、张量并行和流水线并行等方式; 而在轨 AI 模型推理任务的任务分解方式一般可以根据具体任务拆分为推理流水线进行执行. 进一步地, 不同于传统数据中心网络中连续且低利用率的业务模式, 卫星边缘 AI 计算任务呈现突发性强、高峰值利用率和不确定性高的特性, 传统资源优化和负载均衡方法将导致严重的通算资源争用、利用效率低和网络拥堵等问题. 其次, 当前卫星网络通信和计算资源编排面临以下两点挑战. (1) 高度动态网络拓扑: 由于 LEO 卫星的高速轨道运动特性, LEO 卫星星座网络拓扑时变, 同时其与地面 GS、MEO 卫星、GEO 卫星的通信链路均在不断变化. (2) 异构卫星算力分布: 各类卫星所搭载的算力大小分布不均 (如 10~744 TOPS 不等), 且不同制造厂商和不同算力平台类型 (中央处理器 (central processing unit, CPU)、GPU、神经网络处理器 (neural processing unit, NPU)、TPU、现场可编程门阵列 (field-programmable gate array, FPGA) 等) 使得天基算力网络内算力分布呈现一定的复杂性. 由此, 卫星网络拓扑结构复杂多变和计算资源异构分布, 对计算任务的分解拼装和通算资源高效利用提出了新挑战. 在此背景下, 如何建立算力需求不同的卫星边缘 AI 计算任务与动态卫星网络通信和计算资源的合理匹配机制, 在星上资源受限约束下, 通过计算任务的分解与重构实现最终的输出结果仍等价于原始任务, 是提升卫星边缘 AI 服务能力可拓展性的关键.

围绕任务与资源的协同设计, 已有研究从分布式信号处理角度讨论了边缘学习与通信、计算及无线感知的融合 [16], 并从智能反射通信角度探索了通信、感知与安全的联合设计 [17]. 借鉴上述思路, 本文进一步面向轨道与星载资源约束, 关注如何通过分层智能体, 将链路状态、观测质量与计算负载的变化转化为训练节点选择、模型聚合及推理服务链调整等任务级决策. 智能体 AI (agentic AI) 标志着以 LLM 为代表的基础模型技术从 “感知与生成” 向 “决策与执行” 的范式跃迁. 从体系结构上看, LLM 主要提供语义理解、推理与规划等通用认知能力, 但其本身缺乏与外部环境交互和执行任务的能力; 而智能体 (agent) 则是在 LLM 等基础模型之上, 通过引入状态管理、工具调用与行动执行机制构建的任务执行主体, 能够在给定目标约束下完成从感知到行动的闭环过程. 在此基础上, 智能体 AI 进一步从单一智能体扩展为由多个智能体协同组成的智能系统, 通过环境感知、任务分解、动态决策与持续反馈, 实现复杂任务的自主完成与全局优化 [18]. 与传统依赖预定义规则或静态策略的 AI 系统不同, 智能体 AI 强调在开放环境中的自适应能力, 能够根据实时上下文信息动态调整任务执行路径, 并通过多智能体之间的协作实现跨空间与跨时间尺度的资源协调与任务编排 [19]. 这一特性使其特别适用于卫星边缘 AI 这类具有高动态性、不确定性和强耦合特征的复杂系统. 因此, 将智能体 AI 引入卫星边缘 AI 系统, 可以充分利用其在环境感知、动态任务分解、策略生成以及多智能体协同决策方面的优势, 构建面向时变网络环境的自适应任务 – 资源匹配机制. 具体而言, 智能体 AI 能够根据实时网络状态与任务需求, 在线调整任务划分方式与执行策略, 并通过多智能体协同实现卫星边缘 AI 计算任务在空间上的分布式部署与在时间上的有序执行, 从机制上为资源受限条件下的通算资源协调与复杂任务组织提供更灵活的实现方式. 这种机制是否能够进一步改善资源利用率和任务性能, 仍取决于具体任务规模、网络状态及智能体运行开销. 在此框架下, 卫星边缘 AI 智能体通常具备以下核心能力 [20]: (1) 主动感知, 即持续获取并建模卫星动态网络与任务状态; (2) 自主决策, 即基于上下文与目标约束进行策略生成与调整; (3) 工具调用, 即按需调度在轨通信、计算与感知资源完成任务执行; (4) 协同交互, 即通过分布在卫星网络中的多智能体进行信息交换与任务协商, 为跨节点协同优化与故障条件下的任务调整提供支持. 如表 1 所示, 智能体驱动架构与传统分层卫星边缘 AI 架构的本质区别在于任务流程的生成主体以及任务流程能否根据执行反馈进行在线更新. 传统方法通常面向预先定义的任务图, 由规则、启发式算法或优化器在固定目标和动作集合内完成资源分配; 当任务目标、链路状态或观测质量超出预设情形时, 往往需要人工修改规则或重新部署任务流程. 相比之下, 本文所述智能体驱动架构在资源调度层之上进一步引入任务语义与闭环控制机制. 智能体能够将高层任务目标转化为带有数据依赖、资源约束和终止条件的状态化任务图, 持续接收链路状态、计算负载、能源水平和中间处理结果等反馈, 并据此动态调整任务分解方式与执行路径. 这种分工方式使系统既能够利用智能体处理任务语义与环境不确定性, 又能够保留传统优化方法在可行性约束和底层执行方面的优势.

基于上述分析, 本文围绕复杂卫星边缘 AI 任务与动态网络资源匹配问题, 构建了一种面向时变环境的智能

表 1　传统分层卫星边缘 AI 架构与本文智能体驱动架构的比较.

Table 1　Comparison between conventional hierarchical satellite edge AI architectures and the proposed agentic architecture.

Comparison	Conventional satellite edge AI architectures	Proposed agentic architecture	Key benefits and trade-offs
Task planning	The task generator invokes fixed task templates based on predefined service types, with the task graph determined before execution	The task generator interprets high-level mission objectives and context to construct a stateful task graph with dependencies, resource constraints, and termination conditions, allowing task nodes to be added or removed at runtime	Enables task workflows to adapt to objectives and observation results
Adaptive scheduling	Rules, heuristics, or optimizers allocate resources within fixed sets of objectives and actions	Integrates task semantics, ephemeris data, and link, computing, and energy states; an outer-loop agent selects scheduling objectives and tools, then invokes inner-loop optimization algorithms to generate executable plans	Matches task requirements with time-varying communication and computing resources across multiple timescales
Dynamic reconfiguration	Primarily relies on predefined backup paths, timeout-based retransmissions, or local rerouting, with limited ability to modify task logic	Uses execution feedback to reassign tasks to alternative nodes, adjust inter-satellite transmission paths, or insert new subtasks such as re-observation and quality assessment at runtime	Addresses both link/node failures and inadequate observation quality
Cross-layer coordination	GEO, MEO, and LEO layers exchange states or model parameters through fixed control interfaces at predefined intervals	GEO, MEO, and LEO agents handle long-term planning, regional coordination, and execution near data sources, respectively, exchanging task intents, constraints, state summaries, and execution feedback	Balances alignment with global objectives and rapid local responses
Closed-loop decision-making	Mainly relies on a one-shot mapping from resource states to scheduling actions, with execution outcomes rarely driving changes to task structure	Forms a “sense-plan-execute-feedback” loop, in which the outer loop updates the task graph and the inner loop performs constrained optimization and execution	Extends static workflow execution to closed-loop control with continual refinement
Communication overhead	Mainly exchanges model parameters, task instructions, and periodic full-state updates	Requires state summaries, task intents, and feedback in addition to model and service data; event-triggered communication and hierarchical summarization limit additional control traffic	Enables finer-grained coordinated decision-making at the cost of additional control overhead
Inference latency	Fixed pipelines incur low control overhead but may experience long waits under failures or load changes	Introduces agent reasoning and validation latency, while execution near data sources, precomputation, and local re-orchestration can shorten recovery paths	Actual benefits depend on task scale and link conditions
Robustness	Relies on predefined backups, retransmissions, and local fault tolerance	Combines hard-constraint validation, execution feedback, node replacement, path reconfiguration, and safe fallback mechanisms	Handles a broader range of anomalies, but still requires system-level validation
Resource utilization	Updates resource mappings according to predefined policies, which may lag behind topology and load changes	Incorporates computing capacity, storage, energy, thermal states, and payload capabilities into online orchestration	May reduce local congestion and resource idling

体驱动解决方案, 并从训练与推理两个关键环节系统性地展开设计与分析. 本文的章节安排如下: 第 2 节首先对卫星联邦学习进行概念整合, 进而详细阐述所提出的智能体卫星联邦学习的分层架构, 并将现有星间链路调度

方法拓展至智能体驱动架构; 第 3 节首先对卫星边缘推理进行概念整合, 进而提出基于智能体的分层卫星边缘推理架构, 并深入探讨现有服务功能链路由方法在智能体驱动星间协同推理与动态任务编排的拓展; 第 4 节对天基智能的未来发展方向进行展望, 涵盖在轨类脑存算一体计算架构, 基于智能体工作流的遥感时序数据分析, 卫星边缘 AI 资源优化问题的自动化建模、求解与数学证明, 以及未来仿真验证与数字孪生半实物平台搭建; 最后, 第 5 节总结全文.

2　智能体卫星联邦学习

针对星地链路零星连接和可见窗口短的问题, 本节先介绍分层联邦学习架构, 而后针对分层联邦学习存在的网络拓扑高动态和静态模型训练参数设置难以匹配的难题, 详细介绍分层智能体卫星联邦学习的系统架构, 包括各层级智能体的功能划分与协作运行机制, 以及面向该架构的星间链路 (inter-satellite link, ISL) 高效调度方法.

2.1　卫星联邦学习

面向在轨 AI 模型训练的需求, 传统基于 LEO 卫星的卫星联邦学习方法高度依赖地面信关站和参数服务器的集中式协调 [21, 22]. 然而, 高速在轨运行的 LEO 卫星与地面之间的通信受限于零星的星地链路连接和极短的可见时间窗, 例如 LEO 卫星单次过顶有效通信时长仅为 5∼10 min, 仅占整个轨道周期的 2%∼3%. 同时, 受限于有限的星地链路带宽, 例如常用的 S 频段遥测链路在复杂空间环境下其实际有效吞吐量通常仅为数兆比特每秒 (megabits per second, Mbps), 难以支撑大规模原始遥感数据或数吉字节 (gigabyte, GB) 级模型参数的频繁回传, 进而导致了严重的通信瓶颈. 为降低对星地链路的依赖, 文献 [23] 提出了一种基于星间和星地协同传输的卫星联邦学习方法, 利用 ISL 的高速传输特性进行轨道内模型聚合, 显著提升卫星联邦学习收敛速度. 为了进一步摆脱对星地之间通信链路的深度依赖, 文献 [24∼29] 探索了去中心化卫星联邦学习范式, 通过完全在轨的星间通信与分布式计算完成模型训练, 无须与地面实时交互. 然而, 受限于 LEO 星座拓扑的高度动态性与 ISL 的瞬时连通特性, 该架构在保障模型收敛的一致性、控制大规模星座下的模型同步等方面仍面临严峻挑战. 在此基础之上, 文献 [30] 提出了完全基于在轨计算的分层卫星联邦学习架构, 旨在通过构建 LEO, MEO 与 GEO 三层协作网络, 利用轨道内、轨道间的 ISL 互联实现模型参数的在轨本地模型训练与分层聚合. 分层卫星联邦学习主要由以下几个步骤组成.

• **全局模型初始化与下发:** GEO 卫星位于 35786 km 的地球同步轨道, 具有准静止特性和超大覆盖范围, 适合承担网络控制, 全局调度与集中式算力管理等功能. 为此, 在分层卫星联邦学习架构中, GEO 卫星通常作为全局参数服务器, 生成初始的全局模型, 并将其通过 ISL 下发至覆盖范围内的 MEO 卫星. 由于 MEO 轨道高度较高 (典型高度约 8000∼20000 km), 且其与 LEO 卫星之间的持续时间相对较长 (典型可用时长可达 30∼90 min), 在任一时间片内, 每颗 MEO 卫星能够与覆盖范围内的多颗 LEO 卫星建立 ISL. 因此, MEO 卫星再将该模型多播转发给其当前时刻所管理的底层 LEO 卫星簇.

• **LEO 本地模型训练:** 各 LEO 卫星利用其搭载的传感器实时获取的本地观测数据或通过接收其他遥感卫星的观测数据, 利用本地算力执行前向传播与反向传播计算. 经过多轮本地迭代后, 各 LEO 节点得到更新后的本地模型参数或梯度.

• **MEO 区域模型聚合:** LEO 卫星将更新后的模型参数或梯度通过 ISL 上传至当前时刻关联的 MEO 卫星. MEO 卫星作为中间层聚合节点, 收集其管理域内所有 LEO 节点的模型更新, 并执行区域级的加权平均聚合, 生成区域级模型. MEO 卫星将区域级模型回传给 LEO 卫星, 进行下一轮的本地模型训练.

• **GEO 全局模型聚合:** 在下层更新循环往复一定轮数后, 各个 MEO 卫星将生成的最新区域级模型进一步上传至 GEO 卫星. GEO 卫星对所有区域模型进行最终的全局聚合, 产出新一轮的全局模型, 并开启下一轮次的通信迭代, 直至模型达到预设的收敛精度.

传统的卫星联邦学习通常局限于轻量级小模型的训练, 而当前各类复杂空间任务对大模型的需求日益增加.

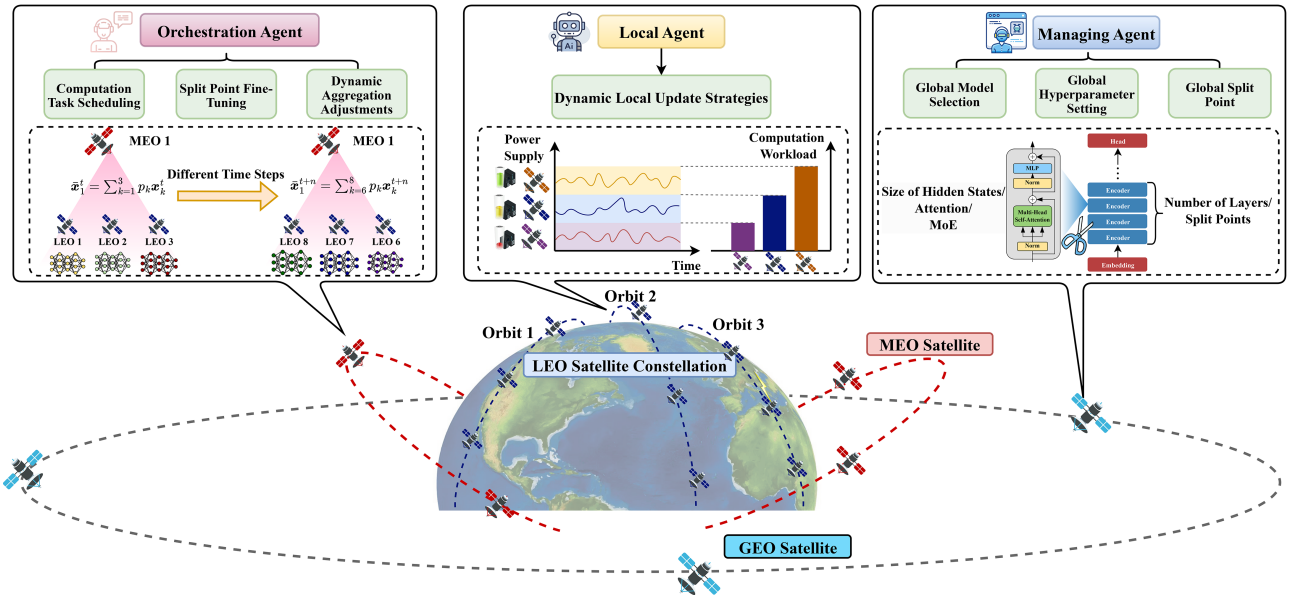

图 2　(网络版彩图) 分层智能体卫星联邦学习架构.

Figure 2　(Color online) Hierarchical agentic satellite federated learning architecture.

由于单颗卫星的算力与存储空间存在固有的物理瓶颈, 分割学习 [31, 32] (split learning) 作为一项针对模型训练的任务分解技术可以被引入该分层架构中, 通过将大模型按层分割并部署于不同轨道的卫星节点进行协同训练 [33], 以有效缓解单星的计算压力. 然而, 在拓扑高度动态和资源极度受限的复杂空间环境中, 现有分层架构依然将卫星视为被动的计算与通信节点, 面临如下挑战: (1) 在网络层面, 卫星网络拓扑具有极高的动态性, 导致参与训练的 LEO 卫星随时上线与离线, 且网络链路状态、卫星算力及能源水平不断波动; (2) 在算法层面, 联邦学习的超参数设定、模型架构选择以及分割学习的拆分节点选择等核心决策目前仍高度依赖人工经验设计 [34~36]; (3) 现有的模型聚合策略、本地更新方法及任务分解方案大多采用静态设计, 无法与动态网络环境匹配. 这种基于固定规则驱动的调度模式难以适应大模型拆分训练过程中 ISL 的频繁通断、卫星计算资源的异构分布以及节点能源状态的持续变化, 容易引发局部计算瓶颈和通信资源浪费. 为应对这一挑战, 本文提出了一种分层智能体卫星联邦学习架构, 将基于 LLM 的智能体作为卫星的自主决策大脑, 使各网络单元能够根据实时环境进行感知与自适应调优. 与针对动态网络环境各类情况分别设置固定规则相比, 该架构使用统一的任务目标与约束描述驱动跨层决策, 并利用训练日志和模型质量反馈持续修正后续训练策略, 从而将传统的静态参数配置扩展为跨层、跨时间尺度的闭环自适应过程.

2.2　分层智能体卫星联邦学习架构

考虑到 GEO, MEO 与 LEO 卫星轨道运行和算力的差异化分布特性, 本文提出了一种量身定制的智能体部署编排方案, 构建了 GEO, MEO 与 LEO 三层异构智能体协作架构, 如图 2 所示. 针对前文所述的网络动态性、经验依赖性以及静态调度局限性, 各层智能体通过以下机制逐一化解挑战.

• **GEO 策略编排智能体:** 本文拟在 GEO 卫星上部署参数量最大的 LLM 智能体, 作为系统的全局策略控制单元. 针对传统方法中超参数设定, 模型架构与拆分节点高度依赖人工经验等挑战, GEO 智能体无需处理瞬时的高频调度, 而是基于长期的全球星历预测与任务精度需求, 自主决策模型架构的选择 (如模型层数、隐藏层维度、注意力机制、混合专家模型等关键架构) 和全局模型的分割方式 (如 Transformer 模型的分割层数). 通过统筹规划模型训练的任务分解方式并下发给中间层, GEO 智能体打破了静态规则的局限, 成为系统中不可或缺的宏观规划者; 而具体的即时通信与聚合任务则被卸载至 MEO 执行, 以规避频繁与 GEO 卫星通信导致过高的传输延迟.

• **MEO 组织协调智能体:** 本文拟在 MEO 卫星上部署中等规模的 LLM 智能体. 作为一定覆盖范围内 LEO 卫星的区域指挥中心, MEO 智能体负责计算任务的即时分配、局部模型聚合与同步控制. 针对卫星网络拓扑极高的动态性导致 LEO 卫星频繁上线与离线的问题, MEO 智能体通过分析本区域内 LEO 卫星的上报日志, 动态甄选当前状态良好的 LEO 卫星参与训练. 此外, 为解决传统静态聚合策略失效的问题, 在分割学习过程中, MEO 智能体能够根据实时网络带宽和算力状态动态微调分割节点; 并在聚合时动态调整加权权重, 以过滤异常更新并缓解非独立同分布数据带来的模型偏移. MEO 智能体还能自主设定动态超时时间, 在同步和异步模型聚合之间寻求自适应的高效平衡.

• **LEO 本地决策智能体:** 本文拟在算力最为受限的 LEO 卫星上部署轻量型 LLM 智能体. LEO 智能体直接贴近观测数据源, 负责本地模型训练的参数控制与调优任务. 针对卫星节点能源水平波动以及静态本地更新方法的局限性, LEO 智能体能够实时感知卫星当前的剩余电量、是否处于日照或阴影区以及本地存储空间与数据分布情况. 据此, 智能体抛弃了固定的训练脚本, 自主调整本地模型更新的次数、批次大小以及是否采用正则化技术等关键参数, 以确保本地模型能够在严苛的资源约束与动态波动的环境下顺利完成可靠更新.

在分层智能体协作架构下, 智能体卫星联邦学习的计算与通信流程从传统的固定时序流水线演进为由智能体驱动的感知决策与自适应模型更新双阶段循环. 在训练初始阶段, 部署于 GEO 卫星的策略编排智能体首先基于长周期星历预测与任务语义, 自主完成模型架构的选择与分割学习的初始分割策略制定, 并将宏观规划下发至 MEO 卫星. 随后, MEO 卫星的组织协调智能体感知其实时覆盖范围内的 ISL 状态与 LEO 卫星的算力负载, 动态执行任务分配与分割节点的微调, 并为选定的 LEO 卫星下发自适应训练指令. 在模型更新阶段, LEO 卫星的本地决策智能体根据其是否处于日照区、剩余电量以及存储余量等实时资源约束, 自主调优本地训练轮数与正则化参数, 完成高效的近源模型训练. 训练产生的梯度或模型参数随后上传至 MEO 智能体, 由其根据各节点上报的运行日志执行动态加权聚合, 以消除非独立同分布数据与网络异构性引发的模型偏移. 最后, 经过区域迭代后的子模型进一步汇聚至 GEO 智能体进行全局优化, 产出最终模型并利用反馈信息开启新一轮的策略演进, 直至卫星联邦学习模型收敛. 需要注意的是, 动态权重可以使聚合过程适应节点和链路状态变化, 但权重变化过快可能增加训练波动. 异步聚合能够减少对慢节点的等待, 但部分更新可能基于较旧的模型产生. 这类陈旧更新可能偏离当前模型的优化方向, 从而影响收敛速度和稳定性. 实际系统可通过设置最大陈旧度、降低陈旧更新的聚合权重以及周期性执行同步聚合等方式减弱其影响. 这些措施有助于改善训练稳定性, 但不能自动保证模型收敛.

针对 LLM 智能体的开销, 不同轨道卫星可根据其计算、存储和能源条件部署不同规模及数值精度的智能体模型. 对于算力仅为数十 TOPS 的 LEO 卫星, 可部署参数规模约为 1B 的 INT4 量化模型, 其权重存储开销约为 0.5 GB, 能够以较低的资源消耗完成星载状态分析、异常识别和局部任务调度等轻量级决策 [37]. MEO 卫星具有相对充足的计算与存储资源, 可部署参数规模约为 3B∼7B 的 INT8 或混合精度模型, 其权重存储开销约为 3∼7 GB, 计入推理缓存和运行环境后, 通常需要 8∼16 GB 内存. 该类模型可在秒级完成区域决策, 主要用于汇总多个 LEO 节点的状态信息, 并执行区域任务分解、节点选择和服务路径调整 [38]. 对于算力达到约 1000 TOPS 且具有较大存储容量的 GEO 卫星, 可部署参数规模约为 7B∼14B 的 FP16 模型, 其权重存储开销约为 14∼28 GB, 实际运行时通常需要配置 32∼64 GB 内存 [39]. 由于 GEO 智能体主要承担全局任务规划、模型选择和跨区域资源协调等低频决策任务, 其秒级推理时延能够满足相应的任务需求.

2.3　面向分层智能体卫星联邦学习的星间链路调度方法

在分层智能体卫星联邦学习架构中, 尽管各层智能体通过自主决策显著提升了计算过程的自适应能力, 但模型参数在跨层传输过程中仍面临严峻的通信约束. 一方面, 多层卫星网络的拓扑结构随时间高速变化, ISL 链路的连通性具有强时变特性 (例如, LEO 卫星以约 7.5 km/s 的超高速度运行, 导致跨轨 ISL 或异构层间链路的稳定可视时间窗通常仅维持 1∼3 min); 另一方面, LEO 卫星受限于能耗预算与有限带宽资源, 在大规模模型参数传输场景下极易成为系统瓶颈 (例如, 面对业界领先的 Qwen2.5-72B 大模型, 其参数量高达 720 亿, 若以 16 位精度存储, 单次完整模型更新的通信开销即高达 144 GB). 因此, 如何在动态拓扑约束下实现通信高效的模型聚

合路径规划, 成为保障分层联邦学习系统可行性的关键问题. 为此, 在本节所提出的拓扑感知分层卫星联邦学习框架基础上, 进一步引入面向智能体协同决策的链路调度机制, 将传统基于规则的静态调度策略扩展为 “智能体感知驱动 + 最优路由求解” 的协同优化范式 [30]. 该方法以最小化模型聚合通信时延为核心目标, 在动态时变图模型上构建通信高效的聚合路径, 并通过智能体实现跨层调度策略的自适应演化.

2.3.1　拓扑感知建模与智能体协同决策机制

链路调度的首要环节是拓扑感知的聚合路由建模与智能体分层决策. MEO 组织协调智能体首先基于星历信息构建当前拓扑快照对应的时变权重图 $\mathcal{G}_t$, 并以链路传输时延作为边权重, 将多颗 LEO 卫星的模型上传过程建模为典型的 “多源单汇” 聚合路由问题. 针对多路径间的链路竞争与等待时延, 本文采用通信 – 计算融合的建模方式, 利用联邦学习模型更新的线性可加性, 在中间节点接收多个上游更新后执行即时聚合. 这种将聚合操作内嵌于路由过程的方法, 实现了路径规划与数据融合的协同优化, 从而可以减少后续链路负载. 为支撑该模型, 不同层级的智能体承担差异化的决策角色: GEO 策略智能体从全局视角出发, 基于长期拓扑统计信息动态调整路由代价函数中的权重参数, 以实现跨轮次策略演化; MEO 协调智能体作为核心决策单元, 在每个快照周期内构建簇内最优上行聚合路由; LEO 本地智能体则结合自身能量状态与链路质量, 对是否参与上传及发送功率进行局部调整. 通过上述分层机制, 链路调度不再依赖单一中心节点, 而是由多层智能体协同完成, 为动态拓扑环境下的自适应调度提供支持.

2.3.2　基于有向最小生成树的聚合路由与自适应调度

在具体路由实现与可靠性保障方面, 本文采用基于有向最小生成树的聚合路由构建方法与时间窗感知调度机制. 如图 3 所示, 在每个拓扑快照内, 系统根据当前拓扑快照和链路权重, 生成以目标节点为根的候选上行聚合树. 其中, 链路权重主要由信号传播时延和模型数据传输时间确定. 聚合树的构建采用 Chu-Liu/Edmonds 算法: 首先为每个非目标节点选择权重最小的出边; 若所选边形成有向环, 则收缩该环并调整相关边权; 最后展开被收缩的环, 得到无环的上行聚合树. 该过程的时间复杂度为 $O(|\mathcal{E}_t|\log|\mathcal{E}_t|)$, 其中 $\mathcal{E}_t$ 表示当前拓扑快照内的可用链路集合. 该树形结构满足两个关键性质: 一是确保每个 LEO 卫星仅沿唯一上行路径传输, 避免冗余通信; 二是在路径汇聚节点触发中间聚合以压缩数据流, 从而通过中间聚合减少部分重复上行数据及其链路负载. 但树形路由不能根本消除共享链路竞争, 其实际性能仍受到接触窗口、链路容量、节点收发限制和聚合等待的共同影响 [30]. 作为对比, 传统 Dijkstra 算法可以作为端到端路由基线, 用于分别寻找各节点到聚合节点的最短路径, 存在较高的重复计算开销. 结合分层框架, 该过程被高效分解为 MEO 时变簇内的局部聚合路由与 MEO-GEO 层间的全局聚合路由两个阶段. 此外, 为进一步提升复杂空间环境下的可靠性, MEO 智能体在执行路由时严格引入时间窗约束, 优先选择能在当前快照周期内完成传输的路径, 并对跨周期长路径实施动态重构与任务延迟调整. 在异步聚合场景下, MEO 智能体还对滞后的模型参数引入时延衰减权重, 以减弱陈旧更新对当前模型的影响, 并避免等待最慢节点引发的木桶效应. 需要说明的是, 时延衰减权重只能在一定程度上改善异步训练的稳定性, 并不能直接保证模型收敛. 所述联合调度方式为短星间可见窗口内的模型更新传输提供一种低复杂度候选方案, 但不保证在时变链路、容量约束和聚合等待并存条件下获得全局最优调度结果.

3　智能体卫星边缘推理

针对静态任务规划与调度难以适应动态卫星网络的问题, 本节面向 MEO-LEO 混合卫星系统, 构建分层智能体卫星边缘推理架构. 该架构利用 MEO 与 LEO 卫星在覆盖范围、拓扑稳定性和计算资源方面的互补性, 对不同类型的智能体进行分层部署. MEO 侧主要承担任务规划、服务编排和系统管理, LEO 侧主要负责数据感知、工具调用和近源推理. 各层智能体通过状态与执行结果的交换形成反馈闭环, 共同完成任务感知、规划分解、协同执行和质量评估.

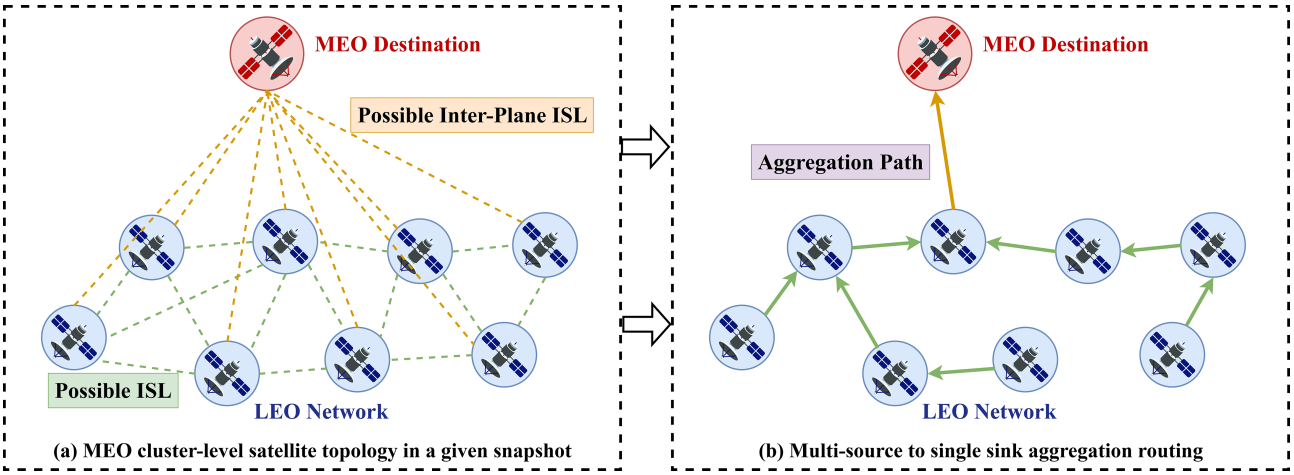

图 3　(网络版彩图) 基于有向最小生成树的聚合路由与自适应调度.

Figure 3　(Color online) Aggregation routing and adaptive scheduling based on directed minimum spanning trees.

3.1　卫星边缘推理

随着卫星边缘 AI 应用需求的不断增长, 在轨推理逐渐成为支撑实时遥感分析、自主通信决策与在轨智能处理的核心能力. 所谓卫星边缘推理, 是指利用卫星边缘节点的计算资源, 在轨就近完成从数据采集、预处理到模型前向计算及结果生成的全流程 AI 任务 [40]. 现有大多数卫星边缘推理方法主要基于 LEO 卫星单层部署 [41, 42]. 在该架构中, LEO 卫星在经过目标区域时, 利用其搭载的传感器获取原始观测数据, 并在本地执行完整的 AI 推理流程. 该架构的核心优势在于其近源计算能力, 能够避免大规模原始数据回传带来的通信开销, 并显著降低端到端响应时延. 然而, 该模式存在明显的局限性: 首先, 单颗 LEO 卫星的计算能力有限, 难以支撑大模型推理或复杂多阶段推理任务; 其次, 推理流程通常预先固化, 缺乏根据环境变化进行动态调整的能力; 此外, 星座中大量卫星的计算资源未被协同利用, 跨节点任务分配困难; 最后, 当出现云层遮挡、链路中断或节点失效时, 系统缺乏重构能力, 易导致任务失败. 为突破单层架构的局限性, 有效的解决方案是引入 MEO 卫星作为中间协调层 [43], 从而构建 MEO-LEO 分层协同推理架构. 在该架构中, LEO 卫星仍负责数据采集与局部推理, 而 MEO 卫星利用其更稳定的拓扑与更强的计算能力, 承担任务分配、路径选择与中间结果聚合等功能. 具体而言, LEO 卫星获取观测数据后, 可选择在本地执行部分推理模块, 或将数据与中间特征上传至 MEO 节点; MEO 节点基于全局视角, 将推理任务划分为多个阶段, 并在多个 LEO 节点之间进行分布式调度. 尽管该分层架构在一定程度上缓解了算力不足与资源孤立问题, 实现了跨节点协同推理, 但其本质仍属于 “规则驱动的分布式系统”, 在应对复杂动态的真实空间环境时面临如下严峻挑战. (1) 缺乏动态任务理解与语义协同能力: 现有调度策略严重依赖预定义规则或启发式算法, 无法根据高层任务语义自动调整与拆解推理流程; 多节点之间仅停留在底层资源级的调度, 缺乏面向任务目标的语义级协同机制. (2) 静态调度策略难以适配高动态环境: 卫星网络拓扑高速变化, 且节点可用算力与能源水平持续波动. 传统的静态或准静态任务分配方案难以与实时动态变化的网络环境及资源状态相匹配, 极易引发局部拥塞或资源闲置. (3) 闭环优化与故障重构能力缺失: 在真实空间任务中, 突发的云雨遮挡, 传感器故障或链路通断属于常态. 现有的开环流水线系统无法基于执行层面的实时反馈自动修正推理路径或触发重观测, 导致系统容错率极低. 上述挑战表明, 传统的 MEO-LEO 架构难以应对高度不确定的空间任务环境, 亟需一种具备高度自治能力的全新架构.

3.2　分层智能体卫星边缘推理

为应对上述挑战, 本文引入智能体 AI, 将卫星节点从被动执行单元提升为具备自主决策能力的智能体, 从而构建智能体驱动的卫星边缘推理架构. 如表 1 所示, 其关键增益体现在三个连续环节: 在任务规划阶段, 智能体依据任务语义生成可修改的任务图, 而非仅选择预设流水线; 在自适应调度阶段, 智能体结合实时资源状态确

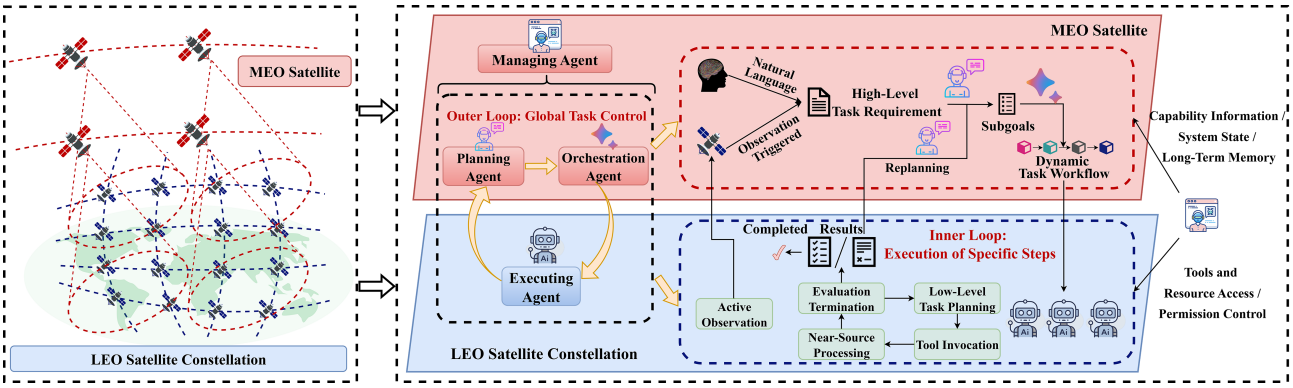

图 4　(网络版彩图) 分层智能体卫星边缘推理架构.

Figure 4　(Color online) Hierarchical agentic satellite edge inference architecture.

定调度目标与约束, 并调用底层算法产生可执行的节点和路径映射; 在动态重构阶段, 系统依据中间结果质量与故障反馈, 同时调整服务路径和后续任务逻辑. 由此形成的 “感知 – 规划 – 执行 – 反馈” 闭环, 使系统能够在不改变底层受约束求解机制的前提下, 将适应范围由资源波动扩展至任务目标与流程结构的变化. 在此基础上, 本文构建了 MEO-LEO 分层智能体架构, 系统中的核心智能体被划分为四类逻辑角色. 需要强调的是, 这里的 “角色” 是指逻辑角色, 而不是物理卫星的一一对应; 同一类角色在后续实现中既可以是单实例, 也可以是多实例, 甚至可以由多个卫星节点共同承载. 具体划分如下 (见图 4).

• **推理任务规划智能体:** 位于 MEO 卫星侧, 是整个任务闭环的起点与终点. 其核心职责是维护全局任务上下文, 将最上层任务请求分解为阶段性子任务, 并根据执行反馈持续判断任务是否已经达到预期质量, 是否需要追加步骤, 是否应触发新的观测或直接结束流程. 换言之, 规划智能体既承担 “先规划” 的职责, 也承担 “最终判定是否结束” 的职责, 是任务语义层的核心控制者.

• **推理任务编排智能体:** 同样位于 MEO 卫星侧, 但它并不直接决定 “做什么”, 而是回答 “由谁做, 在哪里做, 按照什么顺序做” 的推理任务执行流程问题. 在接收到规划智能体输出的子任务后, 编排智能体负责将这些语义化子任务映射为可执行的资源调用过程, 包括执行者选择、任务卸载和服务功能链 (service function chain, SFC) 组织, 调用顺序安排以及必要的路由生成. 当链路状态、卫星负载或任务优先级发生变化时, 它还需要对现有任务流程进行运行时重编排, 从而使工作流能够随着环境变化而动态调整, 而不是一次生成后静态执行.

• **推理任务管理智能体:** 是 MEO 卫星侧的知识支撑与系统维护角色. 与直接面向当前任务的规划和编排不同, 管理智能体更关注系统的长期状态与全局可用能力: 它维护检索增强生成 (retrieval-augmented generation, RAG) 知识库、长期记忆、全局能力注册表、模型与工具元数据、服务健康状态以及策略版本信息, 并在任务开始前为规划与编排过程提供必要的上下文与能力约束, 在任务执行中进行权限控制.

• **推理任务执行智能体:** 主要位于 LEO 卫星侧, 负责把 MEO 卫星生成的抽象子任务转化为具体动作. 它直接面向载荷与工具工作, 承担观测触发、工具调用、近源处理、结果封装和状态回传等职责. 在这里, “工具” 并不局限于遥感模型本身, 还包括姿态控制接口、可见窗口查询、变化检测模块、质量评分器、缓存与压缩模块等各类可调用能力. 执行智能体本身作为独立智能体, 仍可完成 “感知 – 规划 – 执行 – 反馈” 的持续闭环, 但其专注于任务的具体执行步骤, 不承担全局任务规划职责.

上述智能体角色划分、动态任务流图、服务功能链路由与动态重编排分别对应星间协同推理的功能组织、逻辑建模、物理执行和在线调整阶段. 首先, 不同角色的智能体按照任务规划、资源管理、服务编排、任务执行和结果评估等职责进行协作, 构成推理任务的功能主体. 在此基础上, 规划智能体根据任务目标将复杂推理过程分解为多个具有依赖关系的子任务, 并生成描述其控制依赖、数据依赖和执行反馈关系的动态任务流图. 因此, 任务流图中的节点表示待执行的子任务或功能单元, 边表示子任务之间的执行顺序、数据流向与反馈关系; 不同角色的智能体则负责对这些节点进行生成、映射、执行和调整. 随后, 编排智能体从任务流图中提取需要跨卫星

部署的推理功能, 将其映射为由多个虚拟网络功能组成的服务功能链, 并结合卫星节点算力、链路状态和接触窗口, 确定服务实例的部署位置及星间传输路径. 执行智能体按照既定映射调用相应工具或模型服务, 并返回中间结果. 在任务执行过程中, 若局部结果不满足预期, 或网络拓扑、资源状态和任务需求发生变化, 规划智能体可扩展、裁剪、回退或重连任务流图, 编排智能体则可替换服务实例、迁移部分功能或调整传输路径, 从而实现服务功能链的动态重编排. 由此, 任务流图描述 “需要完成哪些功能及其依赖关系”, 服务功能链路由确定 “这些功能由哪些卫星承载并按照何种路径执行”, 动态重编排则解决 “执行条件变化后如何调整任务逻辑、服务映射与传输路径” 的问题. 从整体运行机制来看, 上述过程可进一步概括为 “外环 – 内环” 双环闭环. MEO 侧的规划智能体、编排智能体和管理智能体构成外环, 负责意图解析、任务分解、能力约束和全局调度; LEO 侧的执行智能体构成内环, 负责局部感知、工具调用、结果生成和快速反馈. 外环决定任务如何展开并映射至物理资源, 内环负责具体任务的执行与验证, 内环产生的中间结果和状态反馈又驱动外环更新任务流图与服务功能链. 与传统固定流水线相比, 该机制支持任务逻辑、服务部署和传输路径的闭环调整, 从而提高系统对动态拓扑、资源变化和任务不确定性的适应能力.

智能体生成的任务分解或工具调用可能存在事实错误、逻辑偏差和不可行动作. 因此, 智能体输出不能直接作为卫星控制指令, 可进一步采用生成式外环与确定性安全内核的分层防护方式: 首先, 规划结果必须符合预定义任务图和接口数据类型; 其次, 约束检查器依据轨道可见性、姿态机动、剩余能量、热状态、存储、链路容量、工具权限和任务优先级验证可行性; 再次, 路由、资源分配和载荷动作由传统优化器或经过验证的控制模块求解, 智能体仅给出目标、候选工具和有限动作集合. 对高风险动作, 系统还应在数字孪生环境中执行预演, 并通过置信度阈值、双智能体交叉检查或地面确认后再下发 [44]. 若候选计划未通过模式校验、硬约束检查或超时限制, 系统首先要求规划智能体在错误码和可行域约束下重新生成. 达到最大重试次数后, 管理智能体回退至经过验证的静态任务模板、最短路/备用路由或最近可信检查点. 当安全模式仍无法满足核心约束时, LEO 执行端保持当前安全状态并暂停非关键任务, 同时向 MEO 上报告警. 所有计划版本、校验结果、工具调用和回退原因均写入审计日志. 该机制将生成式模型的灵活性限制在可验证的动作空间内, 但其可靠性仍需通过故障注入、极端场景仿真和在轨试验逐级验证.

3.3　基于服务功能链路由的星间协同推理

在完成智能体角色划分后, 如何在资源受限且拓扑时变的卫星网络中高效落地大规模推理任务是另一核心课题. 随着 LLM 参数规模的激增, 依靠单星执行完整推理流程已不再现实. 为此, 本文提出一种基于微服务化与 SFC 路由的分布式协同推理技术 [45]. 其核心思想在于将复杂推理任务在空间维度上进行精细拆分, 在时间维度上进行动态调度, 并通过多节点协同执行实现与原始单体推理等价的高质量输出结果, 如图 5 所示.

3.3.1　基于服务功能链的卫星边缘推理架构

从任务表示角度看, 复杂的卫星边缘推理任务通常包含数据预处理、特征提取、主干模型推理与结果后处理等多个阶梯式计算过程. 在网络功能虚拟化 (network function virtualization, NFV) 框架下, 每个计算阶段被封装为一个细粒度、资源需求明确的虚拟网络功能 (virtual network function, VNF). 多个 VNF 按照数据依赖关系有序级联, 即构成一条 SFC. 这一转化过程并非静态分配, 而是由智能体深度参与与主导. 具体而言, 规划智能体依据当前的观测上下文与任务语义生成初始任务图; 编排智能体将子任务转化为可部署的 SFC, 严格决定各模块的依赖关系与执行顺序; 执行智能体则在 LEO 侧调用本地预训练模型完成 VNF 的实际落地. 由此, SFC 不仅描述了底层计算结构, 更深层地内嵌了分层智能体间的协同逻辑.

在跨星部署层面, 本文采用微服务化架构, 将智能体本身视为可拆分、可组合的服务集合, 严格遵循 “角色逻辑与资源实体解耦” 的原则. 对于 MEO-LEO 混合系统, MEO 侧承载强状态、长生命周期的服务, 如全局规划、服务编排与知识管理, 并采用多实例冗余部署以抵御单点故障, 显著增强系统的全局鲁棒性. 相对地, LEO 侧则承载面向载荷与本地模型的近源执行服务. 此处系统遵循将服务实例精准部署在最贴近其所依赖载荷的物理节点上的优先原则. 例如, 将特定频段的特征提取 VNF 直接部署于搭载对应合成孔径雷达 (synthetic aperture

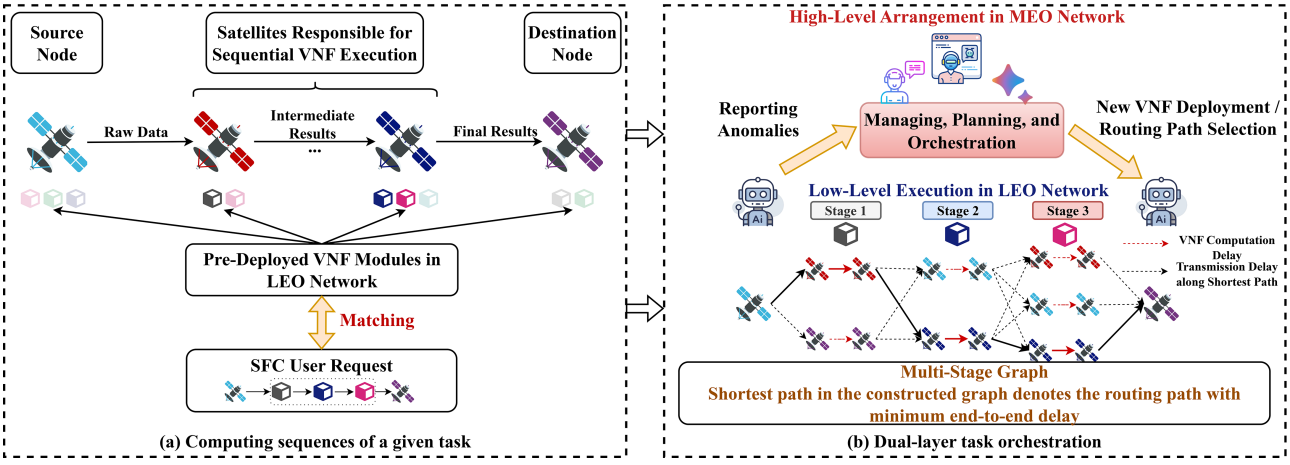

图 5　(网络版彩图) 基于多阶段时变图和双层任务编排的服务功能链路由方法.

Figure 5　(Color online) SFC routing method based on multi-stage graphs and dual-layer task orchestration.

radar, SAR) 传感器的 LEO 卫星上, 以免除海量原始数据的跨星传输. 这种解耦与微服务化的部署方式使得系统在面对局部节点拥塞或突发新任务插入时, 能够按需进行计算资源的弹性调度 [46].

跨轨道、跨制造商部署还需要统一控制接口和语义数据模型. 在服务管理层, 可参考 ETSI 网络功能虚拟化管理与编排框架, 为 VNF 描述、实例化、扩缩容、迁移、健康检查和版本管理定义统一接口 [47]. 在空间任务交互层, 可参考空间数据系统咨询委员会任务运行消息抽象层的服务化思想, 采用与传输协议解耦的消息模型 [48]. MEO 与 LEO 之间至少应交换带版本号的任务描述、VNF 资源画像、输入/输出模式、服务质量需求、观测时间戳、置信度、错误码和执行状态. 标准化接口的作用不只是实现消息互通, 还需支持身份认证、能力授权、超时重试和向后兼容. 任务管理智能体维护全局能力注册表和模式版本, 任务规划智能体使用统一任务本体表达目标与约束, 策略编排智能体依据标准资源描述完成跨厂商 VNF 发现与映射, 终端执行智能体按统一结果模式返回状态. 当节点仅支持较低接口版本或缺失某项能力时, 编排智能体可以在生成 SFC 前完成兼容性检查, 避免语义一致但接口不可执行的服务链.

3.3.2　协同推理路由与动态任务编排

为了支持上述微服务化架构的落地, 协同推理的整体效率高度依赖于 SFC 路由决策机制. 如图 5 所示, 给定一条由若干 VNF 构成的推理 SFC, 编排智能体必须在高速运动的卫星拓扑中为每个 VNF 选择最佳承载节点, 并规划最优的 ISL 传输路径. 这一过程面临典型的 NP 难组合优化挑战, 系统需要在极短的快照窗口内精确平衡节点本地处理时延与跨星间传输时延. 为此, 本文结合星间延迟最短路径的统计稳定性与自适应调度, 提出了一种拓扑感知与智能优化相融合的联合求解方案. 一方面, 利用 LEO 节点间最短路径时延在长期运行中展现出的统计稳定性, 管理智能体可提取离线预计算的平均时延作为先验知识, 在简化的多阶段时变图模型上实现快速的在线路由初筛, 从而有望缩小在线决策所需搜索的空间范围. 另一方面, 考虑到 ISL 物理参数的瞬时波动与局部计算资源的动态消耗, 本文将路由选择问题进一步建模为马尔可夫决策过程 (Markov decision process, MDP), 并利用多智能体强化学习 (multi-agent reinforcement learning, MARL) 框架进行实时策略调优 [49]. 在此机制下, 部署于 MEO 的多个编排智能体通过交换局部状态信息进行协作决策, 确保数据流能够在瞬息万变的空间网络中, 沿着最优路径平滑穿过 SFC 中的所有 VNF [45]. 需要说明的是, MARL 策略所得结果受到状态表示、奖励函数和训练数据分布的限制, 因而属于面向当前场景的近似决策结果, 不代表在所有时变网络状态下均可获得全局最优解.

为了进一步适应高度动态的空间环境并提升系统的容错率, 架构还引入了智能体驱动的运行时重编排机制. 传统的 SFC 一旦部署便难以更改, 而在真实的太空环境中, 链路意外中断或局部节点算力枯竭频发. 本文所提架构依托 “外环控制” 与 “内环执行” 的服务化闭环来有效应对这一挑战. 当 LEO 内环的执行智能体在执行过

程中感知到局部资源急剧恶化, 或因云层遮挡导致推理置信度严重不足时, 它会将这些异常状态以结构化反馈的形式实时上报. 系统接收到反馈后不会简单中断整个推理流程, 而是立即触发 MEO 外环的图级别动态调整. 此时, 编排智能体可实时替换失效的 VNF 承载节点或改写后续的服务路径, 规划智能体也可据此果断插入新的补充推理子任务或请求邻近卫星进行多模态重观测. 以洪涝灾害区域积水识别任务为例, 系统接收到受灾区域快速确认与持续跟踪需求后, 管理智能体首先根据历史观测记录、载荷能力与服务状态提供任务上下文, 规划智能体据此将任务分解为首次观测、积水识别、质量评估与必要时补充观测等阶段. 对于首次观测数据, 编排智能体将数据预处理、云层检测、水体分割、变化检测及置信度评估等计算功能组织为 SFC, 并综合 LEO 卫星的观测窗口、载荷类型、计算负载与 ISL 状态, 将相应 VNF 映射至适宜的执行节点. LEO 侧执行智能体按照编排结果完成载荷调用与近源推理, 并将积水范围、识别置信度及观测质量等结果反馈至 MEO 侧. 当观测覆盖范围、时效性与识别置信度满足任务要求时, 规划智能体终止当前任务, 并由管理智能体更新任务记录与执行经验. 当光学图像受到云层遮挡或识别置信度不足时, 规划智能体在原任务图中追加 SAR 补充观测与多模态融合任务, 编排智能体进一步选择下一颗具有可用观测窗口和相应载荷的 LEO 卫星, 重新调整 VNF 承载节点与 ISL 传输路径, 从而形成更新后的 SFC 并继续执行. 该实例表明, 执行反馈不仅用于评价当前推理结果, 还可驱动任务分解、服务部署与传输路径的协同重构. 相较于完全预定义的静态流水线, 该闭环为异常条件下的任务调整提供了更灵活的实现方式.

4　未来工作

本文针对卫星边缘智能中的分层卫星联邦学习与星间协同推理进行了初步探索. 面向未来天基算力网络的深入演进, 我们认为以下几个方向具有极其重要的研究价值与广阔的发展前景.

4.1　面向严苛物理约束的在轨计算架构

随着天基算力网络规模的持续扩张, 卫星边缘节点承载的 AI 模型参数量与计算密集度呈指数级上升, 这对在轨计算硬件提出了前所未有的物理约束挑战. 其一为热耗散瓶颈: 大功率计算芯片在真空与极端温差环境中极易产生热聚集. 已有研究开始探讨从传统的被动散热向兆瓦级主动热控技术演进的必要性, 期待在轻量化与高效热传导 (如两相流热开关、泵浦微通道冷却等) 方面寻求突破 [50]. 其二为能源与老化瓶颈: LEO 卫星在日照区和阴影区之间不断穿梭, 持续的高强度计算会引发电池频繁的充放电循环. 这种非线性的物理退化显著加速了高昂电池的老化过程, 构成了太空计算中制约系统可持续性的 “隐性成本” [51,52]. 其三为 “存算分离” 瓶颈: 当前在轨计算通常基于遵循冯 · 诺依曼 (von Neumann) 架构的处理器实现, 该架构中存储单元与计算单元是分离部署的, 导致数据需要在存储与处理单元之间频繁传输, 从而带来高额能耗开销. 为突破上述物理极限, 未来工作拟探索具有极低功耗特性的类脑计算架构. 类脑计算旨在模仿生物大脑神经元的工作机制, 通过在器件层利用忆阻器实现类突触权重存储, 并在阵列结构中执行向量 – 矩阵原位计算, 可实现 “存算一体” 融合以及事件驱动的数据处理, 从而显著降低数据搬移带来的能耗开销并提升计算效率 [53]. 目前已有工作在地面环境下验证了脉冲神经网络 (spiking neural networks, SNNs) 的高能效性 [11,26]. SNNs 采用离散的二进制脉冲序列进行信息传递, 具有独特的事件驱动机制与极度稀疏的计算特性. 未来的研究可重点探讨如何将空间多模态感知数据编码为脉冲序列, 并设计基于分层智能体的分布式在轨类脑模型训练算法. 这种硬件友好的计算范式不仅有望使能耗开销降低数个数量级, 还能从根本上缓解散热压力与电池老化速度, 从而有望提升其对天基平台严苛物理约束的适应性.

在工程实现层面, 卫星的尺寸、重量、功率和成本约束共同决定了所提架构的实际部署方式. 尺寸和重量限制了星载计算板卡、存储设备、散热结构及冗余硬件的配置, 功率预算和热设计约束则限制了智能体模型的规模、数值精度和并发推理能力. 同时, 为星座内所有卫星配置高性能硬件将显著增加系统建设与维护成本. 因此, 所提架构采用异构分层部署方式, 将轻量级执行功能部署于靠近数据源的 LEO 节点, 并将计算开销较大的规划与编排功能部署于资源相对充足的 MEO 或 GEO 节点. 在运行过程中, 任务编排还需要综合考虑节点的可用算

力、存储空间、剩余能量、热状态、观测窗口及链路可用性. 当资源约束收紧时, 系统可通过缩小模型规模、降低数值精度与任务并发度, 或迁移和推迟非关键任务维持安全运行, 但这些措施可能增加任务响应时延, 并降低推理精度或服务容量. 此外, 针对空间辐射引起的器件故障及星间链路间歇中断, 工程实现中还需引入状态检查点、任务重试、冗余部署和降级运行等机制, 并承担相应的计算、通信和存储开销.

4.2　基于智能体工作流的遥感时序数据解析

对地观测卫星持续产生海量的多模态、高分辨率时间序列遥感数据, 如高光谱、多光谱与 SAR 数据等, 广泛赋能地表变化检测、农业与生态监测、灾害动态分析以及时空预测等下游任务, 是支撑动态地球系统建模与智能决策的关键数据基础. 现有的处理方法在应对时空动态性时, 往往依赖固定的网络架构与人工先验知识, 泛化能力受限 [54]. 为赋予天基智能处理更高的灵活性, 未来工作拟借鉴在其他领域已得到初步验证的智能体工作流范式 [55], 构建面向遥感时序数据的结构化智能体系统. 该系统将传统流水线重塑为由智能体主导的迭代决策过程, 涵盖三个阶段. (1) 模型选择与组合: 智能体根据自然语言描述的观测意图, 自主从模型库中选取合适的基础时序模型. (2) 代码动态生成与修正: 智能体编写并执行预处理代码, 消除多模态时序数据的对齐误差. (3) 反思性反馈: 智能体在获取初始结果后, 根据多模态重建误差进行 “自我反思”, 并自主微调策略. 这种将 LLM 的推理与动态执行能力引入遥感时序数据分析的方法, 有望实现卫星遥感智能解译任务的自动化闭环与高精度泛化.

4.3　卫星在轨资源优化问题的自动化建模, 求解与数学证明

在多层卫星网络中, 无论是星间聚合调度还是分布式 SFC 路由, 其本质多属于复杂的混合整数非线性规划 (mixed-integer non-linear programming, MINLP) 或大规模组合优化问题. 传统的静态求解器难以在极短的快照窗口内给出高质量解, 且方案的性能评估往往需要复杂的非凸优化收敛性证明. 针对这一痛点, 未来工作将向基于 LLM 智能体的全自动优化体系迈进 [11,56]. 首先, 在自动化建模方面, 拟引入类似 ORLM [57] 和 LLMOPT [58] 的框架. 智能体接收以自然语言描述的资源约束 (如 “最小化 30 颗 LEO 卫星的模型聚合时延”), 自动将其映射为规范的数学模型或直接生成求解器调用代码, 并通过内置纠错机制寻找最优解. 此外, 针对传统启发式算法难以应对时变拓扑的缺陷, 引入类似 HeuriGym [59] 的智能体自动化启发式设计范式. 该范式允许 LLM 智能体通过代码执行获取评估反馈, 从而在无监督环境下持续迭代与优化出专门适配高动态天基网络的定制化路由或调度启发式算法. 其次, 在底层理论证明方面, 期待利用如 GPT-5-Pro 等具备深层推理能力的模型作为 “研究助手” [60]. 智能体不仅能提出启发性的收敛界推导方向, 还能辅助完成如共轭算子梯度泰勒展开、分布式机器学习收敛界等繁杂的数学推导. 这种全链路智能体化, 将为天基算力网络的基础理论研究带来革命性的加速.

4.4　仿真验证与数字孪生半实物平台

在轨物理验证成本较高, 更可行的研究路径是构建轨道、网络、计算与任务四层耦合的数字孪生测试平台. 轨道层可使用系统工具包 (Systems Tool Kit, STK) 或公开两行根数 (two-line element, TLE) 生成卫星位置、覆盖关系和接触窗口; STK 可提供物理任务环境中的轨道与载荷分析 [61]. 网络层可使用离散事件网络仿真器 ns-3 复现链路建立、速率变化、传播时延、队列、丢包和路由协议 [62]. 计算层通过容器或板卡性能剖析数据回放 VNF 执行时延、模型内存与功耗. 任务层则实现第 2 节的联邦学习过程和第 3 节的灾害响应 SFC, 并记录智能体计划、约束校验与回退事件. 验证过程可按 “纯软件仿真 – 软硬件结合 – 半实物数字孪生平台” 逐级推进. 半实物数字孪生平台应接收真实星历、遥测和板卡测量数据持续校准, 并通过拓扑突变、链路中断、智能体幻觉和错误工具调用等故障注入评估安全边界 [63]. 未来智能体驱动的卫星边缘 AI 仿真平台的对比基线应包括传统分层联邦学习、去中心化卫星学习、静态聚合路由、静态 SFC 编排和不含智能体外环的 MEO-LEO 分层推理. 指标应覆盖通信开销、训练收敛、端到端时延、能耗、任务完成率、资源利用率以及链路中断后的恢复性能. 针对实验参数设置, 未来可参考开源轨道计算仿真平台 Orbital Compute Simulator [64]. 该平台基于 TLE 数据和 SGP4 模型进行卫星轨道传播, 并提供星间链路、地面站接触窗口、能源供给、热环境、辐射故障和计算任务调度等模块. 其中, 星间链路模块可用于生成随轨道位置变化的网络拓扑并分析链路路由, 接触窗口模块可用于估

计卫星与地面站之间的可通信时段, 工作负载与联邦学习模块则可为在轨推理任务和分布式训练任务的构造提供参考.

在上述平台上, 还需进一步验证底层通信与感知状态驱动训练和推理任务编排的跨层协同机制. 具体而言, 可将链路可用速率、剩余接触窗口、节点计算负载与能量余量, 以及观测覆盖率、数据质量和结果置信度等信息, 连同时间戳汇总为智能体可调用的状态描述. 对于训练任务, MEO 协调智能体可根据预计本地训练时间与模型上传时间能否满足剩余接触窗口, 联合调整参与节点、本地更新次数与聚合时机; 节点选择还应兼顾观测数据的质量与分布覆盖, 避免仅依据链路条件选择节点而加剧数据偏差. 对于推理任务, 当观测质量不足时, 规划智能体可追加补充观测或多模态融合子任务, 编排智能体则结合载荷可用性、链路容量与计算负载重新确定服务功能链的部署和传输路径. 各层智能体负责更新任务目标、约束与工具选择, 快速链路控制和受约束资源分配仍由相应控制器与优化算法执行, 执行结果再反馈至任务层. 后续可通过分别移除通信状态、感知质量或执行反馈输入的消融实验, 比较训练收敛、推理质量、任务完成率、端到端时延及控制开销, 评估跨层信息对任务编排的实际贡献.

5　总结

随着天基算力网络的蓬勃发展, 卫星边缘 AI 正经历从 “天感地算” 向 “天感天算” 的深刻变革. 面对多层卫星网络中高度时变的拓扑结构与严苛的资源约束, 传统的静态规则与被动执行架构已难以满足大模型时代在轨训练与推理的需求. 本文率先探讨了智能体 AI 在天基算力网络中的应用潜力, 提出了一种分层智能体驱动的卫星联邦学习与星间协同推理架构. 通过赋予卫星节点主动感知, 独立决策与语义协作的能力, 本文将静态处理流水线重塑为动态闭环的任务流图. 在分层卫星联邦学习方面, 本文设计了基于拓扑感知的 MEO 时变簇机制, 并提出时间窗与聚合感知的有向最小生成树路由算法, 有效疏解了在轨大模型分布式训练的通信瓶颈; 在星间协同推理方面, 结合 NFV 与微服务理念, 构建了基于 SFC 的分布式推理机制, 并讨论了多智能体协同下的复杂推理任务的实时路由与动态重编排. 总而言之, 智能体技术的引入为天基资源的弹性编排与复杂任务的自治协同提供了全新的范式. 尽管在严苛物理约束的类脑硬件适配, 时序数据自动化解析以及智能体驱动的资源优化理论证明等方面仍存在广阔的探索空间, 但智能体化演进无疑将成为下一代高可靠, 高弹性空间智能基础设施的核心驱动力, 为最终实现全球泛在的天基算力网络智能服务奠定坚实的理论与技术基础.

参考文献

1 Chaudhry A U, Yanikomeroglu H. Laser intersatellite links in a starlink constellation: a classification and analysis. IEEE Veh Technol Mag, 2021, 16: 48–56

2 Xie H, Zhan Y, Zeng G, et al. LEO mega-constellations for 6G global coverage: challenges and opportunities. IEEE Access, 2021, 9: 164223

3 Tong X Y, Xia G S, Lu Q, et al. Land-cover classification with high-resolution remote sensing images using transferable deep models. Remote Sens Environ, 2020, 237: 111322

4 Li A, Huang P, Shi L, et al. Update of remote sensing satellite ground system of China remote sensing satellite ground station. Natl Remote Sens Bull, 2021, 25: 251–266 [李安, 黄鹏, 石璐, 等. 中国遥感卫星地面站卫星地面系统的发展. 遥感学报, 2021, 25: 251–266]

5 Guerrisi G, Frate F D, Schiavon G. Artificial intelligence based on-board image compression for the Φ-Sat-2 mission. IEEE J Sel Top Appl Earth Observations Remote Sens, 2023, 16: 8063–8075

6 Guimarães C, Netti A, Sauer M, et al. A survey on satellite computing: connecting the dots between networks and applications. IEEE Commun Surv Tutorials, 2026, 28: 567–592

7 Kuang L, Sun J, Zhang J, et al. Towards space-based computing infrastructure network: development trends, network architecture, challenges analysis, and key technologies. ArXiv:2503.06521

8 Kuang L, Shi Y, Liu K, et al. Space computing power networks: fundamentals and techniques. Engineering, 2025, 54: 26–34

9 Zhang Q Y, Xu L, Huang J H, et al. Distributed satellite information networks: architecture, enabling technologies, and trends. Sci China Inf Sci, 2025, 68: 190301

10 Wu W, Huang X Y. Split-LEO: efficient AI model training over LEO satellite networks. Sci China Inf Sci, 2025, 68: 190305

11 Shi Y M, Zhu J Y, Jiang C X, et al. Satellite edge artificial intelligence with large models: architectures and technologies. Sci China Inf Sci, 2025, 68: 170302

12 StarCloud. StarCloud-1. 2025. https://www.starcloud.com/starcloud-1

13 Beals T, Biggs M, Bloom J V, et al. Towards a future space-based, highly scalable AI infrastructure system design. ArXiv:2511.19468

14 北京市科学技术委员会、中关村科技园区管理委员会. 北京加速布局太空数据中心. 2025. https://kw.beijing.gov.cn/xwdt/kcyx/xwdtcyfz/202511/t20251128_4309222.html

15 申佳平. 国星宇航: 已完成全球首次通用大模型太空在轨部署. 人民网. 2026. https://finance.people.com.cn/n1/2026/0127/c1004-40653910.html

16 Xu W, Yang Z, Ng D W K, et al. Edge learning for B5G networks with distributed signal processing: semantic communication, edge computing, and wireless sensing. IEEE J Sel Top Signal Process, 2023, 17: 9–39

17 Shi W, Xu W, You X, et al. Intelligent reflection enabling technologies for integrated and green internet-of-everything beyond 5G: communication, sensing, and security. IEEE Wireless Commun, 2023, 30: 147–154

18 Acharya D B, Kuppan K, Divya B. Agentic AI: autonomous intelligence for complex goals—a comprehensive survey. IEEE Access, 2025, 13: 18912–18936

19 Sapkota R, Roumeliotis K I, Karkee M. AI agents vs. agentic AI: a conceptual taxonomy, applications and challenges. Inf Fusion, 2025, 126: 103599

20 Yu C, Cheng Z, Cui H, et al. A survey on agent workflow—status and future. In: Proceedings of International Conference on Artificial Intelligence and Big Data, 2025. 770–781

21 Razmi N, Matthiesen B, Dekorsy A, et al. On-board federated learning for dense LEO constellations. In: Proceedings of IEEE International Conference on Communications, 2022. 4715–4720

22 Lin Z, Chen Z, Fang Z, et al. FedSN: a federated learning framework over heterogeneous LEO satellite networks. IEEE Trans Mobile Comput, 2025, 24: 1293–1307

23 Shi Y, Zeng L, Zhu J, et al. Satellite federated edge learning: architecture design and convergence analysis. IEEE Trans Wireless Commun, 2024, 23: 15212–15229

24 Zhai Z, Wu Q, Yu S, et al. FedLEO: an offloading-assisted decentralized federated learning framework for low earth orbit satellite networks. IEEE Trans Mobile Comput, 2024, 23: 5260–5279

25 Yan Z, Li D. Convergence time optimization for decentralized federated learning with LEO satellites via number control. IEEE Trans Veh Technol, 2024, 73: 4517–4522

26 Yang P, Wang T, Cai H, et al. Brain-inspired decentralized satellite learning in space computing power networks. IEEE Trans Mobile Comput, 2025, 24: 12935–12949

27 Zhao L, Geng S, Tang X, et al. ALANINE: a novel decentralized personalized federated learning for heterogeneous LEO satellite constellation. IEEE Trans Mobile Comput, 2025, 24: 6945–6960

28 Chen X, Meng T, Li Z, et al. FedHRA: a joint optimization framework for fast convergent decentralized federated learning in LEO satellite networks. IEEE Trans Mobile Comput, 2026, 25: 1–14

29 Cheng L, Feng G, Qin S, et al. Scheduling model transmission and training for contact-based decentralized satellite federated learning. IEEE Trans Cogn Commun Netw, 2026, 12: 1211–1226

30 Li R, Zhu J, Mao Y, et al. Topology-aware routing for federated learning over multi-layer satellite networks. In: Proceedings of the 2025 IEEE Wireless Communications and Networking Conference (WCNC), 2025. 1–6

31 Yin B, Chen Z, Tao M. Predictive GAN-powered multi-objective optimization for hybrid federated split learning. IEEE Trans Commun, 2023, 71: 4544–4560

32 Zhao K, Yang Z, Hu Y, et al. Efficient split federated learning for large language models over communication networks. ArXiv:2504.14667

33 Zhu Y, Zhu J, Wang T, et al. Satellite federated fine-tuning for foundation models in space computing power networks. IEEE Trans Wireless Commun, 2026, 25: 6600–6616

34 Nguyen L X, Yoon J S, Le H Q, et al. A vision of agentic AI for federated learning framework: workflows, system design and challenges. TechRxiv, 2025, doi: 10.36227/techrxiv.176620836.66064840/v1

35 Li H, Wang J, Funk M, et al. Position: agentic federated learning for AI-driven strategy design and optimization. In: Proceedings of ICML 2025 Workshop on Collaborative and Federated Agentic Workflows, 2025

36 Jarczewski R O, Talasso G U, Villas L, et al. Agentic federated learning: the future of distributed training orchestration. In: Proceedings of ICLR Workshop AI Mechanism Design Strategic Decision Making, 2026

37 Kosmidis L, Rodriguez I, Jover Á, et al. GPU4S: embedded GPUs in space-latest project updates. Microprocessors MicroSyst, 2020, 77: 103143

38 之江实验室. 一箭十二星! 太空计算卫星星座成功发射. 2025. https://www.zhejianglab.org/lab/post/3617?pid=3

39 NVIDIA. How StarCloud is bringing data centers to outer space. 2025. https://blogs.nvidia.com/blog/starcloud/

40 Zhang S, Wu W, Li L, et al. Communication-efficient collaborative LLM inference over LEO satellite networks. ArXiv:2604.04654

41 Yao S, Lin Y, Wang M, et al. LEOEdge: a satellite-ground cooperation platform for the AI inference in large LEO constellation. IEEE J Sel Areas Commun, 2025, 43: 36–50

42 Yuan H, Wang Z, Jiang Y, et al. SAI: latency-aware satellite edge LAM inference with looped transformer. In: Proceedings of the ICC 2025-IEEE International Conference on Communications, 2025. 2472–2477

43 Qin X, Ma T, Zhang X, et al. Ultra-dense LEO-MEO constellation integrated 6G: a distributed hierarchical mobility management approach. IEEE Trans Wireless Commun, 2024, 24: 323–339

44 Chhabra A, Datta S, Nahin S K, et al. Agentic AI security: threats, defenses, evaluation, and open challenges. IEEE Access, 2026, 14: 49455–49482

45 Zeng L, Wang Z X, Shi Y M, et al. Service function chain routing in LEO networks using shortest-path delay statistical stability. In: Proceedings of IEEE Wireless Commun Netw Conf (WCNC), 2026

46 Yu Z, Jiang Y, Liu X, et al. Microservice deployment in space computing power networks via robust reinforcement learning. IEEE Trans Mobile Comput, 2026, 25: 2382–2398

47 ETSI. Network functions virtualisation (NFV) release 4; management and orchestration; architectural framework specification. Technical Report ETSI GS NFV 006 V4.4.1, European Telecommunications Standards Institute. 2022. https://www.etsi.org/deliver/etsi_gs/NFV/001_099/006/04.04.01_60/gs_NFV006v040401p.pdf

48 CCSDS. Mission operations message abstraction layer. Technical Report CCSDS 521.0-B-3, Consultative Committee for Space Data Systems. 2024. https://ccsds.org/Pubs/521x0b3.pdf

49 Xu J, Luo J L, Cao X B, et al. Cooperative task scheduling and resource allocation of embodied multi-satellite systems: AI-driven perspective. Sci China Technol Sci, 2026, 69: 1100301

50 Shi J H, Zhang X D, Yang M, et al. Thermal management technologies for space data centers: current status and prospects. J Refrig, 2026, 47: 1–19 [史佳豪, 张旭东, 杨敏, 等. 太空数据中心热控技术研究现状与展望. 制冷学报, 2026, 47: 1–19]

51 Zhu J, Shi Y, Zhou Y, et al. Hierarchical learning and computing over space-ground integrated networks. IEEE Trans Mobile Comput, 2025, 24: 10423–10440

52 Zeng L, Zhu J, Wang Z, et al. Unseen cost of space computing: quantifying LEO battery aging via physics-driven modeling. ArXiv:2603.04372

53 Zhang W, Yao P, Gao B, et al. Edge learning using a fully integrated neuro-inspired memristor chip. Science, 2023, 381: 1205–1211

54 Liu X, Hong D, Chanussot J, et al. Modality translation in remote sensing time series. IEEE Trans Geosci Remote Sens, 2022, 60: 1–14

55 Ang Y, Bao Y, Jiang L, et al. Structured agentic workflows for financial time-series modelling with LLMs and reflective feedback. In: Proceedings of the 6th ACM International Conference on AI in Finance, 2025. 924–932

56 Zhou Y, Wang T, Wu Y, et al. Generative and large AI models for 6G wireless networks: the optimization perspective. Engineering, 2026, 63: 278–286

57 Huang C, Tang Z, Hu S, et al. ORLM: a customizable framework in training large models for automated optimization modeling. Operations Res, 2025, 73: 2986–3009

58 Jiang C, Shu X, Qian H, et al. LLMOPT: learning to define and solve general optimization problems from scratch. In: Proceedings of International Conference on Learning Representations (ICLR), 2025

59 Chen H, Wang Y, Cai Y, et al. HeuriGym: an agentic benchmark for LLM-crafted heuristics in combinatorial optimization. In: Proceedings of the 14th International Conference on Learning Representations (ICLR), 2026

60 Salim A. Accelerating mathematical research with language models: a case study of an interaction with GPT-5-Pro on a convex analysis problem. 2025. ArXiv:2510.26647

61 Ansys. Ansys STK: Digital mission engineering software. 2026. https://www.ansys.com/products/missions/ansys-stk

62 ns-3 Project. What is ns-3? 2026. https://www.nsnam.org/about/

63 Gao Y, Qiu K, Chen Z, et al. Plotinus: a satellite internet digital twin system. J Commun Inf Netw, 2024, 9: 24–33

64 ShipItAndPray. Orbital compute simulator: simulate and schedule GPU compute jobs across satellite constellations. 2026. https://github.com/ShipItAndPray/orbital-compute

Satellite edge artificial intelligence with agents: architectures and technologies

Yuanming SHI[1], Jingyang ZHU[1*], Yong ZHOU[1], Ting WANG[2] & Chunxiao JIANG[3]

1. *School of Information Science and Technology, ShanghaiTech University, Shanghai 201210, China*
2. *Software Engineering Institute, East China Normal University, Shanghai 200062, China*
3. *Beijing National Research Center for Information Science and Technology, Tsinghua University, Beijing 100084, China*
* Corresponding author. E-mail: zhujy2@shanghaitech.edu.cn

Abstract With the development of space computing networks, satellite edge artificial intelligence (AI), in which satellites serve as edge nodes, is undergoing a profound paradigm shift from "sensing in space and computing on the ground" to "sensing and computing in space". However, the time-varying topology, limited energy supply, heterogeneous distribution of computing resources, and complex computing environment affected by space particle radiation make conventional computing architectures designed for static scenarios inadequate for the efficient coordination of on-board training and inference. To address these challenges, this paper proposes an agent-driven hierarchical satellite edge collaborative computing architecture. Built upon the communication and computing resources provided by space computing networks, the proposed architecture introduces an agent mechanism that enables satellite nodes to perceive environmental states, plan and execute tasks, and adjust their actions through feedback according to task requirements and environmental conditions. For distributed on-board model training, we design a hierarchical agent-driven satellite federated learning mechanism and employ a time-window- and aggregation-aware directed minimum spanning tree routing algorithm to alleviate the communication bottleneck in space–ground collaborative distributed model training. For inter-satellite collaborative inference, we propose an agent-driven satellite edge inference architecture. By integrating network function virtualization with microservice concepts, we construct a service-function-chain-based inter-satellite collaborative inference mechanism and employ multi-agent reinforcement learning to support the real-time routing and dynamic orchestration of complex inference tasks. The proposed architecture extends static processing pipelines into closed-loop task flows that can be adjusted according to task states, thereby providing a general framework for heterogeneous resource coordination and complex task collaboration in dynamic satellite networks.

Keywords space computing networks, agentic artificial intelligence, satellite federated learning, satellite edge inference