

面向LEO Walker星座的AI预测驱动分层协同QoS保障机制

李 毅, 乔艳珍, 周康燕, 刘立浩, 及志远, 赵 鸿

(中国星网网络系统研究院有限公司, 北京 100001)

摘 要: 为提升LEO Walker星座的QoS保障能力, 提出一种AI预测驱动分层协同QoS保障架构。该架构通过地面智能控制中心内置的融合AI引擎预测链路质量与业务需求, 利用深度强化学习优化全局QoS与动态网络切片, 并在卫星节点部署轻量级智能代理执行本地QoS保障。同时阐述系统架构、关键AI模型、深度强化学习优化、动态网络切片管理及分层协同控制。仿真结果表明该架构在时延、抖动、数据包传递率、资源利用率等性能上有显著提升。

关键词: Walker星座; 服务质量; 人工智能预测; 动态网络切片; 分层协同控制

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025041

AI-Predicted Driven Hierarchically-Coordinated QoS Guarantee Mechanism for LEO Walker Constellation

LI Yi, QIAO Yanzhen, Zhou Kangyan, LIU Lihao, JI Zhiyuan, ZHAO Hong

China Satellite Network System Co.,Ltd., Beijing 100001, China

Abstract: This paper proposes an AI-predicted driven hierarchically-coordinated QoS (AIP-HC-QoS) architecture for LEO Walker constellation. The architecture employs an AI engine in the ground intelligence and control center (GICC) for link quality and service demand prediction, while deep reinforcement learning optimizes global QoS and dynamic network slicing. Lightweight intelligent agents are deployed on satellite nodes for local QoS execution. This paper details the system architecture, key AI models, DRL optimization, dynamic network slicing management, and hierarchical coordination control. Simulations results indicate significant improvements in delay, jitter, PDR, resource utilization, etc.

Keywords: Walker constellation, QoS, AI prediction, dynamic network slicing, hierarchical coordinated control

0 引言

随着全球数字化转型的加速和万物智联时代的临近, 低地球轨道 (low earth orbit, LEO) 卫星星座凭借其低传播时延、高带宽潜力和广域无缝覆盖, 已成为构建6G及未来全球通信网络的关键组成部分^[1-2]。以Starlink、OneWeb为代表的巨型LEO星座多采用Walker构型^[3], 旨在提供高速互联网接入, 并支持自动驾驶、扩展现实(XR)、全球物联网(IoT)等新兴应用场景^[4-5]。然而, LEO卫星的高速运动 (约7.8 km/s) 也导致网络拓扑剧烈变化, 星间链路 (inter-satellite link, ISL) 和星地链路 (satellite-ground link, SGL) 频繁进行切换, 且信号传播

特性多变, 对网络控制和资源管理带来极高复杂性。地面业务需求的时空不均衡性和突发性, 使得传统静态QoS保障机制难以应对^[6-7]。因此, 在资源受限且极端动态的LEO Walker星座网络中, 为异构业务提供稳定、可靠且满足其差异化需求的QoS机制, 已成为亟待解决的核心问题。

现有LEO网络QoS研究通常借鉴地面经验, 如采用软件定义网络 (software defined networking, SDN) 提升可编程性, 或初步探索AI在链路及流量预测及资源分配中的应用^[8]。网络切片作为5G/6G关键技术之一, 被认为是满足LEO网络差异化业务需求的有效手段^[9]。分层控制架构则被视为管理大规模复杂网络的可行途径^[10]。然

而, 这些研究多聚焦于单一技术或通用场景, 缺乏针对LEO Walker星座特性(如轨道动力学、周期性拓扑变化、缝隙效应等)、深度融合多种AI技术、并能实现从高精度预测到前瞻性资源编排及智能化协同控制的整体性QoS保障框架。

为弥补此空白, 本文提出AIP-HC-QoS (AI predicted-hierarchically coordinated-QoS) 架构。其核心是通过AI驱动的预测洞察网络未来状态, 结合预测驱动的动态网络切片为差异化业务提供隔离且自适应的虚拟资源, 并通过精细化的分层协同控制实现全局优化与本地快速响应的平衡。

1 国内外研究现状

LEO星座QoS保障面临的首要挑战是其极端动态性^[6]。卫星高速移动使ISL和SGL拓扑秒级变化, 从而导致链路参数值剧烈波动。传统QoS保障机制如优先级队列和流量工程, 因缺乏全局实时感知和未来准确预测能力, 在LEO网络中应用性能不佳^[7]。SDN通过将控制平面与数据平面分离, 提供全局视图与集中决策, 但当其应用于巨型星座时面临信令开销大、控制时延高、单点故障等问题, 且多依赖于当前或历史状态, 缺乏前瞻性。商业LEO星座如Starlink和OneWeb已实现大规模运营, 采用复杂自适应资源管理系统应对动态性^[3]。这些系统在QoS保障机制的精细化、预测性和主动性方面仍面临优化压力。

AI/ML技术被广泛认为是提升卫星网络智能化的关键^[8-11]。在链路质量预测方面, LSTM、GRU等模型已被用于预测信道状态^[12], 但对于LEO Walker星座来说, 多维QoS参数综合、中长期精准预测, 并深度融合轨道动力学特性仍是难题^[13]。业务流量预测也采用类似模型^[14], 但需更精细地预测业务类型构成、特定QoS需求及时空分布, 并深度融合主动资源分配策略。深度强化学习(deep reinforcement learning, DRL)在卫星网络资源管理和路由优化中展现出巨大潜力^[15-16], 但其缺乏集成多维度AI预测、动态网络切片、分层协同控制的全局QoS保障框架。

网络切片技术允许在共享物理设施上创建隔离、定制化的虚拟网络, 是满足6G多样化业务需求的关键^[9-17], 同时, 其在LEO网络的应用潜力已获关注^[18], AI/DRL也被提议用于切片智能管理^[19]。然而, 将网络切片应用于LEO Walker星座, 要求切片管理具备高度的灵活性、快速性和预测性, 以适应业务热点“漂移”和频繁切换

的QoS连续性与隔离性保障, 但目前缺乏针对性的成熟机制。

分层协同控制架构被认为是管理大规模复杂网络的有效方案^[10]。地面控制中心负责全局战略, 星上代理负责本地快速响应。星上AI需轻量化, 联邦学习(FL)^[20]和模型压缩^[21]均是热门方向。尽管有理论基础, 但如何针对QoS保障机制设计功能划分合理、智能分布高效、信令开销可控, 并与AI预测、动态网络切片深度融合的分层协同系统, 仍是一个关键问题。

综上, 现有研究在Walker星座特性深度优化、AI预测能力与应用系统性、动态网络切片机制成熟度、分层协同控制与星上智能精细化设计等方面存在不足, 且缺乏与关键要素的深度耦合及协同增强。本文提出的AIP-HC-QoS架构旨在构建以AI精准预测为核心驱动, 以预测驱动动态网络切片为关键资源管理手段, 以优化分层协同控制为智能化执行框架的综合QoS保障体系, 以填补上述空白。

2 AIP-HC-QoS: 系统架构与核心机制

本节将详细阐述AIP-HC-QoS保障系统的架构设计、关键技术模块及其核心工作机制。该系统旨在将地面智能控制中心(ground intelligent control center, GICC)的全局智能与卫星节点智能代理(satellite node intelligent agent, SNIA)的本地智能相结合, 实现从精准预测到智能决策再到高效执行的闭环QoS控制。

2.1 系统整体架构

AIP-HC-QoS系统采用典型的3层协同控制架构, 如图1所示。

2.1.1 地面智能控制中心

定位: 整个系统的“智能大脑”, 部署于地面运控中心或云数据中心。

核心功能如下。

(1) 全局状态感知与数据融合: 汇聚全网多源异构数据, 构建全局动态网络视图。

(2) AI预测引擎: 运行复杂高精度AI模型, 实现中长期网络链路质量与业务需求预测。

(3) 全局QoS策略与资源优化: 基于AI预测及运营商策略, 利用DRL等优化全局QoS策略、动态网络切片管理方案、主动路由与拥塞控制规则。

(4) 知识库与AI模型管理: 存储管理QoS策略库、AI模型库、训练数据等, 负责模型持续训练、更新迭代。

(5) 策略分发与协同接口: 将全局策略、配置参数、




图1 系统整体架构

控制指令等分发给下一级节点。

2.1.2 区域/簇协同节点

定位：在超大规模星座中部署，可降低GICC控制复杂度与时延，由地面区域控制站或特定高能力卫星承担。

核心功能如下。

(1) 区域状态汇聚与预处理：汇聚管辖区域内的SNIA状态信息摘要。

(2) 区域策略细化与执行：接收GICC宏观策略，并结合本区域动态和短期预测进行细化适配，指导SNIA执行。

(3) 区域内快速QoS协同与资源调度：负责区域内快速QoS协同和资源微调。

(4) 信息中继与上报：向GICC上报区域运行状态、策略执行效果以及重大异常。

2.1.3 卫星节点智能代理

定位：部署在每颗（或关键）在轨卫星上的轻量级软硬件实体或纯软件代理，充分考虑星上资源限制。

核心功能如下。

(1) 本地状态监测与业务识别：实时高频率监测本节点资源及链路参数，通过轻量级深度包检测（deep packet inspection, DPI）或机器学习模型识别业务类型与

QoS需求。

(2) AI预测辅助与决策（轻量级）：运行区域/簇协同节点（regional/cluster coordination node, RCCN）下发的压缩/蒸馏^[21]或专门设计的轻量化预测模型（如小型LSTM/GRU）实现极短期预测；参与联邦学习^[20]，利用本地数据进行训练或微调模型，上传参数更新量，以保护隐私并减少开销。

(3) QoS策略执行与本地自适应调整：精准执行上级QoS指令（如队列参数、流量整形监管、路由转发、业务到切片映射）；在预设框架和参数范围内，根据本地实时状态和极短期预测实现快速自主QoS微调。

(4) 切换管理中的QoS连续性保障：在ISL/SGL切换时，保障业务QoS的连续性。

(5) 信息上报与反馈：向上级上报节点关键状态摘要、QoS策略执行效果、网络异常、AI预测准确性等信息。

2.2 AI预测引擎 (GICC内部)

AI预测引擎是AIP-HC-QoS系统的核心驱动力，为GICC决策提供精准、前瞻性的网络状态洞察，其包含链路质量预测和业务需求预测两大子模块，如图2所示。




图2 GICC内部AI预测引擎的详细结构

2.2.1 链路质量预测子模块

预测目标：对在未来特定时间窗口内星座网络中关键ISL及活动SGL的动态QoS参数实现多维度、高精度预测。

预测参数：动态可用带宽 (B_{avail_pred})、端到端/逐跳时延 (D_{pred})、时延抖动 (J_{pred})、链路可靠性指标 (BER, SNR, PLR, $P_{interrupt_pred}$)、链路可用时长 (T_{active_pred})。

输入特征：历史链路QoS时间序列数据、卫星轨道动力学参数（星历、姿态、天线指向，用于计算相对几何关系、ISL可见性、传播损耗，并体现Walker星座周期性拓扑变化）、空间环境参数（太阳活动、地磁活动、电离层闪烁指数）^[22]、卫星自身状态参数（能源、计算负载）。

模型选择与结构如下。

(1) 单链路/少量链路时序预测：采用LSTM或GRU^[12]。GRU单元核心方程如下。

$$\text{重置门: } r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r)$$

$$\text{更新门: } z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z)$$

$$\text{候选隐藏状态: } \tilde{h}_t = \tanh(W_h \cdot [r_t \odot h_{t-1}, x_t] + b_h)$$

$$\text{最终隐藏状态: } h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t$$

其中， x_t 是当前输入， h_{t-1} 是前一时刻隐藏状态， W, b 是可训练参数， σ 是Sigmoid激活函数， $\odot$ 是逐元素乘积。

(2) 全网链路联合预测：采用时空图神经网络

(STGNN)^[13-14]。将星座建模为动态图 $G_t = (V, E_t, X_V^t, X_E^t)$ ，其中 V 是节点， E_t 是活动链路， X_V^t, X_E^t 是节点和边特征。STGNN通常包含空间卷积层（如GCN, GAT）、时间卷积/循环层（TCN, LSTM, GRU, Transformer）和输出预测层。

(3) Walker星座特性融入：在STGNN中，邻接关系 A_t 由轨道动力学确定。输入特征可包含下次切换剩余时间、链路几何仰角、缝隙区域影响等。训练数据覆盖不同运行阶段的链路变化模式。

2.2.2 业务需求预测子模块

预测目标：对在未来特定时间窗口内的各覆盖区域、用户群体或业务类型的业务需求实现多维度、高精度预测。

预测参数：总流量需求 (Vol_{pred})、业务类型构成 (Mix_{pred})、并发用户/连接数 (Con_{pred})、关键QoS参数需求 (QoS_{req_pred})、业务需求的时空动态漂移趋势。

输入特征：历史业务数据、用户行为模式、地理空间特征、时间特征（小时、节假日、未来事件）、卫星覆盖动态参数（波束地面覆盖轨迹、时长）。

模型选择与结构如下。

(1) 特定区域/固定波束时序预测：LSTM/GRU。

(2) 时空关联性强的业务需求：STGNN^[14]。将地面覆盖区域划分为网格单元作为图节点，地理邻近或用户

移动表示边。STGNN能够学习业务需求空间扩散/聚集和时间演化,并结合卫星覆盖动态预测各单元业务需求,如业务从卫星A覆盖区“迁移”到卫星B覆盖区。

(3) 可选择结合注意力机制的深度学习模型,捕捉不同输入特征的动态影响权重或长距离时空依赖。

2.3 DRL 驱动的全局 QoS 策略与资源优化 (GICC 内部)

GICC的核心决策能力由基于深度强化学习的优化框架提供^[15-16],根据AI预测的网络状态和业务需求,并结合运营策略和用户服务协议(service level agreement, SLA),实现动态优化全局QoS策略和网络资源分配,特别是动态网络切片管理。

马尔可夫决策过程(markov decision process, MDP)建模如下。

(1) 智能体 (Agent): GICC内部的“全局QoS策略与资源优化模块”。

(2) 状态 (S_t): 于决策时刻 t 观测到的系统状态,包含当前网络拓扑 G_t 、AI预测的未来链路质量 L_{ij}^t 、AI预测的未来业务需求 D_k^t 、当前网络切片配置与性能、全网可用网络资源状态。

(3) 动作 (A_t): 智能体在状态 S_t 下的决策,为复合动作空间,包括如下几个部分。

- 动态网络切片管理操作 (A_{slice}): CreateSlice(SliceSpec)、ModifySlice(SliceID, ModifyParams)、TerminateSlice(SliceID)。

- 主动路由策略调整操作 (A_{route}): UpdateRoutingPolicy(PolicyParams)。

- 拥塞控制参数配置操作 ($A_{\text{congestion}}$): SetAQMPParams(NodeID, QueueID, AQMConfig)、SetDiffServPolicy(PolicyConfig)。

(4) 奖励 (R_t): 标量奖励信号,用于指导学习方向,旨在最大化长期累积回报。复合奖励函数通过以下公式平衡多目标:

$$R_t = \sum_{s \in \text{ActiveSlices}} w_{\text{sla}} \cdot f_{\text{SLA_Compliance}}(s_t) + w_{\text{util}} \cdot \text{OverallNetworkResourceUtilization}_t - w_{\text{reconfig}} \cdot \text{ReconfigurationFrequencyCost}_t - \sum_{s \in \text{ActiveSlices}} w_{\text{penalty}} \cdot g_{\text{SLA_ViolationSeverity}}(s_t) - w_{\text{cong}} \cdot \text{GlobalCongestionLevel}_t$$

其中 w 为权重因子, $f(\cdot)$ 和 $g(\cdot)$ 分别为量化SLA符合度和违约严重性的函数。

DRL 算法选择: 考虑状态和动作空间的复杂性,可采用 Actor-Critic 类 (A2C、A3C)、改进策略梯度 (PPO)、处理连续动作空间 (DDPG、TD3) 或大规模离

散/混合动作空间 (参数化动作空间、分层 RL) 的算法^[15]。智能体通过与高保真仿真环境交互,并更新策略网络和价值网络,学习近似最优策略 $\pi^*(A_t|S_t)$ 。

2.4 预测驱动的动态网络切片管理

动态网络切片管理是实现差异化服务保障和高效资源利用的核心,其生命周期由AI预测和DRL优化共同驱动^[9-19],如图3所示。




图3 动态网络切片管理流程图

基于预测的前瞻性切片规划与创建: 当AI预测到未来显著需求增长时, DRL 决策将提前创建相应切片, 规划初始资源 (卫星节点、ISL/SGL 路径、带宽池、队列优先级、处理资源)。

运行中的动态自适应调整与迁移如下。

(1) 弹性资源伸缩: GICC 持续监控切片占用率及 QoS 性能, 结合 AI 短期/中期预测, 通过 DRL 决策动态调整资源分配 (增/减带宽)。

(2) 服务区域的预测性迁移: 当 AI 预测用户群体将漂移出当前覆盖范围时, 提前启动迁移。DRL 在下一覆盖卫星上为切片预实例化资源, 通过切换管理机制联动, 将业务平滑迁移至新卫星, 保障服务连续性。

(3) QoS 保障等级动态调整: 当网络资源极度紧张

或拥塞时，DRL根据策略和AI预测，临时有区别地调整非关键切片/业务QoS等级，优先保障高优先级切片的服务质量。

基于性能与预测的切片终止：当服务周期结束、AI预测无业务需求或切片持续无法满足SLA时，DRL决策终止切片并回收资源。

严格的QoS隔离保障：通过SNIA层面精细化队列管理、流量调度和虚拟化资源隔离技术，确保切片间QoS不受影响，保障服务质量。

2.5 分层协同控制与SNIA操作的精细化

分层协同控制机制旨在发挥GICC全局智能和SNIA本地快速响应的能力，兼顾星上资源限制^[10]。

GICC的战略决策与复杂运算：运行计算密集型AI预测和DRL优化，进行长周期战略规划、全局资源优化和复杂策略制定；负责AI模型训练及更新维护；向下级下发宏观控制指令、策略框架、参数范围和轻量化AI模型/规则。

RCCN的区域战术协同：在GICC指导下，负责中短期区域性战术协同；可运行中等复杂度AI模型以进行本地化适配细化；聚合过滤区域SNIA信息，减少GICC负担。

SNIA的本地执行与轻量化智能如下。

(1) 高效QoS策略执行：精准且低时延地执行上级指令（包分类、队列调度参数、流量整形监管和路由转发）。

(2) 轻量化AI模型/规则集实现与应用：GICC通过模型压缩（剪枝、量化INT8/INT4）、知识蒸馏等方式将复杂AI模型转化为轻量版下发SNIA^[21]，或生成基于规则的专家系统。目标计算复杂度1~10 MFLOPS，RAM < 1~5 MB，决策时延 < 1~10 ms。用于极短期本地链路质量趋势预测、业务突发检测、辅助本地快速自适应决策（如在预设备份路径中选择最优）。

(3) 联邦学习深度参与：SNIA作为客户端，利用本地数据更新全局模型参数（上传梯度或权重变化），保护隐私并减少通信开销，提升模型个性化和鲁棒性^[20]。

(4) 授权范围内的快速自适应调整：GICC设定SNIA可自主调整权限。SNIA可根据本地监测和预测，在授权范围内微调队列权重或自主选择备用路径，实现快速故障规避和QoS恢复。

(5) 标准化的信息上报与反馈：按定义格式和周期，摘要化、结构化地上报本地状态、执行效果、异常事件、预测准确性评估给上级，作为闭环优化依据。

2.6 面向Walker星座频繁切换的预测性QoS连续性保障

在LEO Walker星座中，ISL和SGL之间的切换是常

态，其会影响业务连续性和QoS。AIP-HC-QoS通过预测性机制保障切换过程中的QoS，如图4所示。




图4 GICC-SNIA在关键事件期间的信令交互图

基于轨道动力学与AI预测的切换事件预判：GICC的AI预测引擎结合轨道动力学和历史数据，可提前精准预测计划内切换的发生时间、涉及节点及切换目标链路的预期QoS。对于计划外切换，可根据链路质量监测和短期恶化趋势预测并给出风险预警。

提前的跨星/跨链路资源预协商与预留：GICC实现切换预判后，指导源SNIA（或GICC直接）与切换目标对端节点提前发起资源协商，为活动切片和重要业务流在新目标链路上预留所需资源（包括带宽、队列、处理资源）。目标节点的SNIA/控制器响应并确认资源预留。

平滑的业务流量迁移调度与路径预配置：资源预留成功后，GICC规划详细迁移方案，由SNIA执行。

(1) “先连接后断开”：条件允许时，断开旧链路前先建立新链路，使业务逐步平滑迁移，实现“零中断”或“准零中断”切换。

(2) 快速路径重定向/更新：切换执行时刻，SNIA快速更新转发表/流表，将数据包重定向到新路径。

(3) 数据包缓存与前传/重传优化：在切换临界阶段，源SNIA可短暂缓存数据包，待新链路稳定后快速发送。关键数据包可选择性快速重传，对时延极敏感的业务可考虑冗余发送。

(4) SNIA在切换执行中的本地智能辅助：SNIA密切监测切换过程中新旧链路的瞬时QoS。若新链路实际质量与预测偏差大，SNIA可在授权内执行应急预案（如切换到其他备用链路、调整流量调度），并立即上报GICC。

通过上述机制，AIP-HC-QoS旨在将切换过程导致的

业务中断、数据丢失和QoS抖动降至最低,以提升用户体验和网络服务可靠性。

3 仿真实验设计与参数设置

为评估AIP-HC-QoS架构在复杂动态LEO Walker星座环境下的性能,本节将设计一套仿真实验方案。

3.1 仿真目标

(1) 综合QoS性能评估: 定量评估改善端到端业务QoS(平均时延、抖动、数据包传递率(packet delivery ratio, PDR)、吞吐量)方面的能力。

(2) 资源利用效率验证: 考察提升网络资源(ISL/SGL带宽)利用效率方面的效果。

(3) 动态网络切片机制有效性检验: 验证保障差异化QoS、实现切片隔离及自适应调整资源方面的能力。

(4) 切换性能优化评估: 评估预测性切换管理在降低切换过程中业务中断、丢包和QoS抖动方面的成效。

(5) 系统鲁棒性与可扩展性分析: 在不同负载、链路质量波动、星座规模场景下,分析性能的稳定性和适应能力。

(6) 与基准算法性能对比: 在时延、PDR、资源利用率等关键指标上进行性能对比,以凸显AIP-HC-QoS的创新性与优越性。

3.2 仿真环境与关键参数设置

仿真平台选择: 采用NS-3及其卫星网络扩展模块构建基于Python的离散事件仿真平台,以灵活集成AI/ML/DRL库。该平台需精确模拟轨道动力学、动态拓扑、链路特性(路径损耗、多普勒、天线指向、大气衰减、雨衰等)^[22]、数据包传输与处理工程。

3.2.1 LEO Walker星座模型参数

(1) 构型: 代表性的大规模Walker Delta构型,如卫星总数 $N_{\text{sat}}=288$ 颗(可扩展至500~1 000颗),轨道平面数 $N_{\text{plane}}=12$ 个,每轨道面卫星数 $N_{\text{sat_per_plane}}=24$ 颗,轨道高度=550 km,轨道倾角=53°。

(2) ISL: 每颗卫星配备4条链路(前、后、左、右),精确模拟链路建立/断开逻辑。激光ISL,单链路最大容量为10 Gbit/s,可用带宽根据AI预测动态变化。需考虑自由空间损耗。

(3) SGL: 用户链路(Ka/Ku频段)、馈电链路(Ka或Q/V频段)。若干地面关口站、大量用户终端。需考虑路径损耗、天线增益、大气吸收、云衰减、雨衰等。

3.2.2 业务流量模型与网络切片配置

模拟3类典型业务及对应切片如下。

(1) eMBB切片: 高清视频、XR业务。泊松/自相似到达,包较大(1 000~1 500 B),带宽敏感,容忍时延(50~100 ms)。QoS目标示例: 每用户保证带宽>20 Mbit/s/,峰值100 Mbit/s/用户,平均时延<80 ms,丢包率<10⁻³。

(2) uRLLC切片: 远程操控、工业自动化业务。包较小(100~500 B),周期性或突发,对时延(<10ms端到端)和可靠性(PDR>99.999%)要求苛刻。QoS目标示例: 端到端时延<15 ms,抖动<2 ms, PDR>99.9995%。

(3) mMTC切片: 大规模IoT业务。海量连接,包极小(几十到几百字节),间歇性,对时延不敏感(秒/分钟级),要求高连接成功率和聚合数据可靠性。QoS目标示例: 连接成功率>99.5%,聚合丢包率<1%,连接密度>1 000设备/km²(等效)。

业务请求生成: 根据地理分布(城市eMBB/uRLLC多,偏远/行业mMTC多)和时间变化(忙闲时、突发事件)动态生成。

网络切片实例化: 仿真开始或根据GICC决策创建切片,并动态分配调整资源。

3.2.3 AI模型与DRL智能体的仿真实现

AI预测模型: 利用简化网络模型生成合成数据,离线预训练初始LSTM/GRU/STGNN模型。仿真过程中周期性利用新数据进行在线增量学习或微调。

DRL智能体: 将仿真器作为DRL环境。高维状态编码为输入向量,对复杂动作编码解码。精确实现奖励函数,并调整权重。训练初始探索,后期转向利用。

SNIA轻量化AI: 简化模拟,如基于GICC下发规则或短期趋势因子决策,或实现小型预训练决策树或浅层神经网络模型在SNIA上运行。模拟联邦学习核心过程: 本地“伪训练”,上传“参数更新”,GICC“伪聚合”,下发“更新后参数”以影响本地决策阈值/权重。

3.3 性能评估指标

端到端业务QoS指标(区分切片/业务统计): 平均端到端时延、时延抖动、数据包传递率、吞吐量。

网络资源利用效率: 平均链路带宽利用率、频谱效率。

网络切片性能: SLA满足率、切片间隔度(一个切片负载变化对其他切片QoS影响程度)、切片建立/调整时间。

链路切换性能: 平均切换中断时间、切换期间数据包丢失率、切换引起的额外时延。

系统控制开销与复杂度(定性评估): 控制信令开

销、计算复杂度 (GICC AI/DRL, SNIA 轻量 AI)、DRL 收敛性与稳定性。

3.4 基准算法

基准算法1：静态QoS + 最短路径路由 (SQ-SP)：采用静态优先级队列，路由基于跳数最少或传播时延最短 (如Dijkstra) 选择，不考虑动态负载、预测或特定QoS需求，且无网络切片。该算法作为性能下限参考。

基准算法2：SDN反应式QoS + 动态最短路径 (SDN-RDP)：GICC/SDN控制器周期性收集实时链路状态，动态重算最短路径 (可考虑负载为权重) 并更新转发表。QoS区分依赖静态优先级队列实现。该算法为被动响应式，缺乏预测能力。代表基于SDN的反应式QoS调整思路。

基准算法3：AI预测辅助的路由优化 (APR)：GICC AI预测链路质量和业务负载，仅将结果用于优化路由决策 (选择未来预测质量佳且满足需求的路径)。无动态切片、精细化分层协同和SNIA本地智能。QoS区分依赖优先级队列实现。该算法可用于评估AI预测单独用于路由优化的性能。

基准算法4：静态网络切片 + 预测路由 (SNS-PR)：网络资源根据长期平均需求预估，并将其静态划分给切片。切片内路由可利用AI预测链路质量，切片资源不动态调整。该算法用于评估静态切片基础能力，与AIP-HC-QoS动态切片形成对比。

4 仿真结果与分析

本节基于AIP-HC-QoS设计原理和仿真结果对性能进行分析，并与基准算法进行对比。

4.1 端到端业务QoS性能

各方案下的uRLLC切片性能对比如图5~图6所示。




图5 uRLLC业务端到端时延的累积分布概率




图6 各方案下uRLLC业务平均PDR

uRLLC切片性能 (时延、抖动、PDR)：AIP-HC-QoS下uRLLC切片时延和抖动显著低于所有基准算法。SQ-SP和SDN-RDP因缺特殊保障和预测，时延和抖动较大且PDR难以保证；APR虽有预测路由，但因无切片隔离和资源预留性能受限，SNS-PR若静态资源不足或路径不当，其性能也会受限。

各方案下的eMBB切片性能对比如图7~图8所示。




图7 各方案下eMBB切片平均用户吞吐量




图8 各方案下eMBB切片平均端到端时延

eMBB切片性能（吞吐量、时延）：在保障uRLLC的前提下，AIP-HC-QoS的eMBB切片获得较高平均用户吞吐量和可接受平均时延。

4.2 网络资源利用效率

各方案下网络平均带宽利用率如图9所示。




图9 各方案下网络平均带宽利用率

结果表明，AIP-HC-QoS算法的全网平均链路带宽利用率预计显著高于SQ-SP、SDN-RDP和SNS-PR，略高于或持平APR。

4.3 网络切片性能与隔离度

uRLLC切片平均时延变化情况如图10所示。




图10 uRLLC切片平均时延随eMBB切片负载变化

SLA满足率：AIP-HC-QoS下的所有切片SLA满足率显著高于对比基准算法。这是因为AI预测、DRL优化和动态切片的协同作用。

切片间隔离度：AIP-HC-QoS确保uRLLC和mMTC切片的QoS几乎不受eMBB切片负载剧增影响。其中SNIA队列管理和GICC资源边界优化是实现这一目标的关键。

4.4 系统控制开销与复杂度

定性分析表明，分层架构和SNIA轻量化设计可有效平衡开销与性能：GICC负责集中复杂运算，SNIA负责本地快速响应，结合可控的信令交互设计有助于降低整体开销。与完全集中或完全分布式架构相比，该架构可实现更优的复杂度-效益平衡。

5 深入分析与未来展望

AIP-HC-QoS架构在理论设计和仿真性能上展现出创新性与优越性，为LEO Walker星座QoS保障提供前景方案。本节将探讨其关键特性、挑战与局限，并展望未来方向。

5.1 挑战与局限性

5.1.1 AI模型的复杂性、准确性与泛化能力

(1) 数据依赖与冷启动：AI模型训练需海量的高质量数据，星座初始阶段或环境突变时会面临数据不足问题^[8-11]。

(2) 预测精度与鲁棒性：LEO极端动态性、空间环境复杂性、用户业务不确定性对AI模型精度和泛化能力构成考验。

(3) 计算复杂度与实时性：大规模STGNN和DRL训练推理需消耗巨大计算资源，并对决策实时性有较高要求。

(4) 模型可解释性与可信度：深度学习模型“黑箱”特性影响其在关键QoS任务中的接受度。

5.1.2 SNIA轻量化、能力与协同的权衡

(1) 功能-性能-资源约束平衡：轻量化AI可能牺牲模型精度或能力，需在功能、性能与星上资源间寻求平衡^[21]。

(2) 星上模型更新与维护开销：需建立高效、低开销、安全的星上模型/规则更新管理机制。

(3) 联邦学习实际部署挑战：面临星地/星间链路带宽受限、时延波动、链路不稳定，以及星上计算异构性、Non-IID数据等问题^[20-23]。

5.1.3 分层协同控制的信令开销、决策时延与状态一致性

(1) 控制信令开销与网络负载：层级间信息交互产生信令开销，需设计高效信息聚合、过滤、增量更新机制。

(2) 端到端控制回路时延：GICC全局决策回路存在固有传播时延、排队时延和处理时延，需优化以应对突发事件。

(3) 多层次状态一致性与决策协同：信息交互时延可能导致状态不一致和决策冲突，需研发鲁棒协同算法和状态同步机制。

5.1.4 系统整体的鲁棒性、容错能力与安全性

(1) 故障容错与自愈能力：需快速检测定位故障，自动隔离并智能重构网络和QoS保障机制。

(2) 安全性考量：AI模型面临对抗性攻击或数据投毒；控制信道需通过加密认证防攻击；网络切片需实现安全隔离以防攻击扩散。

5.2 未来研究方向

(1) 高保真仿真平台搭建与在轨验证：开发或利用高保真仿真平台进行精细建模与全面评估；利用真实卫星星座的开放接口，进行部分关键技术的在轨测试，以获取真实环境下的性能数据和反馈。。

(2) 可解释、可信与鲁棒的AI模型研究：引入XAI技术提升透明度和可信度；研究鲁棒性增强方法；探索AI模型安全加固技术^[11]。

(3) 能源感知型与可持续的QoS优化：将卫星能源状态和网络能效纳入QoS优化中，设计能源感知型AI模型和DRL奖励函数，以实现星座网络能耗最小化。

(4) 多星座、多层异构网络环境下的协同QoS保障：研究异构网络（GEO、MEO、LEO、HAPS、UAV）间的无缝切换、端到端QoS协同及跨域资源联合优化^[2-24]，探索统一QoS信令机制、跨域AI协同预测模型及超大规模DRL/多智能体系统的实现。

(5) 与地面移动网络（5G-Advanced/6G）的深度融合与端到端网络切片：研究LEO切片与地面5G/6G核心网控制面、用户面及MANO的深度融合与协同互操作；实现空天地一体化端到端网络切片的按需创建、动态配置、全生命周期管理和QoS协同；探索IBN理念应用。

(6) 基于数字孪生网络的智能运维与“What-if”分析：构建LEO星座数字孪生网络（DTN），实时映射物理网络状态，利用AIP-HC-QoS的AI预测和DRL优化能力驱动孪生网络行为模拟和未来推演；在DTN中进行“What-if”分析、策略验证、故障演练、网络演进规划，提升运营智能化和效率。

6 结束语

本文针对LEO Walker星座网络在QoS保障方面所面临的严峻挑战，提出了一种创新的AIP-HC-QoS动态QoS保障架构。该架构深度融合AI预测技术、基于预测的动态网络切片机制及精细化分层协同控制策略，旨在实现LEO网络资源的前瞻性规划、智能化调度和差异化业务的精细化QoS保障。

AIP-HC-QoS的关键创新点包括：GICC构建双重AI

预测引擎，利用LSTM/GRU和GNN/STGNN并融入轨道动力学，进行链路QoS与业务需求的高精度预测；提出基于DRL的预测驱动动态网络切片管理机制，实现切片生命周期最优管理与QoS隔离；设计“GICC - RCCN - SNIA”3层协同控制架构，平衡全局优化、本地响应与星上资源限制；集成面向Walker星座频繁切换的预测性QoS连续性保障方法，利用AI预判提前协商预留资源，平滑迁移业务。

本文详细阐述了AIP-HC-QoS的系统架构、核心技术模块工作原理和交互流程，并设计了全面的仿真实验方案。仿真结果表明，与传统及简化AI方案相比，本架构能在端到端时延、抖动、PDR、资源利用率、切片SLA满足率与隔离度及切换性能等关键性能维度取得显著提升。

综上，AIP-HC-QoS为未来大规模LEO Walker星座网络复杂动态的QoS保障需求提供了全面、智能且前瞻性的系统性解决方案。该研究深化了AI在卫星网络资源管理中的应用^[25]，为构建下一代高效、可靠、普惠的空天地一体化网络提供了重要技术支撑，具有重要学术价值和广阔应用前景。未来工作将聚焦于高保真仿真实现与验证及AI模型鲁棒性、系统安全性、能源效率等优化方面。

参考文献

- [1] 廖德山, 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.
- [2] MIAO D S, DENG L Y, SUN J C, et al. Terrestrial and satellite network integration based 6G system and its key technologies[J]. ZTE Technology Journal, 2024, 30(4): 42-49.
- [3] 陆航, 张佳鑫, 王海旭. 面向6G的低轨卫星通信系统移动性管理技术[J]. 天地一体化信息网络, 2025, 6(1): 35-44.
- [4] LU H, ZHANG J X, WANG H X. Mobility management technologies for 6G-oriented low earth orbit satellite communication systems[J]. Space-Integrated-Ground Information Networks, 2025, 6(1): 35-44.
- [5] 郝子慧, 刘敏, 齐戡, 等. Starlink卫星星座项目进展与未来前景分析[J]. 国际太空, 2025(4): 60-66.
- [6] HAO Z H, LIU M, QI Y, et al. Progress and future prospect analysis of Starlink satellite constellation project[J]. Space International, 2025(4): 60-66.
- [7] GIORDANI M, POLESE M, MEZZAVILLA M, et al. Toward 6G networks: use cases and technologies[J]. IEEE Communications

- Magazine, 2020, 58(3): 55-61.
- [5] DI B Y, SONG L Y, LI Y H, et al. Ultra-dense LEO: integration of satellite access networks into 5G and beyond[J]. IEEE Wireless Communications, 2019, 26(2): 62-69.
- [6] 王汝言, 叶显熠, 何鹏, 等. 面向非地面网络多QoS保障的低地球轨道卫星星座设计[J]. 通信学报, 2023, 44(12): 61-77.
- WANG R Y, YE X Y, HE P, et al. LEO satellite constellation design with multi-QoS guarantee for non-terrestrial network[J]. Journal on Communications, 2023, 44(12): 61-77.
- [7] AI-HARTHI Y, EL-KHAMY S E, EL-DOLIL S A. A survey on QoS-aware routing protocols for LEO satellite networks: challenges, architectures, and future directions[J]. IEEE Access, 2022, 10: 24870-24895.
- [8] PAPA A, BIRD J N, DOBRE O A. Machine learning for QoS management in LEO satellite constellations: a survey[J]. IEEE Access, 2022, 10: 100830-100858.
- [9] ALSENWI M, TRAN N H, BENNIS M, et al. Intelligent resource slicing for eMBB and uRLLC coexistence in 5G and beyond: a deep reinforcement learning based approach[J]. IEEE Transactions on Wireless Communications, 2021, 20(7): 4585-4600.
- [10] VERBRAEKEN J, WOLTING M, KATZY J, et al. A survey on distributed machine learning[J]. ACM Computing Surveys (CSUR), 2020, 53(2): 1-33.
- [11] GUIDOTTI A, VANELLI-CORALLI A, CHIANI M. Machine learning for satellite communications: a comprehensive survey[J]. IEEE Open Journal of the Communications Society, 2021, 2: 1799-1838.
- [12] WANG P, ZHANG J, CHEN S. LSTM-based channel prediction for LEO satellite communication systems[J]. IEEE Wireless Communications Letters, 2021, 10(5): 993-997.
- [13] LIU S, GAO Y, CHEN X. Spatio-temporal graph neural network for link availability prediction in LEO constellations[J]. IEEE Journal on Selected Areas in Communications, 2023, 41(5): 1450-1463.
- [14] WEI J, HE R, CHEN K, et al. DST-LEO: A dynamic spatio-temporal graph neural network for traffic prediction in LEO satellite constellations[C]//Proceedings of ACM MobiHoc. New York: ACM Press, 2022: 1-10.
- [15] GUO K, AN K, ZHANG B, et al. Deep reinforcement learning based routing for LEO satellite networks[J]. IEEE Transactions on Vehicular Technology, 2021, 70(11): 11738-11749.
- [16] CUI T, ZHANG X, DONG P, et al. Deep reinforcement learning-based resource allocation in LEO satellite networks for IoT services[J]. IEEE Internet of Things Journal, 2022, 9(17): 16309-16320.
- [17] ORSINO A, ARANITI G, MILITANO L, et al. Network slicing for non-terrestrial networks: a survey[J]. IEEE Access, 2021, 9: 128573-128591.
- [18] POLESE M, JANA R, ZORZI M. An O-RAN-compliant and AI-empowered end-to-end network slicing framework for 6G[J]. IEEE Communications Magazine, 2022, 60(5): 76-82.
- [19] BEGA D, GRAMAGLIA M, BANCHS A, et al. EvoNetSlice: an evolutionary model for dynamic resource allocation and real-time QoS adaptation in 6G network slicing [J]. IEEE Journal on Selected Areas in Communications, 2020, 38(8), 1766-1778.
- [20] SAVAZZI S, NICOLI M, RAMPA V, et al. Federated learning for LEO-based earth observation[J]. IEEE Transactions on Wireless Communications, 2020, 19(10): 6582-6595.
- [21] HAN S, MAO H, DALLY W J. Deep compression: Compressing deep neural networks with pruning, trained quantization and Huffman coding[C]//Proceedings of International Conference on Learning Representations (ICLR). San Diego: ICLR Press, 2016: 1-12.
- [22] YAO H, WANG C X, HUANG J, et al. A survey of channel measurements and models for satellite communication systems[J]. IEEE Communications Surveys & Tutorials, 2021, 23(1): 150-179.
- [23] ZHANG L, ZHAO H, HOU S, et al. A survey on artificial intelligence in non-terrestrial networks[J]. Chinese Journal of Aeronautics, 2022, 35(11): 1-20.
- [24] LIU J J, SHI Y P, FADLULLAH Z M, et al. Space-air-ground integrated network: a survey[J]. IEEE Communications Surveys & Tutorials, 2018, 20(4): 2714-2741.
- [25] SU Z, XU Q, ZHANG R. Deep reinforcement learning for dynamic resource allocation in geostationary satellite systems[J]. IEEE Transactions on Wireless Communications, 2021, 20(3): 1534-1548.

[作者简介]



李毅 (1984-), 男, 硕士, 中国星网网络系统研究院有限公司高级工程师, 主要研究方向为卫星通信、飞行器总体设计。



乔艳珍 (1983-) 女, 硕士, 现就职于中国星网网络系统研究院有限公司, 主要研究方向为卫星互联网无线通信技术、空间网络组网设计。



周康燕（1981- ），男，硕士，现就职于中国星网网络系统研究院，主要研究方向为卫星互联网总体设计和地面系统设计。



及志远（1998- ），男，硕士，现就职于中国星网网络系统研究院有限公司，主要研究方向为卫星互联网宽演体制、系统设计。



刘立浩（1999- ），男，硕士，现就职于中国星网网络系统研究院有限公司，主要研究方向为卫星互联网系统设计、卫星通信核心算法设计。



赵鸿（1998- ），男，硕士，现就职于中国星网网络系统研究院有限公司，主要研究方向为卫星通信体制评估验证、卫星通信可维可测设计。