

doi:10.13756/j.gtxyj.2026.260126.

专题: 智算中心光网络算网融合关键技术

赵诗萱, 王鑫, 李泳成. 6G全息业务面向光传送网的智能承载算法研究[J]. 光通信研究, 2026(4):29–37.

Zhao S Y, Wang X, Li Y C. Research on Intelligent Service Provisioning Algorithms for 6G Holographic Services in Optical Transport Networks[J]. Study on Optical Communications, 2026(4):29–37.

6G 全息业务面向光传送网的智能承载算法研究(特邀)

赵诗萱¹, 王鑫¹, 李泳成²

(1. 北京信息科技大学 信息与通信工程学院, 北京 102206; 2. 苏州大学 电子信息学院, 江苏 苏州 215031)

摘要:【目的】第六代移动通信技术(6G)全息业务是由用户主动交互产生,具有动态和突发的业务特性。为了满足用户多感官沉浸式体验,全息业务涉及全息点云视频、音频和嗅觉等多模态数据,这类多模态业务对网络提出了超大带宽、超低时延及多模态数据严格同步的传输需求;同时用户视角采用灵活的六自由度(6DoF)方式交互,微小的视角转动会引发视场内点云数量的变化,导致业务请求速率变化。全息点云视频存在遮挡和视角限制,用户无需每次接收全部数据即可保持沉浸式体验。因此,面临动态、突发和严格同步约束的多模态全息业务请求,如何在6DoF视角转动预测下进行全息业务的高效动态适配面临重要挑战,现有方法难以满足上述沉浸式业务的高效承载需求。文章聚焦业务多模态数据的网络传输过程,忽略数据采集、压缩、解码和渲染等全息通信过程,具体面向光传送网(OTN)开展6G全息业务的智能承载算法研究,重点关注该业务数据传输中资源高效的动态路由与波长分配问题。【方法】为解决该问题,文章提出了基于Transformer全息视角转动性预测下融合图神经网络与深度强化学习的业务智能承载算法。该算法采用Transformer进行6DoF全息视角转动性预测,建立预测视角与全息业务传输带宽的映射模型,将动态带宽需求变为静态;基于边-节点切换图卷积神经网络提取OTN中节点与链路的特征;通过基于深度强化学习的业务智能承载策略,实现多模态6G全息业务数据的路由与波长分配。【结果】仿真结果表明,与对比算法相比,文章所提算法使结合业务阻塞率与带宽资源占用率的联合优化目标平均降低了约58%。【结论】文章所提算法能够在动态场景下提升OTN对6G全息业务的资源利用效率并降低阻塞率,以支撑6G全息用户的沉浸式体验。

关键词: 第六代移动通信技术全息业务; 光传送网; 路由与波长分配; 全息视角转动预测; 深度强化学习

中图分类号: TN929

文献标志码: A

Research on Intelligent Service Provisioning Algorithms for 6G Holographic Services in Optical Transport Networks

ZHAO Shixuan¹, WANG Xin¹, LI Yongcheng²

(1. School of Information and Communication Engineering, Beijing Information Science and Technology University, Beijing 102206, China; 2. School of Electronic and Information Engineering, Soochow University, Suzhou 215031, China)

Abstract: 【Objective】6th Generation Mobile Communication Technology (6G) holographic services are generated by proactive user interactions and possess dynamic and bursty characteristics. To meet the multi-sensory immersive experience requirements of users, holographic services integrate diverse modalities of data, including holographic point cloud videos, audio, and olfaction. Such multi-modal services impose extremely high bandwidth, ultra-low latency, and strict synchronization transmission requirements for the network. Meanwhile, the user's perspective adopts a flexible Six-Degree-of-Freedom (6DoF) interaction method. A slight change in the perspective rotation will cause a change in the number of point clouds within the field of view, leading to a change in the rate of services requests. Holographic point cloud videos have issues of occlusion and perspective rotation limitations. Users do not need to receive all the data each time to maintain an immersive experience. Multi-modal holographic service requests are dynamic, bursty, and subject to strict synchronization constraints. Therefore, how to achieve efficient and dynamic provisioning of holographic services under 6DoF viewpoint rotation prediction poses a significant challenge. The existing methods are unable to meet the efficient provisioning requirements of the aforementioned immersive services. This paper focuses on the transmission process of multi-modal service data in the network, ignoring the holographic communication process such as data collection, compression, decoding, and rendering. It specifically conducts research on the intelligent provisioning algorithm for 6G holographic services in Optical Transport Networks (OTN), with particular emphasis on resource-efficient dynamic routing and wavelength assignment during data transmission. 【Methods】To address these issues, this paper proposes an intelligent provisioning algorithm based on Transformer-based holographic viewpoint rotation prediction combined with graph neural network and deep reinforcement learning. This algorithm employs a Transformer to perform 6DoF holographic viewpoint rotation prediction. It establishes a mapping model between the predicted viewpoints and the holographic service transmission bandwidth, converting the dynamic bandwidth demand into a static one. It then uses the graph neural network based on edge-node switching convolution to extract the features of nodes and links in the optical transport network. Subsequently, it realizes the routing and wavelength assign-

收稿日期:2026-05-06; 修回日期:2026-06-10; 纸质出版日期:2026-08-10

基金项目:国家重点研发计划资助项目(2023YFB2905505);国家自然科学基金资助项目(62271338)

作者简介:赵诗萱(2005—),女,山西忻州人。本科,主要研究方向为光通信网络。

通信作者:王鑫,副教授。E-mail:xinwang@bistu.edu.cn

© Editorial Office of *Study on Optical Communications*. This is an open access article under the CC BY-NC-ND license.

ment of multi-modal 6G holographic service data through an intelligent provisioning strategy based on deep reinforcement learning. **【Results】**The simulation results show that, compared with the benchmark algorithms, the proposed algorithm achieves a reduction of approximately 58% in the combined optimization objective of the service blocking rate and the bandwidth resource occupancy rate. **【Conclusion】**The proposed algorithm in this paper can enhance the resource utilization efficiency of the optical transport network for 6G holographic services in dynamic scenarios. It also reduces the blocking rate, thereby supporting the immersive experience of 6G holographic users.

Key words: 6G holographic services; OTN; routing and wavelength assignment; holographic viewpoint rotation prediction; deep reinforcement learning

0 引言

第三代合作伙伴计划(3rd Generation Partnership Project, 3GPP)于 2026 年 3 月发布的《6G 场景用例与业务需求》明确指出,第六代移动通信技术(6th Generation Mobile Communication Technology, 6G)将从传统“视听交互”演进至“多模态感官沉浸式体验”^[1]。全息通信(Holographic-Type Communication, HTC)业务作为 6G 沉浸式业务的典型代表,需协同传输点云视频、音频及嗅觉等多模态数据,通过六自由度(Six Degrees of Freedom, 6DoF)视角主动式交互满足用户沉浸式体验^[2]。

全息用户的主动式交互导致 6DoF 视角的频繁变化,这将直接改变视场内点云数量,引发业务请求速率和传输带宽随时间动态波动,呈现较强的突发性^[3];多模态数据并发传输对端到端时延及多流同步提出严格约束;全息点云视频 Tbit/s 级超大带宽需求进一步加剧了网络传输的带宽压力。光传送网(Optical Transport Networks, OTN)具备大容量与低时延优势^[4],可作为承载全息业务的有效手段之一。但现有面向 OTN 的动态路由与资源分配方法^[5-9]难以适配 HTC 业务视角驱动下的动态突发带宽需求,无法保障多模态数据严格同步传输,因而难以支撑全息用户的多感官沉浸式体验。

为此,本文面向 OTN 提出全息业务智能承载算法。针对 HTC 业务随视角变化波动的特点,先采用 Transformer 预测下一时刻的 6DoF 视角,并映射为实际带宽需求,将动态突发需求转化为准静态需求。在此基础上,用边-节点切换图卷积神经网络提取 OTN 的节点与链路特征,再由深度强化学习策略完成全息路由与波长分配。

1 问题描述

HTC 业务由 6DoF 视角变化驱动,动态突发性强。用户在交互过程中仅关注视场角(Field of View, FoV)内的局部点云即可满足沉浸式体验,传输完整全息图/点云视频会造成带宽浪费;而视角的

频繁变化会不断改变可见点云规模,带宽需求也随之波动。本文将时间离散为连续的时隙,假设每个时隙内用户视角不变,记时隙序号为 t 。同时,全息业务要并发传输视觉、音频及嗅觉等多模态数据,对时延和同步的要求很严,否则将严重影响沉浸体验。其中,点云视频作为核心载体,其 Gbit/s~Tbit/s 级的超大规模数据量给网络传输带来很大压力。因此,在 OTN 承载环境下,需解决以下问题:在满足带宽容量、端到端时延及多流同步约束的前提下,如何联合实现:① 6DoF 视角的模型构建;② 多模态数据的并发路由选择;③ 波长资源的高效分配,从而实现 HTC 业务面向 OTN 的动态高效承载。

1.1 全息业务与传输带宽建模

本文聚焦全息影院或全息演唱会的特定场景,将全息业务请求建模为 $H = \{h_i\}_{i=1}^N$,其中: H 为含 N 个子任务 h_i 的业务集合,第 i 个子任务 h_i 在第 $t=i$ 时隙处理,每个子任务均为单源、多目的传输任务,并携带多模态数据。 h_i 可表示为

$$h_i = (s_i, D_i, st_i, V_i, A_i, O_i), \quad (1)$$

式中: s_i 为 h_i 的源节点; $D_i = \{d_{i,k}\}_{k=1}^{K_i}$ 为 h_i 的目的节点集合, K_i 为目的节点总数, $d_{i,k}$ 为 D_i 中第 k 个目的节点;在多模态数据方面, st_i 为 h_i 的点云强度信息; V_i 、 O_i 和 A_i 分别为视觉(点云)、嗅觉和音频信息,具体地, $V_i = (R_i, G_i, C_i, X_i, Y_i, Z_i)$, (R_i, G_i, C_i) 与 (X_i, Y_i, Z_i) 分别为 h_i 的点云视频信息与点云坐标位置信息; O_i 为嗅觉设备信息、嗅觉时间戳与 h_i 的点云嗅觉时间戳编号^[10]; A_i 为音频的编码与波形相关数据(如采样率、量化字长和声道数等)。上述业务建模符合 HTC 中组播和多数据流并发传输特性。

① 6DoF 视角建模

全息用户的 6DoF 视角由三维平移与旋转组成,6DoF 视角可建模为沿 x 、 y 、 z 轴的平移自由度(Δx , Δy , Δz)以及围绕这些轴的旋转自由度,包括偏航角 φ 、俯仰角 θ 和滚转角 ζ 。但在固定观演场景全息影院/演唱会中,用户交互过程不涉及空间位移,6DoF 视点的旋转角度是影响视场内点云数量进而影响业务带宽请求的关键参数,即旋转自由度

主导请求带宽变化。进一步地, ζ 对可见点云规模影响可忽略, 因此仅保留 φ 和 θ 来表征全息用户 6DoF 视角。

② 视角驱动的带宽模型

用户视角变化决定可见点云数量, 从而影响视觉带宽需求。子任务 h_i 的视觉模态传输带宽需求 B_i^{vis} 可表示为

$$B_i^{\text{vis}} = f_v(S_i(\varphi_i, \theta_i), st_i, V_i), \quad (2)$$

式中: $f_v(\cdot)$ 为带宽映射函数; $S_i(\varphi_i, \theta_i)$ 为视场内点云规模。该模型本质上建立了从视角到 FoV, 到点云密度, 再到业务带宽请求的映射关系。

③ 全息多模态总带宽需求

全息业务总带宽 B_i 由视觉、听觉与嗅觉信息的多模态叠加得到, 可表示为

$$B_i = B_i^{\text{vis}} + B_i^{\text{aud}} + B_i^{\text{olf}}, \quad (3)$$

式中, B_i^{aud} 和 B_i^{olf} 分别为音频与嗅觉数据的带宽请求。这体现了 HTC 业务多数据流并发、强同步约束和多模态数据带宽需求的核心特征。

1.2 基于 OTN 的全息路由与波长分配问题

本文聚焦于 OTN 光承载层, 并对电层处理过程进行抽象简化, OTN 可建模为 $G=(V, E)$, 其中, V 为由可重构光分插复用器 (Reconfigurable Optical Add-Drop Multiplexer, ROADMs) 构成的节点集合; E 为光纤链路集合。对于任一链路 $e \in E$, 设其波长集合为 W , $w \in W$ 为某一具体波长, $C_{e,w}$ 为链路 e 上波长 w 的单波承载能力; 本文假设各波长容量相等, 即 $C_{e,w} = C$, 则链路总容量为 $|W| \cdot C$ 。

面向 HTC 业务在 OTN 中的承载需求, 该问题可建模为联合优化问题, 包含两个核心子问题: ① 全息多模态数据并发组播路由选择; ② 链路波长资源分配。具体而言, 鉴于 HTC 业务的超大带宽、超低时延和严格同步的传输需求, 对于每个业务请求 h_i , 需要在源节点 s_i 和每个目的节点之间, 为不同模态数据分别构建满足并发路由差分时延、端到端时延和链路容量资源等约束下的组播树, 实现多流协同传输^[11]。图 1 所示为传输视觉 (V) 信息、听觉 (A) 信息和嗅觉 (O) 信息的组播树示例。图中, S 、 d_1 和 d_2 分别示意源节点及两个目的节点; 绿、紫和橙路径对应 V、A 和 O 3 路组播, 分别对应 h_i 的多模态分量 V_i 、 A_i 和 O_i 。

波长分配是指在链路带宽容量约束下, 为业务带宽请求分配可用的波长资源。具体地, 该联合优化需满足以下约束条件: ① 连通性约束: 组播路径需

保证源到各目的节点可达; ② 链路容量约束: 任一链路一波长分配量不超过其可用带宽容量 $C_{e,w}^{\text{rem}}$; ③ 业务需求满足约束: 分配带宽总量满足业务子任务 h_i 的需求; ④ 时延约束: 端到端传输时延 (由链路传播时延与源/目的节点光/电转换处理时延构成) 不超过业务规定时延上界 $T_{\max}$; ⑤ 差分时延约束: 在每对源和目的节点之间, 业务多路径并行传输时, 多流时延差不超过差分时延上界 ΔT 。即 $\Delta T_{\max} = \max\{|T_{\text{vis}} - T_{\text{aud}}|, |T_{\text{vis}} - T_{\text{olf}}|, |T_{\text{aud}} - T_{\text{olf}}|\} \leq \Delta T$, 式中: T_{vis} 、 T_{aud} 和 T_{olf} 分别为视觉、听觉和嗅觉模态数据从源节点 s_i 到目的节点 $d_{i,k}$ 的端到端时延。




图 1 面向 HTC 业务的全息路由拓扑

Figure 1 Holographic routing topology for HTC services

综上, 该问题可归结为, 在满足带宽、时延及差分时延等约束条件下, 在线联合优化全息路由与波长分配策略, 以最小化业务阻塞率, 来提高带宽利用率, 并实现全息业务在 OTN 中的动态高效承载。

2 视角转动预测下融合图神经网络和深度强化学习的智能承载算法

基于上述问题, 本文提出了基于 Transformer 全息视角转动性预测下, 融合边-节点切换图卷积神经网络与优势演员-评论家深度强化学习 (Transformer-based Holographic Viewpoint Rotation Prediction with Graph-Neural-Network-based Edge-Node Switching Convolution and Advantage Actor-Critic, THVRP-GENSC-A2C) 的业务智能承载算法。图 2 所示为本文所提算法的流程图。

2.1 基于 Transformer 的视角转动预测


全息视点旋转由偏航角 φ 和俯仰 θ 来表示。为刻画其时间演化特性, 本文采用 Transformer 预测 φ 和 θ , 如图 2 中的 (a) 图所示。

在每个时隙 t , 模型接收历史视角序列

$\{(\varphi_j, \theta_j)\}_{j=1}^t$ 作为输入。首先通过线性映射至特征空间,并叠加正弦-余弦位置编码。接着,将编码后的序列输入到由两层 Transformer 编码器堆叠构成的特征提取部分^[12],每层包含多头自注意力层与前馈网络层。其中,多头自注意力层将输入序列分别映射为查询、键和值矩阵,通过计算序列内任意两个位置之间的注意力权重,对所有位置的信息进行加权

聚合,从而捕获视角变化的长程时序依赖;前馈网络则进一步增强模型的非线性表达能力。

取最后一个输出隐状态,经过线性解码层映射为 $t+1$ 时刻的预测视角 $(\varphi_{t+1}, \theta_{t+1})$ 。由视角与可见点云规模的映射关系,算出视场内可见点云数量,进而得到视觉带宽及业务总带宽需求,这样就能提前预判动态资源需求。



注:GENSC为边-节点切换图卷积神经网络; $\pi_{\theta}(a_t|x_t)$ 为动作 a_t 在状态 x_t 下的概率分布; θ 为策略参数; $V_{\psi}()$ 为状态价值。

图 2 THVRP-GENSC-A2C 算法示意图

Figure 2 Illustration of the proposed THVRP-GENSC-A2C algorithm

2.2 网络特征提取

本文采用 GENSC^[13]并行提取节点与链路特征,如图 2(b)所示。给定网络拓扑 $G=(V, E)$, X_V 为节点初始特征矩阵,表示节点占用状态; X_E 为链路初始特征矩阵,表示波长资源占用情况。设 $H_V^{(l)}$ 与 $H_E^{(l)}$ 分别为第 l 层节点与链路隐藏特征矩阵,且 $H_V^{(0)}=X_V$ 、 $H_E^{(0)}=X_E$ 。通过边-节点切换卷积,实现节点与链路特征的交替聚合与更新,得到 $H_V^{(l+1)}$ 与 $H_E^{(l+1)}$ 。其中,节点层与链路层更新可写为 $H_V^{(l+1)}=\sigma(M \cdot \phi(H_E^{(l)} \cdot P_E) \cdot M^T \cdot \Theta \cdot \tilde{A}_V \cdot H_V^{(l)} \cdot W_V)$, $H_E^{(l+1)}=\sigma(M^T \cdot \phi(H_V^{(l)} \cdot P_V) \cdot M \cdot \Theta \cdot \tilde{A}_E \cdot H_E^{(l)} \cdot W_E)$,式中: $\sigma(\cdot)$ 为非线性激活函数; M 为节点-链路关联矩阵, M^T 为其转置矩阵; $\phi(\cdot)$ 为对角化操作; Θ 为 Hadamard 乘积; P_V 和 P_E 为边-节点切换可学习映射矩阵,分别将节点和链路特征映射至链路域和节点域; W_V 和 W_E 分别为邻域聚合后的节点和链路线性变换矩阵; $\tilde{A}_V$ 和 $\tilde{A}_E$ 为归一化邻接矩阵。此外,节点-链路关联矩阵 M 用于刻画拓扑关系,邻接矩阵 $\tilde{A}$ 反映局

部结构信息。该机制能够同时捕获节点负载状态、链路容量分布和路径资源耦合关系。相比于传统方法,该方法可显著增强网络状态表征能力,为后续决策提供更精准的输入^[10-11]。

现有孤立提取单一维度特征的模型,会造成网络结构信息与属性信息割裂,无法完整捕捉网络内部的关联逻辑,最终导致网络信息丢失,提取精度较差^[14-15],因此本文选取 GENSC,突破了节点和边特征独立训练与单独输入的方式,在边特征训练阶段由边-点联合信息输入,点特征训练阶段也是边-点协同信息输入。

2.3 基于深度强化学习的全息业务智能承载算法

智能体采用 A2C 算法实现策略优化,Actor 网络和 Critic 网络均基于深度神经网络实现。深度强化的学习核心 3 要素包括状态、动作和奖励,其核心建模如下:

①状态:时隙 t 的状态 x_t 表征 OTN 网络环境信息,由节点和链路特征构成。节点特征为节点占

用状态,链路特征为链路剩余波长容量,用于刻画当前网络资源分布。

②动作:时隙 t 的动作 a_t 包含多模态组播树选择(视觉/听觉/嗅觉)和波长资源分配。为避免动作空间爆炸,引入 K 最短路径启发式策略^[10]:首先,为每类业务生成 K 条候选路径,然后,基于时延、差分时间延及容量约束筛选可行路径,并组合形成多模态组播树,最后,完成波长分配。该过程实现了对高维动作空间的有效压缩。

③奖励函数:奖励函数 r_t 采用约束驱动的分段形式。若所选动作无法完成可行路由与资源分配(即无法满足可达路径或波长容量约束),则给予固定失败惩罚;若动作为可行,则在基础奖励上扣减综合资源代价。定义如下:

$$r_t = \begin{cases} r_{\text{fail}}, & a_t \text{ 不可行} \\ r_{\text{max}} - (\alpha_1 \Phi_{\text{wave}} + \alpha_2 \Phi_{\text{node}} + \alpha_3 \Phi_{\text{delay}}), & a_t \text{ 可行} \end{cases}, \quad (4)$$

式中: r_{fail} 为动作不可行时的固定惩罚, r_{max} 为动作可行时的基础奖励,且 $r_{\text{max}} > r_{\text{fail}}$; $\alpha_1, \alpha_2, \alpha_3 > 0$ 为权重系数; Φ_{wave} 为波长代价,表征波长资源消耗与链路负载均衡状况; Φ_{node} 为节点代价,反映组播树链路上节点的占用状况及资源消耗; Φ_{delay} 为时延代价,反映业务在传播与处理环节的时延性能。该设计将多目标优化问题转化为统一奖励信号,提升了学习稳定性。

④策略更新机制:基于上述 3 元组定义,图 2(c)所示为 A2C 算法的迭代过程。Actor 网络根据状态 x_t 与动作空间生成动作概率分布 $\pi_{\theta}(a_t|x_t)$ 。Critic 网络基于 x_t 与 x_{t+1} 估计当前状态价值 $V_{\psi}(x_t)$ (ψ 为 Critic 参数)与下一状态价值 $V_{\psi}(x_{t+1})$,并计算时序差分误差(Temporal Difference error, TD-error) $TD(t)$ 为

$$TD(t) = r_t + \gamma V_{\psi}(x_{t+1}) - V_{\psi}(x_t), \quad (5)$$

式中: γ 为折扣因子; r_t 为当前时刻的奖励。 $TD(t)$ 的正负与大小直接用来衡量当前动作相对于状态的优劣,Actor 网络依据 TD-error 更新其参数 θ ,即

$$\theta_{t+1} = \theta_t + \eta_{\text{action}} \cdot \nabla_{\theta} \ln \pi_{\theta}(a_t|x_t) \cdot TD(t), \quad (6)$$

式中: ∇_{θ} 为 Actor 策略参数 θ 的梯度; $\ln \pi_{\theta}(a_t|x_t)$ 为动作 a_t 在状态 x_t 下的对数概率; η_{action} 为 Actor 网络学习率。Critic 网络依据 TD-error 与奖励更新其参数 ψ ,即

$$\psi_{t+1} = \psi_t + \eta_{\text{critic}} \cdot TD(t) \cdot \nabla_{\psi} V_{\psi}(x_t), \quad (7)$$

式中: ∇_{ψ} 为 Critic 参数 ψ 的梯度; η_{critic} 为 Critic 网络学习率。通过迭代优化,实现策略逐步收敛。

相较于传统基于值函数的强化学习方法,A2C

算法采用策略梯度直接优化随机策略,更适合在约束筛选后对可行动作进行概率建模与决策。然而,现有深度 Q 网络(Deep Q-Network, DQN)^[16]在解决本问题时,需要对高维动作空间逐一枚举,复杂度较高。而近端策略优化(Proximal Policy Optimization, PPO)^[17]等方法因其需要多轮小批量更新机制,通常带来更高的训练开销。

3 分析与讨论

3.1 仿真设置

本文基于 Python 3.9.13 平台进行了仿真实现,运行环境为 12th Gen Intel(R) Core(TM) i7-12700H 处理器。选取两类测试网络进行验证:小规模网络包含 10 个节点和 14 条链路;大规模网络包含 35 个节点和 74 条链路。各链路长度在 $[2, 5]$ km 区间内随机生成。核心仿真参数如表 1 所示。为了评估本文所提算法的性能,本文选取如下对比算法:①无视角预测的智能决策(Graph-Neural-Network-based Edge-Node Switching Convolution with Advantage Actor-Critic, GEN-SC-A2C)算法:该算法不引入视角预测机制,仅基于边-节点切换卷积进行特征提取,并结合深度强化学习中的 A2C 算法实现决策。②拥塞代价加权最短路径算法(Congestion-Cost-Weighted Shortest Path Algorithm, SPA):一种基于拥塞代价加权的最短路径算法。在经典最短路径的基础上引入动态拥塞约束,当链路带宽占用率超过设定阈值时,对其路由代价按比例放大。

表 1 仿真核心参数设置

Table 1 Core simulation parameter settings

参数名	取值
链路波长数	80
视角预测输入维度	2
端到端时延上限/ms	5
差分时间延上限/ms	1
视角预测模型结构参数(模型维度/注意力头数/编码层数)	32 / 4 / 2
Actor 网络学习率	2.3e-4
Critic 网络学习率	1.2e-4
K 最短路径数	8
奖励折扣因子	0.99
阻塞惩罚/失败惩罚	-80
成功奖励/最低奖励	10

不同算法的性能比较主要基于如下性能评估参

数:业务带宽资源占用率、业务阻塞率以及带宽资源占用率与阻塞率的联合优化目标。业务带宽资源占用率度量的活跃传输占可用波长带宽的比例,反映了波长资源的利用率,将其定义为 $\rho =$

$$\frac{\sum_{e \in E} (C_{\text{tot}}^e - \sum_{w \in W} C_{\text{rem}}^{e,w})}{\sum_{e \in E} C_{\text{tot}}^e}, \text{式中: } C_{\text{tot}}^e \text{ 为链路 } e \text{ 的总带宽容}$$

量; $C_{\text{rem}}^{e,w}$ 为链路 e 在波长 w 上的剩余带宽容量。业务阻塞率定义为 $b = N_{\text{blocked}}/N_{\text{req}}$, N_{blocked} 为被阻塞的业务请求数量, N_{req} 为总业务请求数量,业务阻塞率反映了业务请求因无可行路由组合或波长容量不足而无法被成功承载的比例。联合优化目标定义为 $J = \delta b + \xi \rho$, 以刻画带宽资源占用率和业务阻塞率之间的权衡关系, δ 和 ξ 为权重系数。考虑到 HTC 场景中业务阻塞对用户体验影响更为显著, 取 $\delta = 0.7$, $\xi = 0.3$, 以增强对业务接入能力的优化权重。

3.2 仿真结果分析

3.2.1 6DoF 视角预测误差分析

在开展 OTN 承载性能评估前, 首先对 Transformer 视角预测进行定量验证。本文在 360° 视频眼动数据集上进行测试, 将视频 1~视频 23 划分为训练集, 视频 24~视频 45 划分为测试集; 模型输入为前 20 个时隙的视角序列, 输出为下一时隙的预测视角。表 2 所示为 Transformer 在测试集上的预测误差统计结果。

表 2 视角预测误差

Table 2 Viewpoint prediction error

指标	偏航角 误差/°	俯仰角 误差/°	误差小于 2° 占比 (%)	误差小于 5° 占比 (%)
角度误差均值	2.02±	0.54±	73.1±3.3	95.3±0.7
值±标准差	0.13	0.06		

Transformer 视角预测误差处于合理范围, 绝大多数样本的双角最大误差控制在 5° 以内, 该精度可为后续视场估计与带宽需求映射提供有效输入。

3.2.2 算法性能分析

为评估算法统计稳定性, 本文在两种拓扑下各选取一个代表性业务负载规模, 分别基于表 1 参数开展 3 次独立重复实验, 统计业务阻塞率 b 、带宽资源占用率 ρ 及联合优化目标 J 的均值与标准差。表 3 和表 4 为上述独立实验的统计汇总。

由表 3 可知, THVRP-GENSC-A2C 的联合优化目标均值为 (31.77±6.18)%, 低于 SPA 的 (37.26±0.38)% 与 GENSC-A2C 的 (76.83±7.73)%。由表 4 可知, 大规模下 THVRP-GEN-

SC-A2C 的联合优化目标均值为 (6.51±1.20)%, 低于 SPA 的 (8.52±0.15)% 与 GENSC-A2C 的 (48.16±5.54)%。在大、小规模网络中, 3 次独立实验中主方法联合优化目标均优于 SPA, 表明所提算法具有一定稳定性。

表 3 小规模网络且业务数为 30 时各算法的性能 (均值±标准差)

Table 3 Performance of each algorithm in the small-scale network with 30 service requests

算法	$b(\%)$	$\rho(\%)$	$J(\%)$
THVRP-GEN-SC-A2C	24.53±7.05	48.65±4.16	31.77±6.18
GENSC-A2C	82.95±10.20	62.56±2.17	76.83±7.73
SPA	30.70±0.56	52.56±0.05	37.26±0.38


表 4 大规模网络且业务数为 20 时各算法的性能 (均值±标准差)

Table 4 Performance of each algorithm in the large-scale network with 20 service requests

算法	$b(\%)$	$\rho(\%)$	$J(\%)$
THVRP-GEN-SC-A2C	3.60±1.41	13.29±0.90	6.51±1.20
GENSC-A2C	57.30±6.98	26.83±2.51	48.16±5.54
SPA	6.73±0.20	12.70±0.03	8.52±0.15

进一步地, 图 3 和图 4 所示分别为基于固定随机种子获得的小规模与大规模网络代表性实验曲线, 图中给出了不同算法随业务请求规模变化的性能表现。

图 3 所示为小规模测试网络中, 业务请求数量由 15 增加至 45 时各算法的性能变化。随着请求规模的增大, 链路可用波长资源被加速消耗, 各算法的业务阻塞率 b 、带宽资源占用率 ρ 及联合优化目标 J 整体呈上升趋势。



(a) 阻塞率 b vs. 业务请求数量

(a) Blocking rate b vs. service requests



(b) 带宽资源占用率 ρ vs. 业务请求数量(b) Bandwidth occupancy rate ρ vs. service requests(c) 联合优化目标 J vs. 业务请求数量(c) Joint optimization objective J vs. service requests

图3 小规模网络中不同算法随业务请求规模变化的性能对比

Figure 3 Performance comparison of different algorithms with varying service request scales in small-scale networks

如图 3(a)所示,相较于 GENSC-A2C 和 SPA 算法,本文所提 THVRP-GENSC-A2C 算法的业务阻塞率 b 分别降低了 85% 和 50%。其原因在于视角预测降低了单业务带宽需求,同时 A2C 算法通过全局资源感知持续优化策略,使算法能保持较低阻塞率。如图 3(b)所示,相较于 GENSC-A2C 和 SPA 算法,本文所提算法的带宽资源占用率 ρ 分别降低了 25% 和 8%。与 GENSC-A2C 算法相比,视角预测仅传输视场内有效点云,避免了完整全息数据的冗余传输;与 SPA 算法相比,A2C 算法通过资源代价引导策略向均匀占用链路波长方向收敛。如图 3(c)所示,在权重系数为 7:3 时,相较于 GENSC-A2C 和 SPA 算法,本文所提算法的联合优化目标 J 分别平均降低了 71% 和 29%。该指标 b 权重占 70%,优势建立在上述机制的共同作用之上。需要说明的是,引入 GENSC-A2C 算法作为对照旨在量化视角预测对系统性能的影响,而非单纯比较路由与波长分配策略。在相同带宽需求条件下,TH-

VRP-GENSC-A2C 与 SPA 算法之间的对比更具参考价值。

对于大规模测试网络,网络规模扩大后,候选路径组合数增加,策略收敛难度随之上升。由图 4 可知,本文所提算法在大规模拓扑下仍保持优势。




(a) 阻塞率 b vs. 业务请求数量(a) Blocking rate b vs. service requests(b) 带宽资源占用率 ρ vs. 业务请求数量(b) Bandwidth occupancy rate ρ vs. service requests(c) 联合优化目标 J vs. 业务请求数量(c) Joint optimization objective J vs. service requests

图4 大规模网络中不同算法随业务请求规模变化的性能对比

Figure 4 Performance comparison of different algorithms with varying service request scales in large-scale networks

与 GENSC-A2C 算法相比,本文所提算法阻塞率与带宽资源占用率的降幅较大,主要源于业务请求差异:GENSC-A2C 算法未引入视角预测,须为

每个请求预留完整全息数据带宽,传输的业务数据量相对更大;本文所提算法通过视角预测仅传输视场内的有效点云数据,单业务带宽显著降低,性能表现的差异因数据量的差别而放大。与 SPA 相比,因二者均传输基于视角预测下满足用户沉浸式体验的最小带宽,差异主要来自网络状态感知与路由决策的协同机制。本文所提算法通过视角预测叠加强化学习智能决策,在较大规模网络中依然维持了较低的阻塞与带宽占用。

综上所述,相较于 GENSC-A2C 和 SPA 算法,本文所提 THVRP-GENSC-A2C 算法在结合业务阻塞率与带宽资源占用率的联合优化目标上实现降低,体现出了良好的资源利用效率与高负载适应能力。

4 结束语

本文针对 6G 全息业务面向 OTN 的高效承载问题,综合考虑多模态数据组播传输、链路波长容量以及时延等约束,提出了一种基于全息视角转动性预测下融合图神经网络与深度强化学习的 THVRP-GENSC-A2C 智能承载算法。该方法通过引入视角驱动的业务需求前馈机制,有效削减了冗余带宽开销;结合图神经网络对拓扑状态的结构化表征能力以及强化学习对动态决策的自适应优化能力,实现了面向多模态并发业务的联合路由与资源分配优化。仿真结果表明,本文所提算法在不同业务请求数量与网络规模下均能显著降低业务阻塞率,并在带宽资源占用率与联合优化目标上保持一定优势,尤其在高业务请求承载数量下能够显著缓解资源竞争带来的阻塞问题,并提升整体资源利用效率。进一步分析表明,业务需求预测与全局状态感知的协同引入,是提升系统性能的关键因素。然而,当前仿真仅基于 10 与 35 节点拓扑开展,距离实际大规模网络部署仍有差距,后续需结合真实业务场景与运营商级拓扑进一步验证其可扩展性。此外,电层与光层协同等因素对全息业务 OTN 承载的影响仍需进一步建模与验证。未来将进一步研究电层与光层的协同调度,实现面向多种规模网络的建模与性能优化。

参考文献:

[1] 3GPP. Study on 6G Use Cases and Service Requirements: TR 22.870 (Release 20)[R]. Sophia Antipolis, France:3GPP,2026.

- [2] 王旭,刘琼,彭宗举,等. 6DoF视频技术研究进展[J]. 中国图象图形学报, 2023, 28(6): 1863–1890.
Wang X, Liu Q, Peng Z J, et al. Research Progress of Six Degree of Freedom (6DoF) Video Technology[J]. Journal of Image and Graphics, 2023, 28(6): 1863–1890.
- [3] 陈佳,刘上,郜帅,等. 面向全息通信的智算融合网络[J]. 电子学报, 2025, 53(3): 754–764.
Chen J, Liu S, Gao S, et al. Smart Computing Integration Network for Holographic Communication[J]. Acta Electronica Sinica, 2025, 53(3): 754–764.
- [4] 张德朝,孙将,曹珊,等. 面向跨智算集群互联的新型 HIC-OTN技术[J]. 电信科学, 2025, 41(4): 53–60.
Zhang D C, Sun J, Cao S, et al. Novel HIC-OTN for Interconnection of Cross-Intelligent Computing Clusters[J]. Telecommunications Science, 2025, 41(4): 53–60.
- [5] 孔英会,杨佳治,高会生,等. 基于强化学习的光传送网路由波长优化[J]. 红外与激光工程, 2022, 51(11): 20220084.
Kong Y H, Yang J Z, Gao H S, et al. Optimization of Routing and Wavelength Optimization Algorithm for Optical Transport Network based on Reinforcement Learning[J]. Infrared and Laser Engineering, 2022, 51(11): 20220084.
- [6] 侯临凤,何荣希,吴梓敬. 弹性光网络中基于DRL的 RMSA算法[J]. 光通信技术, 2024, 48(3): 57–63.
Hou L F, He R X, Wu Z J. RMSA Algorithm based on DRL in Elastic Optical Networks[J]. Optical Communication Technology, 2024, 48(3): 57–63.
- [7] 郝志芃,杨慧洁,陈虹,等. 弹性光网络分层流量疏导优化方法[J]. 光通信研究, 2024(4): 230182.
Hao Z P, Yang H J, Chen H, et al. Stratification Traffic Grooming Methods in Elastic Optical Networks[J]. Study on Optical Communications, 2024(4): 230182.
- [8] 刘兆洋,潘必韬. 基于强化学习的光网络自适应高效率 RWA算法[J]. 光通信研究, 2024(4): 240024.
Liu Z Y, Pan B T. A Reinforcement Learning based Adaptive and Efficient RWA in All Optical Networks[J]. Study on Optical Communications, 2024(4): 240024.
- [9] 尚晓凯,翟慧鹏,韩龙龙. 基于深度强化学习的光网络资源分配方法研究[J]. 电子技术与软件工程, 2022, 11(9): 12–15.
Shang X K, Zhai H P, Han L L. Research on Optical Network Resource Allocation Method based on Deep Reinforcement Learning[J]. Electronic Technology & Software Engineering, 2022, 11(9): 12–15.
- [10] Wang X, Zhang C, Wang Y, et al. Holographic View-

- point Rotation Prediction-based Resource-Efficient Holographic-Type Communication Service Provision in an EON-Enabled NG-RAN[J]. *Journal of Optical Communications and Networking*, 2025, 17(5): 425–438.
- [11] Wang X, Zhang C, Wang R, et al. Flexible-Unit Deployment and Lightpath Provision over 6G AI-RAN for Holographic Type Communications [J]. *Journal of Lightwave Technology*, 2026, 44(4): 1342–1356.
- [12] Vaswani A, Shazeer N, Parmar N, et al. Attention Is All You Need [C]// *Advances in Neural Information Processing Systems 30 (NIPS 2017)*. Long Beach, CA, USA: Curran Associates, Inc., 2017: 6000–6010.
- [13] Jiang X, Ji P, Li S. CensNet: Convolution with Edge-Node Switching in Graph Neural Networks[C]// *Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence*. Macao, China: International Joint Conferences on Artificial Intelligence Organization, 2019: 2656–2662.
- [14] Kipf T N, Welling M. Semi-Supervised Classification With Graph Convolutional Networks[C]// *The 5th International Conference on Learning Representations (ICLR)*. Toulon, France:ICLR, 2017: 02907.
- [15] Veličković P, Cucurull G, Casanova A, et al. Graph Attention Networks[C]//*The 6th International Conference on Learning Representations (ICLR)*. Vancouver, Canada:ICLR, 2018: 48429.
- [16] Kafaei P, Cappart Q, Chapados N, et al. Dynamic Routing and Wavelength Assignment with Reinforcement Learning [J]. *INFORMS Journal on Optimization*, 2023, 6(1): 1–18.
- [17] Di Cicco N, Mercan E F, Karandin O, et al. On Deep Reinforcement Learning for Static Routing and Wavelength Assignment[J]. *IEEE Journal of Selected Topics in Quantum Electronics*, 2022, 28(4): 3600112.