

面向6G卫星互联网的多层级智能决策优化框架设计

柳虎威, 周 丽

(北京经济管理职业学院临空经济管理学院, 北京 100102)

摘 要: 随着6G通信技术的发展, 低轨卫星互联网凭借其全球覆盖、低时延等优势成为构建天地一体化网络的关键技术。然而, 6G卫星互联网系统面临星座配置、资源调度和业务优化等多层级强耦合决策问题, 现有单层优化方法难以有效处理层间依赖关系。针对该问题, 提出一种面向6G卫星互联网的多层级智能决策优化框架。首先构建涵盖星座部署、资源调度和业务优化的3层决策模型, 建立层间信息交互和约束传递机制; 然后设计基于改进遗传算法、凸优化分解和多智能体深度强化学习的混合智能算法, 通过交替方向乘子法实现多层级协调优化; 最后基于MATLAB仿真平台验证框架性能。实验结果表明, 相比传统分层优化和启发式算法, 该框架在系统容量、频谱效率和QoS满足度方面分别提升 $(8.6\pm 1.2)\%$ 、 $(10.8\pm 1.3)\%$ 和 $(6.5\pm 0.8)\%$ 。

关键词: 6G卫星互联网; 多层级决策; 智能优化; 资源调度; 深度强化学习

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025040

Multi-Level Intelligent Decision Optimization Framework for 6G Satellite Internet

LIU Huwei, ZHOU Li

School of Airport Economy Management, Beijing Institute of Economics and Management, Beijing 100102, China

Abstract: With the development of 6G communication technology, LEO satellite Internet has become a key technology for constructing space-terrestrial integrated networks due to its advantages of global coverage and low latency. However, 6G satellite Internet systems face multi-level strongly coupled decision-making problems such as constellation configuration, resource scheduling, and service optimization, and existing single-layer optimization methods are difficult to effectively handle inter-layer dependencies. To address this issue, a multi-level intelligent decision optimization framework for 6G satellite Internet is proposed. First, a three-layer decision model covering constellation deployment, resource scheduling, and service optimization is constructed, and inter-layer information interaction and constraint transfer mechanisms are established. Then, a hybrid intelligent algorithm based on improved genetic algorithm, convex optimization decomposition, and multi-agent deep reinforcement learning is designed, and multi-level coordinated optimization is achieved through alternating direction method of multipliers. Finally, the framework performance is verified based on MATLAB simulation platform. Experimental results show that compared with traditional hierarchical optimization and heuristic algorithms, the framework improves system capacity, spectrum efficiency, and QoS satisfaction by $(8.6\pm 1.2)\%$, $(10.8\pm 1.3)\%$, and $(6.5\pm 0.8)\%$, respectively.

Keywords: 6G satellite Internet, multi-level decision making, intelligent optimization, resource scheduling, deep reinforcement learning

收稿日期: 2025-06-30; 修回日期: 2025-08-13

基金项目: 四川省哲学社会科学重点实验室“智慧应急管理重点实验室”资助项目 (No. 2025ZHYJGL-3); 国家自然科学基金 (No. 24FGLB047); 北京经理学院科技英才支持计划 (No. 25KJLH01)

Foundation Items: Foundation of Sichuan Provincial Key Laboratory of Philosophy and Social Sciences: Key Laboratory of Intelligent Emergency Management (No. 2025ZHYJGL-3), the National Social Science Fund of China (No. 24FGLB047), the Science and Technology Talent Support Program of Beijing Institute of Economics and Management (No. 25KJLH01)

0 引言

6G移动通信系统旨在实现“万物智联”的愿景，提出了Tbit/s级峰值速率、亚毫秒级时延和99.999 99%可靠性等极致性能指标^[1-2]。低轨卫星互联网作为6G天地一体化网络的重要组成部分，能够为偏远地区、海洋和极地等地面网络无法覆盖的区域提供无缝连接^[3-4]。近年来，StarLink、OneWeb、Kuiper等大型星座的快速发展，标志着卫星互联网进入了规模化部署阶段^[5-6]。然而，6G卫星互联网系统的设计和运营面临着前所未有的挑战。星座规模达到数万颗卫星，系统复杂度呈指数级增长^[7-8]；6G业务对系统性能提出了极致要求，需要在全球范围内保障增强移动宽带（enhanced mobile broadband, eMBB）、超可靠低时延通信（ultra-reliable and low latency communications, uRLLC）、大规模机器类通信（massive machine type communications, mMTC）等多样化业务的服务质量（quality of service, QoS）^[9-10]；卫星的高速移动性导致网络拓扑动态变化，传统优化方法难以应对^[11-12]；星座配置、资源调度、业务优化等决策问题相互耦合，需要协同优化以实现系统整体性能最优^[13-14]。

国内外学者在卫星网络优化领域开展了广泛研究。在星座设计方面，Ferreira等^[15]提出了基于多目标强化学习的认知卫星通信优化方法，但未考虑动态业务需求对星座配置的影响。Ma等^[16]研究了基于遗传算法的低地球轨道（low earth orbit, LEO）卫星星座优化问题，采用全局覆盖作为优化目标，然而缺乏与下层资源调度的协调机制。Crisp等^[17]针对Walker星座设计了改进的粒子群算法，在覆盖性能和成本之间寻求平衡，但仅考虑了静态优化场景。

在资源管理方面，An等^[18]针对卫星通信系统设计了能效资源分配算法，采用分数编程求解功率分配问题，但假设星座配置固定不变。Chen等^[19]提出了基于深度强化学习的移动边缘计算任务卸载方法，通过深度Q网络（deep Q-network, DQN）算法优化计算资源分配，仅考

虑了单一优化目标。Zhang等^[10]研究了卫星移动边缘计算的QoS优化问题，设计了基于机器学习的资源预测方法，但未充分考虑星座拓扑的影响。

在业务优化方面，Li等^[20]研究了基于博弈论的卫星网络频谱分配问题，设计了多用户竞争的纳什均衡求解算法。Liu等^[21]提出了基于深度强化学习的卫星网络自适应路由方法，通过Actor-Critic算法处理动态路由决策，但未考虑资源约束的影响。近年来，ITU-R发布了6G网络架构标准^[22]，为卫星互联网集成提供了指导框架。

近年来一些学者开始关注多层级优化问题。Boyd等^[23]提出了分布式优化的交替方向乘子法（alternating direction method of multipliers, ADMM），为多层级协调优化提供了理论基础。Schulman等^[24]设计了近端策略优化算法，在多智能体强化学习方面取得重要进展。Bertsekas等^[25]在多层级优化理论方面提供了重要的数学基础。然而，现有研究主要集中在算法层面的改进，缺乏针对6G卫星互联网特点的系统性建模和优化框架。

现有主要方法的性能对比见表1，可以看出，现有研究在处理多层级耦合决策方面存在明显不足。大多数研究将星座配置、资源调度、业务优化视为独立问题，忽略了层间强耦合关系；优化算法主要针对特定子问题设计，缺乏处理多层级决策的统一框架；性能评估往往基于简化假设，与实际6G业务需求存在差距；理论分析不够深入，缺乏收敛性和复杂度的严格证明。

与现有研究相比，本文的核心创新在于：建立了6G卫星互联网多层级强耦合决策的数学模型，设计了层间信息传递和约束传递的统一机制；提出了混合智能算法框架，将连续优化、离散优化和强化学习有机结合；证明了多层级ADMM在非凸条件下的收敛性质。具体而言，本文的主要技术贡献体现在以下几个方面：在建模方面，构建了涵盖星座配置、资源调度和业务优化的多层级决策模型，建立了层间信息交互和约束传递的数学框架；在算法设计方面，提出了混合智能优化方法，针对不同层级的特点设计了专门的求解算法，并通过

表1 现有主要方法性能对比

研究文献	优化层级	主要算法	系统容量提升	时延性能	算法复杂度	收敛性证明	主要局限
文献[15]	星座层	多目标强化学习	6.3%	未考虑	$O(N^2)$	无	未考虑下层耦合
文献[16]	星座层	遗传算法	8.5%	一般	$O(N^2M)$	无	静态优化
文献[18]	资源层	凸优化	9.7%	良好	$O(N^3)$	有	星座固定
文献[19]	资源层	DQN	7.2%	较好	$O(N^2)$	无	单目标优化
文献[21]	业务层	博弈论	5.8%	一般	$O(N)$	有	资源约束简化
文献[22]	业务层	Actor-Critic	6.9%	较好	$O(N^2)$	无	未考虑资源耦合

ADMM 实现多层级协调；在理论分析方面，提供了算法收敛性证明和复杂度分析，建立了坚实的理论基础。

1 系统模型与问题建模

1.1 6G 卫星互联网系统架构

考虑一个由 N 颗 LEO 卫星组成的 6G 卫星互联网系统，卫星集合记为 $\mathcal{S} = \{s_1, s_2, \dots, s_N\}$ 。系统采用 Walker Delta 星座配置，包含 P 个轨道面，每个轨道面部署 M 颗卫星，满足 $N = P \times M$ 。地面服务区域划分为 K 个小区，小区集合记为 $\mathcal{C} = \{c_1, c_2, \dots, c_K\}$ ，每个小区内有多用户请求不同类型的 6G 业务。卫星 s_i 在时刻 t 的轨道位置由开普勒轨道要素确定，表示为：

$$\mathbf{r}_i(t) = f(a_i, e_i, i_i, \Omega_i, \omega_i, M_i(t))$$

其中， a_i 、 e_i 、 i_i 、 Ω_i 、 ω_i 分别为半长轴、偏心率、轨道倾角、升交点赤经和近地点幅角， $M_i(t)$ 为平近点角。

卫星与地面小区之间的可见性通过几何约束确定，表示为：

$$\eta_{i,k}(t) = \begin{cases} 1, & \theta_{i,k}(t) \geq \theta_{\min} \text{ 且 } d_{i,k}(t) \leq d_{\max} \\ 0, & \text{其他} \end{cases}$$

其中， $\theta_{i,k}(t)$ 为卫星 s_i 相对于小区 c_k 的仰角， $d_{i,k}(t)$ 为星地距离， $\theta_{\min}$ 和 $d_{\max}$ 分别为最小仰角阈值和最大通信距离。

卫星间的星间链路容量由香农公式确定，表示为：

$$C_{ij}(t) = B_{\text{ISL}} \log_2 \left(1 + \frac{P_{\text{ISL}} G_t G_r \lambda^2}{(4\pi d_{ij}(t))^2 N_0 B_{\text{ISL}}} \right)$$

其中， B_{ISL} 为星间链路带宽， P_{ISL} 为发射功率， G_t 、 G_r 分别为发射和接收天线增益， λ 为载波波长， N_0 为噪声功率谱密度。

1.2 多层级决策问题建模

6G 卫星互联网的多层级决策问题可建模为 3 层优化结构。

(1) 第一层：星座配置决策

$$\min_{\mathbf{x}_1} F_1(\mathbf{x}_1) + \phi_1(\mathbf{x}_2^*(\mathbf{x}_1), \mathbf{x}_3^*(\mathbf{x}_1, \mathbf{x}_2^*))$$

$$\text{s.t. } \mathbf{g}_1(\mathbf{x}_1) \leq \mathbf{0}, \mathbf{h}_1(\mathbf{x}_1) = \mathbf{0}$$

其中， $\mathbf{x}_1 = [P, M, a, e, i, \Omega, \omega]$ 为星座配置变量，包含轨道面数、每面卫星数和轨道要素向量。 $F_1(\cdot)$ 为星座部署成本函数， $\phi_1(\cdot)$ 为下层决策反馈函数，反映星座配置对系统整体性能的影响。

(2) 第二层：资源调度决策

$$\min_{\mathbf{x}_2} F_2(\mathbf{x}_1, \mathbf{x}_2) + \phi_2(\mathbf{x}_3^*(\mathbf{x}_1, \mathbf{x}_2))$$

$$\text{s.t. } \mathbf{g}_2(\mathbf{x}_1, \mathbf{x}_2) \leq \mathbf{0}, \mathbf{h}_2(\mathbf{x}_1, \mathbf{x}_2) = \mathbf{0}$$

其中， $\mathbf{x}_2 = [B, P, F]$ 包含带宽分配矩阵 $B \in \mathbb{R}^{N \times K}$ 、功率

分配矩阵 $P \in \mathbb{R}^{N \times K}$ 和计算资源分配矩阵 $F \in \mathbb{R}^{N \times K}$ 。矩阵元素 $B_{i,k}$ 、 $P_{i,k}$ 、 $F_{i,k}$ 分别表示卫星 s_i 为小区 c_k 分配的带宽、功率和计算资源。

(3) 第三层：业务优化决策

$$\min_{\mathbf{x}_3} F_3(\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3)$$

$$\text{s.t. } \mathbf{g}_3(\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3) \leq \mathbf{0}, \mathbf{h}_3(\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3) = \mathbf{0}$$

其中， $\mathbf{x}_3 = [\lambda, \mu, \tau]$ 包含业务接入策略 $\lambda \in \{0, 1\}^{U \times N}$ 、调度策略 $\mu \in \mathbb{R}^{U \times T}$ 和切换策略 $\tau \in \{0, 1\}^{U \times N \times T}$ ，其中 U 为用户数， T 为时间步数。

针对多层级决策模型的数学描述，对各层决策变量和函数关系进行说明如下：各层目标函数 $F_1(\cdot)$ 、 $F_2(\cdot)$ 、 $F_3(\cdot)$ 分别表示星座配置成本、资源调度成本和业务质量惩罚函数，其具体形式将在第 1.4 节中详细定义。下层决策反馈函数 $\phi_1(\cdot)$ 和 $\phi_2(\cdot)$ 用于量化层间耦合关系，体现多层级协调机制的数学表达。约束函数 $\mathbf{g}_1(\mathbf{x}_1)$ 、 $\mathbf{g}_2(\mathbf{x}_1, \mathbf{x}_2)$ 、 $\mathbf{g}_3(\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3)$ 和 $\mathbf{h}_1(\mathbf{x}_1)$ 、 $\mathbf{h}_2(\mathbf{x}_1, \mathbf{x}_2)$ 、 $\mathbf{h}_3(\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3)$ 分别表示各层的不等式和等式约束条件，确保优化解的物理可行性，其详细分类和具体形式将在第 1.3 节中阐述。

1.3 约束条件设计

(1) 星座配置约束条件：星座配置需要满足轨道稳定性、碰撞避免和覆盖连续性等约束条件。轨道稳定性要求偏心率 $e_i \in [0, 0.1]$ ，轨道倾角 $i_i \in [30^\circ, 90^\circ]$ ，以确保卫星轨道的长期稳定性；碰撞避免约束 $\min_{i \neq j} d_{ij}(t) \geq d_{\text{safe}}$ 保证任意两颗卫星之间的最小安全距离，其中 $d_{\text{safe}} = 5 \text{ km}$ ；覆盖连续性约束 $\sum_{i=1}^N \eta_{i,k}(t) \geq 1, \forall k, t$ 确保每个地面小区在任意时刻至少被一颗卫星覆盖，保证服务的连续性。

(2) 资源分配约束条件：资源分配受到卫星载荷能力和系统干扰的限制。功率约束 $\sum_{k=1}^K P_{i,k} \leq P_{i, \max}, \forall i$ 确保每颗卫星的总发射功率不超过最大值，带宽约束 $\sum_{k=1}^K B_{i,k} \leq B_{i, \max}, \forall i$ 保证频谱资源的有效利用，计算资源约束 $\sum_{k=1}^K F_{i,k} \leq F_{i, \max}, \forall i$ 限制卫星的计算能力分配，干扰约束 $\text{SINR}_{i,k} \geq \text{SINR}_{\min}, \forall i, k$ 确保通信质量满足最低要求，其中信干噪比定义为：

$$\text{SINR}_{i,k} = \frac{P_{i,k} G_{i,k}}{N_0 B_{i,k} + \sum_{j \neq i} P_{j,k} G_{j,k}}$$

(3) 业务 QoS 约束条件：不同类型的 6G 业务具有差异化的 QoS 需求。时延约束 $D_u \leq D_{u, \max}, \forall u \in \mathcal{U}$ 保证用户

业务的端到端时延满足要求, 根据ITU-R IMT-2030建议书^[23]的技术规范, eMBB业务的端到端时延要求为 $D_{u,\max} = 10 \text{ ms}$, uRLLC业务要求为 $D_{u,\max} = 1 \text{ ms}$; 可靠性约束 $R_u \geq R_{u,\min}, \forall u \in \mathcal{U}$ 确保业务传输的成功率, 其中uRLLC业务要求为 $R_{u,\min} = 99.999\%$ ^[26]; 速率约束 $C_u \geq C_{u,\min}, \forall u \in \mathcal{U}$ 保证用户的最低速率需求, 其中eMBB业务要求为 $C_{u,\min} = 100 \text{ Mbit/s}$ ^[27]。

1.4 目标函数设计

系统整体优化目标为最小化加权成本函数, 即:

$$\min_{\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3} J = w_1 J_1(\mathbf{x}_1) + w_2 J_2(\mathbf{x}_2) + w_3 J_3(\mathbf{x}_3) + J_{\text{coupling}}(\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3)$$

其中, $J_1(\mathbf{x}_1)$ 为星座部署成本, 包含卫星制造、发射和运维成本, 表示为:

$$J_1(\mathbf{x}_1) = a_1 N + a_2 \sum_{i=1}^N (a_i - a_{\text{ref}})^2 + a_3 \sum_{i=1}^N e_i^2$$

$J_2(\mathbf{x}_2)$ 为资源消耗成本, 反映功率和计算资源的使用代价, 表示为:

$$J_2(\mathbf{x}_2) = \beta_1 \sum_{i=1}^N \sum_{k=1}^K P_{i,k} + \beta_2 \sum_{i=1}^N \sum_{k=1}^K F_{i,k} + \beta_3 \sum_{i=1}^N \sum_{k=1}^K B_{i,k}$$

$J_3(\mathbf{x}_3)$ 为服务质量惩罚, 对违反QoS约束的情况进行惩罚, 表示为:

$$J_3(\mathbf{x}_3) = \gamma_1 \sum_{u \in \mathcal{U}} \max(0, D_u - D_{u,\max}) + \gamma_2 \sum_{u \in \mathcal{U}} \max(0, C_{u,\min} - C_u)$$

J_{coupling} 为层间耦合项, 反映多层级决策的相互影响, 表示为:

$$J_{\text{coupling}} = \delta_1 \|A_1 \mathbf{x}_1 + A_2 \mathbf{x}_2 - \mathbf{b}_1\|_2^2 + \delta_2 \|B_1 \mathbf{x}_2 + B_2 \mathbf{x}_3 - \mathbf{b}_2\|_2^2$$

其中, A_1, A_2, B_1, B_2 为耦合矩阵, $\mathbf{b}_1, \mathbf{b}_2$ 为耦合向量, 用于刻画层间约束关系。

2 多层级智能决策优化算法

2.1 总体算法框架

针对多层级强耦合决策问题, 本文设计了基于交替方向乘子法的协调优化框架, 如算法1所示。该框架的核心思想是将原始复杂优化问题分解为3个相对独立的子问题, 通过引入辅助变量和拉格朗日乘子, 建立层间信息交互机制, 实现多层级决策的协同优化。算法通过迭代求解各子问题并更新对偶变量, 逐步逼近全局最优解。

算法1: 多层级协调优化框架

输入: 系统参数 Θ , 初始解 $\mathbf{x}_1^0, \mathbf{x}_2^0, \mathbf{x}_3^0$, 收敛精度 ε , 最大迭代次数 $T_{\max}$

输出: 最优解 $\mathbf{x}_1^*, \mathbf{x}_2^*, \mathbf{x}_3^*$

1 初始化拉格朗日乘子 λ^0, μ^0 , 惩罚参数 ρ_1, ρ_2

2 **for** $t = 1$ to $T_{\max}$ **do**

3 // 星座配置子问题求解

4 $\mathbf{x}_1^t \leftarrow \arg \min L_1(\mathbf{x}_1 | \mathbf{x}_2^{t-1}, \mathbf{x}_3^{t-1}, \lambda^{t-1}, \mu^{t-1})$

5 // 资源调度子问题求解

6 $\mathbf{x}_2^t \leftarrow \arg \min L_2(\mathbf{x}_2 | \mathbf{x}_1^t, \mathbf{x}_3^{t-1}, \lambda^{t-1}, \mu^{t-1})$

7 // 业务优化子问题求解

8 $\mathbf{x}_3^t \leftarrow \arg \min L_3(\mathbf{x}_3 | \mathbf{x}_1^t, \mathbf{x}_2^t, \lambda^{t-1}, \mu^{t-1})$

9 // 对偶变量更新

10 $\lambda^t \leftarrow \lambda^{t-1} + \rho_1 (A_1 \mathbf{x}_1^t + A_2 \mathbf{x}_2^t - \mathbf{b}_1)$

11 $\mu^t \leftarrow \mu^{t-1} + \rho_2 (B_1 \mathbf{x}_2^t + B_2 \mathbf{x}_3^t - \mathbf{b}_2)$

12 // 收敛性检验

13 **if** $t > 1$ and $\|\mathbf{x}_1^t - \mathbf{x}_1^{t-1}\|_2 + \|\mathbf{x}_2^t - \mathbf{x}_2^{t-1}\|_2 + \|\mathbf{x}_3^t - \mathbf{x}_3^{t-1}\|_2 < \varepsilon$ **then**

14 **break**

15 **end for**

16 **return** $\mathbf{x}_1^t, \mathbf{x}_2^t, \mathbf{x}_3^t$

算法的关键在于构造合适的增广拉格朗日函数。第 i 层的增广拉格朗日函数定义为:

$$L_i(\mathbf{x}_i | \mathbf{x}_{-i}, \lambda, \mu) = F_i(\mathbf{x}_i) + \lambda^T \mathbf{g}_i(\mathbf{x}_i) + \frac{\rho}{2} \|\mathbf{g}_i(\mathbf{x}_i)\|_2^2$$

其中, $\mathbf{x}_{-i}$ 表示除第 i 层外的所有决策变量, $\mathbf{g}_i(\cdot)$ 为耦合约束函数。对偶变量更新采用梯度上升方法, 步长由惩罚参数控制。算法的收敛性由ADMM理论保证, 在凸性条件下收敛到全局最优解。

2.2 星座配置层优化算法

星座配置子问题属于混合整数非线性规划问题, 决策变量既包含连续的轨道参数, 也包含离散的卫星数量。由于传统数学优化方法难以处理这类混合整数问题, 本文设计了改进遗传算法, 通过自适应参数调整和精英保留策略提高算法性能, 如算法2所示。

算法2: 改进遗传算法

输入: 种群规模 N_{pop} , 最大代数 G , 交叉变异参数

输出: 最优星座配置 $\mathbf{x}_1^*$

1 随机初始化种群 $P^0 = \{\mathbf{x}_1^1, \mathbf{x}_1^2, \dots, \mathbf{x}_1^{N_{\text{pop}}}\}$

2 **for** $g = 1$ to G **do**

3 // 适应度评估

4 **for** $i = 1$ to N_{pop} **do**

5 $f_i \leftarrow \text{evaluate_fitness}(\mathbf{x}_i^g)$

6 **end for**

7 // 计算种群多样性

```

8   $D(g) \leftarrow \text{compute\_diversity}(P^g)$ 
9  // 自适应参数调整
10  $p_c(g) \leftarrow \text{adaptive\_crossover\_rate}(D(g))$ 
11  $p_m(g) \leftarrow \text{adaptive\_mutation\_rate}(D(g))$ 
12 // 选择操作
13  $P_{\text{select}} \leftarrow \text{tournament\_selection}(P^g, \{f_i\}_{i=1}^{N_{\text{pop}}})$ 
14 // 交叉操作
15  $P_{\text{cross}} \leftarrow \text{crossover}(P_{\text{select}}, p_c(g))$ 
16 // 变异操作
17  $P_{\text{mut}} \leftarrow \text{mutation}(P_{\text{cross}}, p_m(g))$ 
18 // 精英保留
19  $P^{g+1} \leftarrow \text{elitism}(P_{\text{mut}}, P^g, \text{elite\_ratio})$ 
20 end for
21 return best_individual( $P^G$ )

```

改进遗传算法的核心创新在于种群多样性的动态控制机制。种群多样性指标定义为个体间欧氏距离的平均值,表示为:

$$D(t) = \frac{1}{N_{\text{pop}}(N_{\text{pop}} - 1)} \sum_{i=1}^{N_{\text{pop}}} \sum_{j=i+1}^{N_{\text{pop}}} \| \mathbf{x}_i - \mathbf{x}_j \|_2$$

基于多样性指标,交叉概率采用指数衰减自适应调整,表示为:

$$p_c(t) = p_{c,\min} + (p_{c,\max} - p_{c,\min}) \exp\left(-\frac{D(t)}{D_0}\right)$$

变异概率根据个体适应度进行自适应调整,表示为:

$$p_m^i(t) = p_{m,\min} + (p_{m,\max} - p_{m,\min}) \exp\left(-\frac{f_i - f_{\min}}{f_{\max} - f_{\min}}\right)$$

算法采用锦标赛选择保持选择压力,单点交叉处理连续变量,均匀变异处理离散变量。精英保留策略确保适应度前 20% 的优质解不会丢失,提高算法的收敛稳定性。为进一步增强局部搜索能力,对精英个体执行高斯扰动,表示为:

$$\mathbf{x}_{\text{new}} = \mathbf{x}_{\text{elite}} + \sigma \cdot \mathcal{N}(0, \mathbf{I})$$

其中, σ 为搜索步长,根据算法收敛情况自适应调整。

星座配置层优化算法的输出结果为最优星座配置方案,该方案包含决策变量 $\mathbf{x}_1 = [P, M, a, e, i, \Omega, \omega]$ 的最优取值组合,具体包括最优轨道面数、每面卫星数、轨道高度、偏心率、轨道倾角、升交点赤经和近地点幅角等关键轨道参数。算法通过编码技术处理混合整数变量,利用自适应交叉变异策略和精英保留机制,在满足覆盖连续性、碰撞避免等物理约束的前提下,寻找使星座部署成本最小化与系统性能最大化达到最优平衡的参数配置。

2.3 资源调度层优化算法

资源调度子问题在给定星座配置的条件下,优化频谱、功率和计算资源的分配。由于目标函数和约束条件均为凸函数,采用分布式凸优化方法求解,既保证全局最优性,又降低计算复杂度,如算法 3 所示。

算法 3: 分布式资源优化算法

输入: 星座配置 $\mathbf{x}_1$, 初始价格 $\boldsymbol{\pi}^0$, 步长 α , 收敛精度 ε_{res}

输出: 资源分配方案 $\mathbf{x}_2^* = \{\mathbf{x}_2^i\}_{i=1}^N$

```

1  设置  $t \leftarrow 0$ 
2  repeat
3    // 各卫星并行求解子问题
4    for  $i = 1$  to  $N$  in parallel do
5       $\mathbf{x}_2^{i,t+1} \leftarrow \arg \min L_i(\mathbf{x}_2^i | \boldsymbol{\pi}^t)$  // 求解凸优化子问题
6    end for
7    // 聚合需求信息
8    total_demand  $\leftarrow \sum_{i=1}^N \mathbf{A}_i \mathbf{x}_2^{i,t+1}$ 
9    // 价格更新
10    $\boldsymbol{\pi}^{t+1} \leftarrow \max(0, \boldsymbol{\pi}^t + \alpha(\text{total\_demand} - \text{capacity}))$ 
11    $t \leftarrow t + 1$ 
12 until  $\|\boldsymbol{\pi}^t - \boldsymbol{\pi}^{t-1}\|_2 < \varepsilon_{\text{res}}$  or  $t > T_{\max}$ 
13 return  $\{\mathbf{x}_2^{i,t}\}_{i=1}^N$ 

```

分布式资源优化算法的核心思想是将原问题分解为 N 个卫星子问题,通过价格机制协调各卫星的资源分配决策。每个卫星子问题的优化目标为:

$$\min_{\mathbf{p}_i, \mathbf{b}_i, \mathbf{f}_i} \sum_{k=1}^K (c_{i,k}^p p_{i,k} + c_{i,k}^b b_{i,k} + c_{i,k}^f f_{i,k}) + \boldsymbol{\pi}^T (\mathbf{A}_i \mathbf{x}_i - \mathbf{b}_i)$$

其中, $\boldsymbol{\pi}$ 为资源价格向量, $\mathbf{A}_i$ 为约束矩阵, $\mathbf{x}_i = [\mathbf{p}_i^T, \mathbf{b}_i^T, \mathbf{f}_i^T]^T$ 为卫星 i 的资源分配向量。算法的收敛性由拉格朗日对偶理论保证。由于各子问题均为凸优化问题,存在强对偶性,价格更新过程收敛到最优对偶解,对应的原问题解即为全局最优解。收敛速度为 $O(1/\sqrt{t})$, 其中 t 为迭代次数。

2.4 业务优化层算法设计

业务优化子问题涉及动态环境下的多智能体协作决策,具有状态空间大、动作连续、环境非平稳等特点。本文采用多智能体近端策略优化算法,通过集中训练分布执行的框架实现高效求解。算法将每颗卫星建模为一个智能体,智能体的状态空间包含位置信息、负载状态、信道条件和用户需求等多维信息,表示为:

$$\mathbf{s}_i = [\text{pos}_i, \text{load}_i, \text{channel}_i, \text{user}_i] \in \mathbb{R}^{d_s}$$

动作空间包含业务调度和切换决策，表示为：

$$\mathbf{a}_i = [\text{schedule}_i, \text{handover}_i] \in \mathbb{R}^{d_a}$$

奖励函数综合考虑吞吐量、时延和功耗等多个因素，表示为：

$$r_i = w_{\text{thr}} \cdot \text{throughput}_i - w_{\text{del}} \cdot \text{delay}_i - w_{\text{pow}} \cdot \text{power}_i$$

为处理高维连续状态空间，本文设计了基于多头注意力机制的深度神经网络架构，如图1所示。网络结构采用编码器-解码器模式，首先通过空间特征提取模块处理卫星位置和信道状态信息，该模块由两层全连接网络组成，隐藏层维度分别为128和256，激活函数采用ReLU。时序特征提取采用双层LSTM网络，隐藏状态维度为256，用于捕获卫星运动和业务需求的时间依赖关系。

网络的核心创新在于引入多头注意力机制，通过8个注意力头并行处理不同类型的特征信息，自适应地关注对决策最重要的状态特征。策略网络和价值网络共享前述特征提取层，策略网络输出层采用Tanh激活函数以适应连续动作空间，价值网络输出层采用单目标量值表示状态价值。这种设计既保证了特征提取的有效性，又通过参数共享提高了学习效率。基于该网络架构，多智能体近端策略优化算法的具体流程如算法4所示。算法采用广义优势估计降低方差，使用裁剪目标函数保证策略更新的稳定性。多智能体设置下，各智能体共享价值网络参数，但保持独立的策略网络，在提高学习效率的同时保证决策的分布式特性。

算法4：多智能体近端策略优化算法

输入：环境参数，网络参数 θ_0, ϕ_0 ，最大回合数 M

输出：最优策略 π_θ^*

```

1 初始化策略网络 $\pi_{\theta_0}$ ，价值网络 $V_{\phi_0}$ ，经验缓冲区 $\mathcal{B}$ 
2 for episode = 1 to  $M$  do
3   重置环境，获取初始状态 $\mathbf{s}_0 = \{\mathbf{s}_0^i\}_{i=1}^N$ 
4   for  $t = 0$  to  $T - 1$  do
5     // 所有智能体并行决策
6     for  $i = 1$  to  $N$  in parallel do
7        $\mathbf{a}_t^i \sim \pi_\theta(\cdot | \mathbf{s}_t^i)$  // 策略采样
8     end for
9     // 环境交互
10     $\{\mathbf{s}_{t+1}^i, r_t^i\}_{i=1}^N \leftarrow \text{env.step}(\{\mathbf{a}_t^i\}_{i=1}^N)$ 
11    // 经验存储
12    for  $i = 1$  to  $N$  do
13       $\mathcal{B}.\text{store}((\mathbf{s}_t^i, \mathbf{a}_t^i, r_t^i, \mathbf{s}_{t+1}^i))$ 
14    end for
15  end for
16 // 优势函数计算
17 for  $t = 0$  to  $T - 1$  do
18    $\hat{A}_t^i \leftarrow r_t^i + \gamma V_\phi(\mathbf{s}_{t+1}^i) - V_\phi(\mathbf{s}_t^i)$  // GAE估计
19 end for
20 // 网络参数更新
21 for  $k = 1$  to  $K_{\text{epochs}}$  do

```




图1 基于多头注意力机制的深度神经网络架构

```

22 // 策略网络更新
23  $L_\pi \leftarrow \mathbb{E}[\min(r_i(\theta), \hat{A}_i, \text{clip}(r_i(\theta), 1-\varepsilon, 1+\varepsilon) \hat{A}_i)]$ 
24  $\theta \leftarrow \theta + \alpha \nabla_\theta L_\pi$ 
25 // 价值网络更新
26  $L_V \leftarrow \mathbb{E}[(V_\phi(s_i^i) - \hat{V}_i^{i, \text{target}})^2]$ 
27  $\phi \leftarrow \phi + \beta \nabla_\phi L_V$ 
28 end for
29 end for
30 return  $\pi_\theta$ 

```

2.5 算法复杂度与收敛性分析

(1) 时间复杂度分析：多层级协调优化算法的时间复杂度由各层子算法复杂度构成。星座配置层的改进遗传算法复杂度为 $O(T_1 \cdot N_{\text{pop}} \cdot N^2)$ ，其中 T_1 为最大迭代次数， N_{pop} 为种群规模。资源调度层的分布式算法复杂度为 $O(T_2 \cdot N \cdot K^2)$ ，其中 T_2 为价格更新迭代次数。业务优化层的多智能体强化学习复杂度为 $O(T_3 \cdot N \cdot |A|)$ ，其中 T_3 为训练轮数， $|A|$ 为动作空间大小。总体时间复杂度为：

$$T_{\text{total}} = O(T_{\text{outer}} \cdot (T_1 N_{\text{pop}} N^2 + T_2 N K^2 + T_3 N |A|))$$

其中 T_{outer} 为外层 ADMM 迭代次数。

(2) 空间复杂度分析：算法的空间复杂度主要由种群存储、价格向量和神经网络参数决定，总体复杂度为 $O(N_{\text{pop}} \cdot N + N \cdot K + N \cdot |S| \cdot |A|)$ ，其中 $|S|$ 为状态空间大小。

(3) 收敛性分析：基于 ADMM 理论，当各子问题均收敛时，整体算法收敛到卡鲁什-库恩-塔克 (Karush-Kuhn-Tucker, KKT) 点。具体地，设 $\mathbf{x}^* = (\mathbf{x}_1^*, \mathbf{x}_2^*, \mathbf{x}_3^*)$ 为原问题的最优解， (λ^*, μ^*) 为最优对偶乘子，则有以下定理。

定理 1 在以下条件下，算法 1 收敛到原问题的最优解：(i) 各子问题的目标函数 F_i 为凸函数且连续可微；(ii) 约束函数 $\mathbf{g}_i$ 为仿射函数；(iii) 存在可行解使得 Slater 条件成立；(iv) 惩罚参数 $\rho_1, \rho_2 > 0$ 。

证明： 根据 ADMM 收敛理论，在以上条件成立时，序列 $\{(\mathbf{x}^t, \lambda^t, \mu^t)\}$ 收敛到 KKT 点 $(\mathbf{x}^*, \lambda^*, \mu^*)$ 。收敛速度分析：当目标函数强凸时，收敛速度为 $O(1/t)$ ；当目标函数非强凸但满足其他正则条件时，收敛速度为 $O(1/\sqrt{t})$ 。

3 仿真实验与结果分析

3.1 仿真环境设置

基于 MATLAB R2023a 和 Satellite Communications Toolbox 构建 6G 卫星互联网仿真环境。仿真采用 Walker

Delta 星座配置，通过卫星场景建模函数建立动态卫星运行环境，时间跨度设置为 24 小时以覆盖完整的卫星运行周期。星座参数采用 6 个轨道面、每面 11 颗卫星的配置，轨道高度设定为 780 km，轨道倾角为 86.4°，能够实现对中高纬度地区的有效覆盖。地面站部署选择了北京、纽约、伦敦、东京、悉尼、莫斯科、柏林、巴黎、首尔、孟买等 10 个全球主要城市，以模拟真实的全球业务分布场景。地面站配置考虑了地理位置的多样性和业务需求的差异性，能够有效验证算法在不同覆盖场景下的性能表现。

6G 业务流量模型根据 ITU-R IMT-2030 建议书的技术要求进行设计。eMBB 业务占总用户数的 60%，峰值速率要求达到 100 Mbit/s 以上，主要模拟高清视频、虚拟现实等大带宽应用。uRLLC 业务占 25%，时延要求小于 1 ms，可靠性要求达到 99.999%，主要模拟工业自动化、自动驾驶等超低时延应用。mMTC 业务占 15%，连接密度要求达到每平方千米 100 万个设备，主要模拟物联网传感器、智能电表等大规模连接应用。业务到达过程采用泊松分布建模，到达率参数 $\lambda=0.5$ ，能够真实反映实际网络中业务的随机性和突发性特征。用户移动性模型采用随机路点模型，移动速度范围为 0~120 km/h，涵盖了静止用户、步行用户、车载用户等不同移动场景。信道模型考虑了自由空间路径损耗、大气衰落、多普勒频移等因素，并引入了随机阴影衰落以模拟真实的无线传播环境。

为保证实验结果的统计可靠性，每组实验重复进行 50 次独立的蒙特卡洛仿真，实验结果取平均值并计算 95% 置信区间。仿真采用固定随机种子确保结果的可重现性，同时通过不同随机种子的多次实验验证算法性能的稳定性。关键参数的选择依据如下：种群规模 100 是基于收敛性和计算复杂度的权衡分析确定的；学习率 0.001 是通过网格搜索在 [0.000 1, 0.01] 范围内选择最优值确定的；惩罚参数 $\rho_1 = \rho_2 = 0.5$ 是根据 ADMM 理论的收敛条件和实验调优确定的；折扣因子 0.99 符合强化学习中长期奖励的标准设置。轨道高度范围参考了当前主流 LEO 星座（如 Starlink、OneWeb）的配置；载波频率选择 28 GHz 符合 6G 毫米波通信的技术路线；业务比例参考了 ITU-R IMT-2030 建议书对 6G 业务场景的预测。仿真参数设置具体见表 2。

3.2 对比算法设置

为全面评估算法性能，本文选择了具有代表性的对比算法进行实验验证。传统分层优化 (traditional hierar-

表2 仿真参数设置

参数类别	参数名称	参数值	说明	参数类别	参数名称	参数值	说明
星座参数	轨道高度	550~1 200 km	LEO轨道范围	通信参数	载波频率	28 GHz	6G毫米波段
	轨道倾角	53°~87°	覆盖中高纬度地区		系统带宽	1 GHz	单载波带宽
	轨道面数	6~12个	Walker Delta配置		最小仰角	10°	地面可见性阈值
	每面卫星数	8~22颗	根据覆盖需求调整		最大发射功率	50 W	单卫星功率限制
	最小安全距离	5 km	避免卫星碰撞		噪声温度	290 K	标准环境噪声
业务参数	eMBB用户比例	60%	增强移动宽带	算法参数	种群规模	100个	遗传算法种群
	uRLLC用户比例	25%	超可靠低时延		最大迭代次数	300次	外层ADMM迭代
	mMTC用户比例	15%	大规模机器通信		学习率	0.001	神经网络训练
	业务到达率	泊松($\lambda=0.5$)	动态业务模型		折扣因子	0.99	强化学习参数

chical optimization, THO) 算法采用逐层顺序优化的方法, 星座配置使用经验参数设计, 资源调度采用比例公平算法, 业务优化使用轮询调度策略, 各层之间无信息反馈机制^[28]。启发式算法 (heuristic algorithm, HSA) 基于贪婪策略进行快速求解, 在每个决策点优先选择当前局部最优解, 适用于对实时性要求较高的应用场景^[29]。单层集中优化 (single-layer centralized optimization, SCO) 算法将所有决策变量统一建模为单一优化问题, 采用粒子群算法进行求解, 不考虑问题的内在层级结构特性^[30]。

深度Q网络基线算法仅在业务优化层使用DQN方法, 星座配置和资源调度层采用固定的经验配置, 主要用于验证多层级协同优化的必要性。多目标遗传算法采用非支配排序遗传算法II (non-dominated sorting genetic algorithm II, NSGA-II) 处理多目标优化问题, 将3层目标函数作为多个独立的优化目标同时考虑, 通过帕累托前沿寻找折中解^[31]。这些对比算法涵盖了不同的优化范式和求解策略, 能够全面验证所提框架的优越性。

3.3 性能评估指标

本文建立了综合性的性能评估体系, 包含主要性能指标如下: 系统容量定义为网络中所有用户的总吞吐量, 即 $C_{\text{sys}} = \sum_{u \in \mathcal{U}} R_u$, 反映了网络的整体数据传输能力; 频谱

效率表示单位带宽的数据传输率, 计算式为 $SE = \frac{C_{\text{sys}}}{B_{\text{total}}}$,

衡量了频谱资源的利用效率; 能量效率定义为单位功耗的数据传输率, 即 $EE = \frac{C_{\text{sys}}}{P_{\text{total}}}$, 体现了系统的能耗经济

性; 服务质量满足度 $QoS = \frac{|\{u: D_u \leq D_{u,\max}, R_u \geq R_{u,\min}\}|}{|\mathcal{U}|}$

表示满足 QoS 要求的用户比例, 综合考虑了时延和速率约束。

3.4 实验结果分析

实验结果表明, 在不同星座规模 (48~192 颗卫星) 的测试场景下, 多层级框架 (multi-level framework, MLF) 算法的系统容量性能始终优于对比算法。具体而言, 当卫星数量为 48 颗时, MLF 算法的系统容量达到 732.4 Gbit/s, 而 THO、HSA 和 SCO 算法分别为 674.3 Gbit/s、621.8 Gbit/s 和 698.1 Gbit/s。随着卫星数量增加到 192 颗, 各算法的性能差距进一步扩大, MLF 算法相比 THO、HSA 和 SCO 算法的系统容量分别提升 8.6%、17.2% 和 4.8%。这一性能提升源于多层级协调机制能够有效处理星座配置与资源分配之间的复杂耦合关系, 实现了全局性能的优化。传统方法由于缺乏层间信息交互, 难以充分利用系统资源, 导致整体性能受限。不同算法在系统容量方面的性能对比如图 2 所示。




图2 不同算法在系统容量方面的性能对比

MLF 算法在频谱效率和能量效率两项指标上均表现最优, 且具有最小的标准差, 表明性能稳定性最好。MLF 算法的频谱效率相对于 THO 算法提升了 10.8%, 能量效率提升了 10.2%。这得益于资源调度层采用的分布式

凸优化算法能够在满足 QoS 约束的前提下, 实现频谱和功率资源的最优配置。各算法的频谱效率和能量效率对比见表 3。

表 3 各算法的频谱效率和能量效率对比

算法	频谱效率/(bit·s ⁻¹ ·Hz ⁻¹)		能量效率/(Mbit·J ⁻¹)	
	均值	标准差	均值	标准差
MLF	4.12	0.08	156.7	12.3
THO	3.72	0.14	142.3	18.7
HSA	3.31	0.21	129.1	24.2
SCO	3.95	0.17	149.8	15.8
NSGA-II	3.84	0.19	145.2	20.1

不同业务类型 QoS 满足度对比如图 3 所示, 在不同业务类型 QoS 满足度方面, MLF 算法对各类业务均提供良好支持, 特别是对时延敏感的 uRLLC 业务表现出色。MLF 算法在 eMBB、uRLLC 和 mMTC 业务上的 QoS 满足度分别达到 91.7%、94.3% 和 88.9%, 平均比 THO 算法提升 6.5%。这一优势主要来源于业务优化层采用的多智能体强化学习算法能够根据实时网络状态和业务需求动态调整调度策略, 实现差异化的 QoS 保障。




图 3 不同业务类型 QoS 满足度对比

算法收敛性能对比如图 4 所示, MLF 算法在约 85 轮迭代后达到收敛, 目标函数值稳定在最优解附近。MLF 算法的收敛轮数比 THO 算法减少约 27%, 比 SCO 算法减少约 38%。这一优势源于 ADMM 框架的分解特性降低了各子问题的复杂度, 同时各层专用算法的设计提高了求解效率。




图 4 算法收敛性能对比

计算复杂度对比见表 4。虽然 MLF 算法的时间复杂度略高于启发式方法, 但相比单层集中优化显著降低, 且在工程可接受范围内。MLF 算法的实际运行时间比理论预期更优, 这得益于 MATLAB 并行计算工具箱的高效实现和分布式算法的并行特性。

表 4 计算复杂度对比

算法	理论复杂度	平均运行时间/s	内存占用/MB	收敛轮数/轮
MLF	$O(N^2 K)$	267.3	142.6	85
THO	$O(NK^2)$	189.4	98.7	117
HSA	$O(NK)$	68.1	41.2	45
SCO	$O(N^3 K)$	1 156.8	387.2	138
NSGA-II	$O(N^2 M)$	423.7	201.3	195

参数敏感性分析结果如图 5 所示, 实验结果表明算法对参数变化具有良好的鲁棒性, 在较宽的参数范围内都能保持稳定性能。算法在惩罚权重参数为 0.5 时达到最优性能, 且在 [0.3, 0.7] 范围内性能变化小于 2%, 体现了良好的参数鲁棒性。




图 5 参数敏感性分析结果

为验证算法在动态环境下的适应性,设计了用户需求突变和卫星故障等场景。MLF算法能够快速适应环境变化,在扰动发生后15分钟内恢复至稳定状态,表现出良好的动态适应能力。动态环境适应性测试结果如图6所示。




图6 动态环境适应性测试结果

为验证框架中各组件的有效性,设计了详细的消融实验。表5为不同算法配置下的性能表现,其中“ $\pm$ ”后表示50次独立仿真实验的95%置信区间。实验结果表明,仅使用改进遗传算法时系统容量提升(3.1 ± 0.4)%,主要改善了星座配置的合理性;仅使用分布式资源优化时系统容量提升(4.9 ± 0.7)%,体现了资源分配优化的重要性;仅使用多智能体强化学习时系统容量提升(4.5 ± 0.6)%,在QoS满足度方面表现较好。双层协调实验进一步验证了层间协调的价值。星座层与资源层协调优化(无业务层)的系统容量提升达到(6.2 ± 0.8)%,资源层与业务层协调优化(无星座层)的提升为(7.1 ± 0.9)%。完整MLF框架通过3层协调优化,系统容量提升达到(8.6 ± 1.2)%,相比最佳双层协调方案仍有1.5%的提升,验证了全层级协调的必要性。通过配对 t 检验分析,完整MLF框架与各个简化版本的性能差异均在 $p<0.001$ 水平上

显著,确保了实验结果的统计可靠性。同时,收敛性分析显示,完整框架的收敛轮数(85轮)优于大部分简化版本,表明多层级协调机制不仅提升了性能,还改善了算法的收敛特性。

3.5 实验结果总结

综合实验结果表明,本文所提出的多层级智能决策优化框架在6G卫星互联网应用中表现良好。与最优对比算法相比,该框架在系统容量、频谱效率和QoS满足度方面分别提升(8.6 ± 1.2)%、(10.8 ± 1.3)%和(6.5 ± 0.8)%,验证了多层级协调优化的有效性。算法在85轮迭代内实现收敛,收敛轮数比传统分层方法减少约27%,表明混合智能算法具有良好的收敛特性。虽然算法的时间复杂度略高于启发式方法,但相比单层集中优化显著降低,计算开销在工程可接受范围内。参数敏感性分析和动态环境测试表明,该框架对参数变化和环境动态具有良好的适应性和鲁棒性,适用于6G卫星互联网系统的实际部署和运营。

4 结束语

针对6G卫星互联网的多层级强耦合决策问题,本文提出了一种智能决策优化框架。通过构建3层决策模型、设计混合智能算法、建立协调机制,实现了星座配置、资源调度和业务优化的协同优化。理论分析证明了算法的收敛性,仿真实验表明该框架在测试场景下具有良好的性能表现,为6G卫星互联网系统设计提供了理论支撑和技术方案。

未来工作将重点关注以下几个方面:首先,考虑多星座异构协同的复杂场景,研究不同轨道高度和功能的卫星协作机制;其次,集成边缘计算和网络切片技术,构建更加智能化的6G卫星互联网架构;再次,引入不确定性和鲁棒性优化方法,提高系统对环境变化和故障的适应能力;最后,开展真实星座环境下的验证实验,进一步验证框架的工程可行性。

表5 不同算法配置下的性能表现

实验配置	系统容量提升	频谱效率提升	QoS满足度提升	收敛轮数	说明
仅改进遗传算法	(3.1 ± 0.4)%	(4.2 ± 0.6)%	(2.8 ± 0.5)%	95	星座层优化
仅分布式资源优化	(4.9 ± 0.7)%	(7.3 ± 0.9)%	(3.2 ± 0.4)%	78	资源层优化
仅多智能体强化学习	(4.5 ± 0.6)%	(5.8 ± 0.8)%	(5.1 ± 0.6)%	102	业务层优化
双层协调(星座+资源)	(6.2 ± 0.8)%	(8.9 ± 1.0)%	(4.6 ± 0.7)%	89	无业务层协调
双层协调(资源+业务)	(7.1 ± 0.9)%	(9.2 ± 1.1)%	(5.8 ± 0.8)%	91	无星座层协调
完整MLF框架	(8.6 ± 1.2)%	(10.8 ± 1.3)%	(6.5 ± 0.8)%	85	3层协调优化

参考文献

- [1] 张平, 陈岩, 吴超楠. 6G: 新一代移动通信技术发展态势及展望[J]. 中国工程科学, 2023, 25(6): 1-8.
ZHANG P, CHEN Y, WU C N. Six-generation mobile communication: development trend and outlook[J]. Strategic Study of Chinese Academy of Engineering, 2023, 25(6): 1-8.
- [2] LETAIEF K B, CHEN W, SHI Y, et al. The roadmap to 6G: AI empowered wireless networks[J]. IEEE Communications Magazine, 2019, 57(8): 84-90.
- [3] 倪少杰, 岳洋, 左勇, 等. 卫星网络路由技术现状及展望[J]. 电子与信息学报, 2023, 45(2): 383-395.
NI S J, YUE Y, ZUO Y, et al. The status quo and prospect of satellite network routing technology[J]. Journal of Electronics & Information Technology, 2023, 45(2): 383-395.
- [4] CHEN S, SUN S, KANG S. System integration of terrestrial mobile communication and satellite communication-the trends, challenges and key technologies in B5G and 6G[J]. China Communications, 2021, 17(12): 156-171.
- [5] KODHELI O, LAGUNAS E, MATURO N, et al. Satellite communications in the new space era: a survey and future challenges[J]. IEEE Communications Surveys & Tutorials, 2020, 23(1): 70-109.
- [6] REMILI K D, BOUZOURINE N, HARTANI R, et al. Tech diplomacy and critical technologies: case of the LEO satellite internet[J]. Telecommunications Policy, 2025, 49(4): 102947.
- [7] 杜星葵, 束妮娜, 刘春生, 等. 低轨卫星网络安全问题及防御技术综述[J]. 电子与信息学报, 2025, 47(6): 1609-1622.
DU X K, SHU N N, LIU C S, et al. Overview of security issues and defense technologies for low earth orbit satellite network[J]. Journal of Electronics & Information Technology, 2025, 47(6): 1609-1622.
- [8] DEL PORTILLO I, CAMERON B G, CRAWLEY E F. A technical comparison of three low earth orbit satellite constellation systems to provide global broadband[J]. Acta Astronautica, 2019, 159: 123-135.
- [9] 李科新, 尤力, 高西奇. 基于大规模MIMO的低轨卫星通信系统[J]. 天地一体化信息网络, 2022, 3(1): 2-8.
LI K X, YOU L, GAO X Q. Massive MIMO LEO satellite communications system[J]. Space-Integrated-Ground Information Networks, 2022, 3(1): 2-8.
- [10] ZHANG Z, ZHANG W, TSENG F H. Satellite mobile edge computing: improving QoS of high-speed satellite-terrestrial networks using edge computing techniques[J]. IEEE Network, 2019, 33(1): 70-76.
- [11] 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.
- [12] 郑爽, 张兴, 王文博. 低轨卫星通信网络路由技术综述[J]. 天地一体化信息网络, 2022, 3(3): 97-105.
- [13] ZHENG S, ZHANG X, WANG W B. Survey of low earth orbit satellite communication network routing technology[J]. Space-Integrated-Ground Information Networks, 2022, 3(3): 97-105.
- [14] JIA M, ZHU S, WANG L, et al. Routing algorithm with virtual topology toward to huge numbers of LEO mobile satellite network based on SDN[J]. Mobile Networks and Applications, 2018, 23: 285-300.
- [15] WANG M, CUI Y, WANG X, et al. Machine learning for networking: workflow, advances and opportunities[J]. IEEE Network, 2017, 32(2): 92-99.
- [16] FERREIRA P V R, PAFFENROTH R, WYGLINSKI A M, et al. Multi-objective reinforcement learning for cognitive satellite communications using deep neural network ensembles[J]. IEEE Journal on Selected Areas in Communications, 2018, 36(5): 1030-1041.
- [17] MA F, ZHANG X, LI X, et al. Hybrid constellation design using a genetic algorithm for a LEO-based navigation augmentation system[J]. GPS Solutions, 2020, 24: 62.1-62.14.
- [18] CRISP N H, SMITH K L, HOLLINGSWORTH P. Launch and deployment of distributed small satellite systems[J]. Acta Astronautica, 2015, 114(9): 65-78.
- [19] AN K, LIANG T, YAN X, et al. Power allocation in land mobile satellite systems: an energy-efficient perspective[J]. IEEE Communications Letters, 2018, 22(7): 1374-1377.
- [20] CHEN M, WANG T, ZHANG S, et al. Deep reinforcement learning for computation offloading in mobile edge computing environment[J]. Computer Communications, 2021, 175: 1-12.
- [21] LI W, JIA L, CHEN Q, et al. A game theory-based distributed downlink spectrum sharing method in large-scale hybrid satellite constellations[J]. IEEE Transactions on Communications, 2024, 72(8): 4620-4632.
- [22] LIU X, ZHOU H, ZHANG Z, et al. Multipath cooperative routing in ultra-dense LEO satellite networks: a deep reinforcement learning-based approach[J]. IEEE Internet of Things Journal, 2025, 12(2): 1789-1804.
- [23] ITU-R. Framework and overall objectives of the future development of IMT for 2030 and beyond[R]. 2023.
- [24] BOYD S, PARIKH N, CHU E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers[J]. Foundations and Trends in Machine Learning, 2011, 3(1): 1-122.
- [25] SCHULMAN J, WOLSKI F, DHARIWAL P, et al. Proximal policy optimization algorithms[J]. arXiv preprint arXiv:1707.06347, 2017.
- [26] BERTSEKAS D P. Nonlinear programming[M]. Belmont: Athena Scientific, 2016.
- [27] 3GPP. Study on scenarios and requirements for next generation access technologies[R]. 2017.
- [28] LIMANI X, CAMELO M, MARQUEZ-BARJA J M, et al. Unveil-

ing network sharing capabilities enabled by 5G network slicing[C]// 2025 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2025: 1-3.

- [28] ANANDALINGAM G, FRIESZ T L. Hierarchical optimization: an introduction[J]. Annals of Operations Research, 1992, 34: 1-11.
- [29] FENG X, LI Y, XU M. Multi-satellite cooperative scheduling method for large-scale tasks based on hybrid graph neural network and metaheuristic algorithm[J]. Advanced Engineering Informatics, 2024, 60: 102362.
- [30] KENNEDY J, EBERHART R. Particle swarm optimization[C]// Proceedings of ICNN'95-International Conference on Neural Networks. Piscataway: IEEE Press, 1995, 4: 1942-1948.
- [31] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197.

[作者简介]



柳虎威（1994-），男，北京经济管理职业学院讲师，主要研究方向为优化理论与方法。



周丽（1978-），女，北京经济管理职业学院教授、副院长，主要研究方向为优化理论与方法。