

基于终端流量预测的低地球轨道卫星互联网资源分配策略

沈斐¹, 吕承丞^{1,2}, 张嘉璇^{1,2}, 阮小婷^{1,2}

(1. 中国科学院上海微系统与信息技术研究所无线传感网与通信重点实验室, 上海 200050; 2. 中国科学院大学, 北京 101408)

摘要: 针对地面网络存在覆盖盲区和卫星网络通信资源利用率低等问题, 提出了基于终端流量预测的低地球轨道 (LEO) 卫星互联网资源分配策略。该策略利用真实数据集提出改进 LSTM-ARIMA 算法, 准确预测地面区域未来一定时间内产生的数据流量, 通过 Stackelberg 博弈构建差分数据传和任务卸载 2 种通信模型。综合考虑数据处理时延和能耗, 通过求解纳什均衡, 得到用户通过 LEO 卫星互联网传输数据或卸载任务的最优比率, 以及卫星提供网络服务的最优定价。仿真结果表明, 所提策略在数据传输服务中收益能提高约 40%, 在任务卸载服务中收益能提高约 50%。

关键词: 低地球轨道卫星互联网; 数据流量预测; 资源分配; 数据传输; 任务卸载

中图分类号: TN927

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2024049

LEO satellite Internet resource allocation strategy based on terminal traffic prediction

SHEN Fei¹, LYU Chengcheng^{1,2}, ZHANG Jiakuan^{1,2}, RUAN Xiaoting^{1,2}

1. Key Laboratory of Wireless Sensor Network and Communications, Shanghai Institute of Microsystem and Information Technology, Chinese Academy of Sciences, Shanghai 200050, China

2. University of Chinese Academy of Sciences, Beijing 101408, China

Abstract: A resource allocation strategy for the low earth orbit (LEO) satellite Internet based on terminal traffic prediction was proposed to address the problems of blind coverage spots in ground network and the low resource utilization of satellite network. An improved LSTM-ARIMA algorithm was proposed with real datasets by the strategy to accurately predict the data traffic generated in the ground area over a certain period of time in the future. Two communication models, differentiated data transmission and task offloading were constructed through Stackelberg games, taking into the data processing latency and energy consumption account. By solving the Nash equilibrium, the optimal ratio for users to transmit data or unload tasks through the LEO satellite Internet, as well as the optimal pricing for satellites to provide network services, were obtained. Extensive simulation results verify that the proposed strategy can increase the revenue by approximately 40% in data transmission services and 50% in task offloading services.

Keywords: LEO satellite Internet, data flow prediction, resource allocation, data transmission, task offloading

0 引言

随着航空航天技术的不断进步, 人们部署大量

航天器构成地球轨道卫星网络 (EOSN, earth orbit satellite network), 使空间通信、地球观测和深空

收稿日期: 2023-11-08; 修回日期: 2024-01-17

通信作者: 吕承丞, lnb@mail.usc.edu.cn

基金项目: 国家重点研发计划基金资助项目 (No.2019YFE0120700); 上海市科技创新行动计划基金资助项目 (No.22511100800, No.22511100500)

Foundation Items: The National Key Research and Development Program of China (No.2019YFE0120700), The Project of Science and Technology Commission of Shanghai (No.22511100800, No.22511100500)

探索等成为可能^[1]。由于 EOSN 部署在太空中，可以更有效地满足地面网络难以覆盖的区域日益增长的通信需求，如海洋或偏远地区^[2]。目前，人们在 EOSN 领域的研究已经取得重大进展，引发了对低地球轨道（LEO, low earth orbit）卫星互联网的重新定义^[3]。LEO 卫星互联网将任何可用作网络节点的航天器定义为太空节点（SN, satellite node），并为地面和太空中各种卫星网络终端（SNT, satellite network terminal）提供服务^[4]。

LEO 卫星互联网是将所有实体终端与其他网络（如互联网、航空网络和蜂窝网络）连接起来的网络总和，此网络将使地面应用（地面-卫星通信）、空中应用（空中-卫星通信）和太空应用（如太阳系互联网、空间旅游和月球村）等成为可能^[5]。然而，由于海量卫星和网络终端的运动性、通信流量的时变性以及服务覆盖的广域性，LEO 卫星互联网拓扑结构和性能要求高度动态，这涉及移动性管理、网络链路选择和有限的 EOSN 资源分配等问题。因此，要实现 LEO 卫星互联网优化部署，还需要解决许多技术问题。基于终端流量预测的 EOSN 基本架构如图 1 所示。




图 1 基于终端流量预测的 EOSN 基本架构

针对地面网络覆盖盲区 and EOSN 资源利用率低等问题，本文设计了一个真实数据集驱动的网络终端数据流量预测模型，并利用该模型进行 EOSN 资源动态分配。如图 1 所示，该网络由 LEO 云服务器结合地面站共同辅助解决地面网络覆盖盲区（如海洋、轨道交通、偏远山区）的通信问题，通过不同地区的船流、车流、人流密度和轨迹坐标等信息预测未来一定时间内的数据流量，动态配置覆盖该地区的卫星网络带宽，合理分配有限的卫星资源。本文主要贡献如下。

1) 通过真实数据集使用差分自回归移动平均-长短期记忆（LSTM-ARIMA, long short term mer-

mory-autoregressive integrated moving average）网络预测某地区未来一定时间内的终端数据流量，并提出了 EOSN 数据差异化传输及任务卸载系统模型，考虑不同场景中用户对任务时延、能耗、服务质量等需求，提供了针对性的数据传输或任务卸载服务，有效分配了有限的卫星通信资源，提高了用户和卫星的收益。

2) 根据预测的网络终端数据流量，建立了 Stackelberg 博弈模型，以确定用户通过卫星传输数据或卸载任务的最优比率。通过求解纳什均衡，得到了用户的最优决策和卫星提供网络服务的最优定价。

3) 利用真实的远洋航运数据集给出了不同区域内不同时间的终端数据流量热力图，结果表明，该流量预测算法具有较高的准确性。将基于 Stackelberg 博弈的 EOSN 差异化数据传输及任务卸载算法与其他算法进行比较，证明了本文所提基于终端流量预测的 LEO 卫星互联网资源分配策略能有效节约通信资源，并为用户及卫星带来更高收益。

1 相关工作

1.1 卫星通信与任务卸载

LEO 卫星互联网资源有限，因此卫星通信中的任务卸载对时延、能耗、数据传输速率都有更高的要求。近年来，研究人员对卫星通信中的任务卸载做了许多研究，Liu 等^[6]基于空天地一体化中功率有限的物联网设备的卸载问题，采用带约束的马尔可夫决策过程制定任务卸载决策问题，并提出一种基于自适应联合深度强化学习的算法。此外，分布鲁棒时延优化算法被运用于制定稳定任务卸载决策^[7]，该算法通过使最坏情况下预期的能量受限系统的时延最小化，得到了效率较高的卸载策略。基于学习的队列感知任务卸载和资源分配算法经常用于解决任务卸载和资源分配时出现的信息不完全、维数灾难、排队时延等问题^[8]。考虑动态网络环境、大范围覆盖和能量备份约束下通信和计算资源的联合优化问题，Gong 等^[9]提出一种基于李雅普诺夫函数的多智能体近端策略优化算法。但是这些卸载算法在降低用户处理任务的时延及能耗方面仍有不足，为了进一步解决卸载任务的时延及能耗问题，Yu 等^[10]提出一个支持边缘计算的空天地一体化网络（SAGIN, space-air-ground integrated network）框架，最大限度降低了任务完成时延和卫星资源消

耗。智能任务卸载和多维资源分配算法经常被用于降低任务卸载时延^[11],关于如何制定最优卸载决策,Qin等^[12]结合EOSN和边缘计算设计了一个混合卸载架构,提出了一种多智能体行动者-批评家强化学习算法。此外,李雅普诺夫函数、强化学习、深度确定性梯度下降等方法也经常被运用于制定更好的卸载策略^[13-15]。但是这些卸载策略没有充分考虑卸载卫星节点的收益,因此本文提出一种在有效降低任务处理时延及系统能耗的同时确保卸载卫星收益的算法。

1.2 卫星通信与资源分配

卫星通信过程中离不开卫星和地面终端的配合,由于LEO卫星互联网中资源有限以及卫星运动和地面流量不均,每颗卫星接收的流量往往存在差异。为了解决网络资源利用率低的问题,Jia等^[16]提出一种非地球静止轨道混合业务场景下LEO卫星互联网的自适应随机接入和数据传输方案,该方案的网络资源利用率较高。Wang等^[17]提出一种用于天地一体化物联网的低时延异构网络MAC方法,该方法可以显著降低网络时延,提高系统可扩展性并平衡系统总负载。Lu等^[18]对卫星网络的结构进行优化,以提高星座的传输效率。关于卫星网络的资源调度问题,文献^[19-20]提出基于软件定义网络和网络功能虚拟化的SAGIN-IoV(Internet of vehicles)边缘云架构以及基于联邦的学习流量分流算法,提高了卫星网络决策精度和传输服务质量。Zhang等^[21]提出一种基于联邦学习的服务功能链部署方法,有效提高了SAGIN的网络资源利用率。Zhang等^[22]提出基于业务类型的SAGIN体系结构,实现了CPU资源利用率、链路资源利用率和用户服务质量的明显提高。为了优化网络带宽分配,Abdu等^[23]提出一种灵活的宽带EOSN通信系统的载波和功率分配方法,实现了利用最少带宽资源提供最佳业务匹配。在星座设计上,Yuan等^[24]提出双中继Halo轨道星座用于地月通信网络,实现了在保证用户服务质量的前提下能量效率最大化。断点传输的中继卫星任务调度星座模型有效解决了卫星通信中的数据传输快速增长的问题^[25],在此基础上,Li等^[26]提出一种可扩展型中继卫星调度框架,实现了调度方案的利润和最大化。Zhang等^[27]提出一种在线联合数据下载和资源管理方案,实现了卫星集群网络数据丢失率为零,

并有效降低了网络能耗。

保证通信服务质量是卫星通信中关键的一环。Davarian等^[28]实现了直接对地链路,从而更好地为用户群服务,提升了小卫星在深空通信和跟踪系统中的性能,避免出现网络拥塞。El等^[29]提出一种多属性路由调度算法,可在星际网络中稳定提供信息,显著降低了平均端到端时延和开销。

然而,上述关于卫星网络的研究没有充分考虑海洋、轨道交通、高速公路等复杂场景中数据流量分布的特点,也没有根据用户对数据类型、任务优先级等需求提供针对性通信服务,导致卫星通信资源大量浪费,通信质量较差。因此,本文提出基于LSTM-ARIMA预测模型的EOSN通信服务系统,为轨道交通、海洋航运等提供针对性通信服务,合理地分配有限的卫星通信资源,并提高用户及卫星的收益,符合未来卫星通信的应用需求与发展趋势。

2 系统模型

2.1 LEO卫星互联网的差异化数据传输服务

为满足地面网络覆盖盲区的轨道交通、海洋航运及偏远地区中不同用户通信数据流量需求,本文建立了一个EOSN差异化数据传输系统,如图2所示,统筹考虑网络终端的位置坐标、数据流量及时变性。该系统分为地面层和EOSN层,主要包括LEO、云服务器、地面站和各种类型终端用户。




图2 EOSN差异化数据传输系统

本文根据不同用户的服务需求,通过LSTM-ARIMA模型预测不同区域内的数据流量,分配系统带宽后,按大、中、小型数据划分数据流量传输需求。不同类型数据通过不同途径辅助传输至所需

用户，其中，小型数据主要服务于无法与地面站直接通信的用户，可由LEO卫星辅助的云服务器直接传输至有需求的用户；中、大型数据由于数据量较大，需要LEO卫星或云服务器先从地面站缓存临时备份，再传输给所需用户。根据任务类型，EOSN差异化数据传输方式具体可分为以下3种。

1) 小型数据任务：数据量较小且无法与地面站直接通信的任务，由云服务器通过LEO卫星传输给所需用户，或者由LEO卫星辅助传输。

2) 中型数据任务：该任务数据量较大，主要通过地面站传输给所需用户，或者经由LEO卫星辅助传输。

3) 大型数据任务：与中型数据任务相同，为了降低数据传输时延，由地面站传输给所需用户，同时可由云服务器和LEO卫星联合辅助数据传输。

2.2 LEO卫星互联网任务卸载服务

如图3所示，本文通过LSTM-ARIMA模型预测海洋航运、轨道交通、偏远地区未来即将产生的数据流量，对带宽进行合理分配，建立了一个EOSN任务卸载系统。该系统分为用户层、卸载层和地面站3层结构，用户层的主体为有卸载需求的用户；卸载层包括参与任务卸载的LEO卫星、云服务器、飞行器节点；地面站主要负责接收用户卸载请求、协调卫星参与卸载和预测数据流量分配系统带宽等。

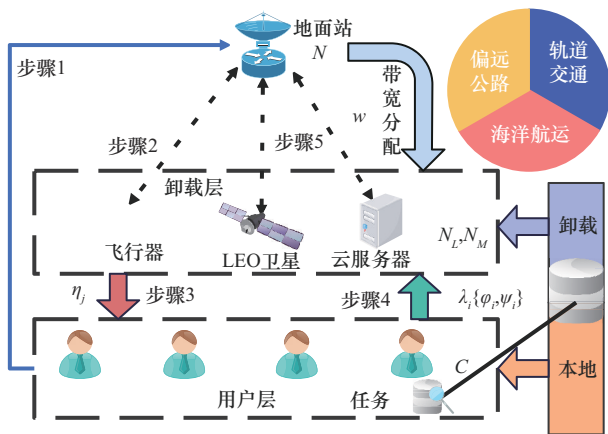


图3 EOSN任务卸载系统

任务卸载请求及决策过程具体分为以下5个步骤。

1) 有任务卸载需求的用户将请求发送给地面站。

2) 地面站将请求信息概要（如卸载任务大小、计算量等）发送给用户通信范围内的LEO卫星节点。

3) LEO卫星节点将自身信息（如信道带宽、CPU频率、卸载定价等）传递给用户。

4) 用户与LEO卫星节点进行信息交互后，选择合适的节点并制定卸载决策。用户确定卸载策略后，向LEO卫星发送卸载请求，LEO卫星接收并通过请求后开始卸载。

5) 任务完成后，由LEO卫星将信息反馈给地面站。

时延和能耗是任务卸载过程中需要考虑的关键因素，本文通过任务卸载具体过程计算时延和能耗。当用户对可划分任务做出卸载决策后，将任务划分为本地处理任务和卸载处理任务。其中，本地处理时延主要是用户自主计算任务所耗费的时间，卸载处理时延包括数据传输时延、卸载节点计算时延和计算结果返回本地时延。一般情况下，计算结果返回本地时延较小，可以忽略不计，因此卸载处理时延主要由数据传输时延和卸载节点计算时延构成。本地处理和卸载处理可以并行运行，因此两者的最大值即本次任务卸载时延。用户能耗主要为处理本地任务能耗和传输数据能耗，卸载节点能耗主要为处理卸载数据能耗。

2.3 系统模型主要参数

本文所使用的主要参数如表1所示。

| 参数 | 含义 |
|------------|------------------------|
| C | 用户数量 |
| N_L | LEO卫星数量 |
| N_M | 云服务器数量 |
| f | 执行任务时CPU频率 |
| λ | 任务卸载比率 |
| p | 数据传输功率 |
| x,y | LEO卫星和云服务器覆盖流量 |
| ϕ_i | 用户 <i>i</i> 卸载任务数据量 |
| ψ_i | 用户 <i>i</i> 卸载任务数据处理周期 |
| w | 传输信道带宽 |
| η | 任务卸载定价 |
| R | 卫星覆盖范围 |
| ϵ | 卫星传输数据成本 |
| r | 数据传输速率 |

系统中共有 C 个用户、 N_L 个LEO卫星、 N_M 个云服务器和一个地面站 N 。令 C 、 N_L 和 N_M 分别表示用

户、LEO卫星和云服务器的集合。其中, $C = \{C_i | i \in \{1, 2, \dots, C\}\}$, $|C| = C$, $N_L = \{L_j | j \in \{1, 2, \dots, N_L\}\}$, $|N_L| = N_L$, $N_M = \{M_k | k \in \{1, 2, \dots, N_M\}\}$, $|N_M| = N_M$ 。用户 i 可定义为 $C_i = \{\lambda_i, f_i^l, p_i\}$, λ_i 为用户卸载比率, f_i^l 为用户本地计算的CPU频率, p_i 为用户数据传输功率。用户 i 所需传输任务定义为 $DT_i = \{\phi_i^{DT}\}$, 定义传输任务的阈值分别为 φ_1 和 φ_2 , $\phi_i^{DT} < \varphi_1$ 时传输任务为小型数据任务, $\varphi_1 \leq \phi_i^{DT} < \varphi_2$ 时为中型数据任务, $\phi_i^{DT} \geq \varphi_2$ 时为大型数据任务。卸载任务定义为 $OT_i = \{\phi_i^{OT}, \psi_i^{OT}\}$, ϕ_i 为数据量, ψ_i 为处理数据所需的CPU周期。

LEO卫星 j (LEO _{j}) 可定义为 $L_j = \{w_{L_j}(t), \eta_{L_j}, \varepsilon_{L_j, C}, \varepsilon_{L_j, N}, f_{L_j}^o, x_j(t), R_{L_j}\}$, $w_{L_j}(t)$ 为LEO _{j} 在 t 时刻分配的信道带宽, η_{L_j} 为LEO _{j} 通信服务定价, $\varepsilon_{L_j, N}$ 和 $\varepsilon_{L_j, C}$ 分别为LEO _{j} 从地面站缓存数据和传输数据给所需用户的单位成本, $f_{L_j}^o$ 为LEO _{j} 计算卸载任务时的CPU频率, $x_j(t)$ 为 t 时刻LEO _{j} 覆盖范围内的数据流量, R_{L_j} 为LEO _{j} 的覆盖范围, 只有当用户 i 在其覆盖范围内才能顺利通信。云服务器 k 定义为 $M_k = \{w_{M_k}(t), \eta_{M_k}, \varepsilon_{M_k, N}, \varepsilon_{M_k, C}, f_{M_k}^o, y_k(t), R_{M_k}\}$, 各变量定义与 L_j 对应一致。该EOSN系统通过ARIMA模型预测数据流量后, 通过LEO卫星和云服务器为用户提供相应的通信服务。

3 问题建模

本节主要对系统中的数据流量预测的ARIMA、EOSN差分化数据传输和EOSN任务卸载3种模型进行建模。

3.1 数据流量预测的ARIMA

本文针对不同类型的网络终端建立流量预测模型。ARIMA模型是研究时间序列的一种重要方法, 该模型包括自回归(AR, autoregression)部分、差分部分和移动平均(MA, moving average)部分, 本文在此基础上提出了改进ARIMA模型。

3.1.1 AR模型

AR模型表示为 $x_j(t) = \Delta x + \kappa_1 x_j(t-1) + \kappa_2 x_j(t-2) + \dots + \kappa_p x_j(t-p)$ 。其中, Δx 是常数, $\kappa_1, \kappa_2, \dots, \kappa_p$ 是自回归系数, 代表第 p 个滞后项对当前时间点的相对影响程度。

3.1.2 MA模型

MA模型表示为 $x_j(t) = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$ 。其中, μ 是时间序列的均值或期望, $\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}$ 是白噪声项, $\theta_1, \theta_2, \dots, \theta_q$ 是MA模型的参数, 用于衡量对应白噪声对当前时间点的影响程度, q 是阶数, 指过去白噪声项的数量。

3.1.3 改进ARIMA模型

ARMA模型仅适用于时间序列平稳的情况, 当时序序列非平稳时, 其统计特性会随着时间发生改变, ARMA模型不再适用。因此本文引入差分项, 通过差分处理使非平稳序列转化为平稳序列, 从而得到ARIMA模型。随着预测时间的增长, 预测结果受噪声的影响也逐渐增大, 为了减小噪声对预测结果的影响, 本文在原有ARIMA模型的基础上引入噪声补偿函数 $f(t)$, 进一步提高了预测精度, 改进ARIMA模型为 $\left(1 - \sum_{i=1}^p \kappa_i L^i\right) (1 - L)^s x_j(t) = \left(1 + \sum_{i=1}^q \theta_i L^i\right) \varepsilon_t + f(t)$ 。其中, p 是自回归部分, s 是差分阶数, q 是移动平均部分, L 是滞后算子, $L^1 x_j(t) = x_j(t-1)$, $L^2 x_j(t) = x_j(t-2)$ 。

随预测时间改变的噪声补偿函数可表示为

$$f(t) = \begin{cases} 0, & x_j(t+h) \leq \mu \\ c, & x_j(t+h) > \mu \end{cases} \quad (1)$$

其中, $x_j(t+h)$ 表示预测的未来 h 时刻的值, μ 表示原时间序列的均值, c 为常数。

在改进ARIMA模型确定数据流量的基础上, 本文利用LSTM模型对用户轨迹进行预测, 提出了LSTM-ARIMA区域流量分布预测算法。其中, LSTM模型是一种特殊的神经网络, 适用于分析顺序数据, 在预测行迹的任务上比其他方法更有优势^[30]。基于预测结果对LEO卫星互联网中的带宽资源进行针对性分配, 得到随时间 t 变化的动态带宽 $w_{L_j}(t)$ 和 $w_{M_k}(t)$ 分别为

$$w_{L_j}(t) = \frac{x_j(t)}{N_L} w_1 \quad (2)$$

$$w_{M_k}(t) = \frac{y_k(t)}{N_M} w_2 \quad (3)$$

其中, w_1 和 w_2 分别为卫星网络分配给 LEO 卫星和云服务器的总带宽, 这种基于流量预测分配系统带宽的方法符合未来卫星网络的应用前景与发展趋势。

3.2 EOSN 差分化数据传输

用户 i 的效用函数为

$$U_{C_i}^{\text{DT}} = F(T, T') - H(\eta) \quad (4)$$

其中, $F(T, T')$ 是通过 LEO 卫星辅助传输数据相较于直接传输所节约时间的满意度函数, T 是全部数据直接传输至用户 i 所需的时间, T' 是通过 LEO 卫星辅助传输数据所消耗的时间, $H(\eta)$ 是用户 i 需要支付给辅助传输 LEO 卫星的费用。LEO _{j} 和云服务器 k 的效用函数分别为

$$U_{L_j}^{\text{DT}} = H(\eta_{L_j}) - L(\lambda) \quad (5)$$

$$U_{M_k}^{\text{DT}} = H(\eta_{M_k}) - L(\lambda) \quad (6)$$

其中, $H(\eta)$ 为 LEO 卫星或云服务器从用户处获得的直接收益, $L(\lambda)$ 是由传输数据比率确定的成本函数。用户 i 与 LEO _{j} 数据传输速率可表示为

$$r_{C_i}^{L_j} = w_{L_j} \text{lb} \left(1 + \frac{P_i g_i}{w_{L_j} O} \right) \quad (7)$$

其中, O 为高斯白噪声功率谱密度, 用户与 LEO 卫星之间的信道可建模为具有自由空间传播损耗的瑞利衰落信道, 信道增益 g_i 表示为

$$g_i = \frac{|h_i|^2}{L_0 d_{ij}^\rho} \quad (8)$$

其中, h_i 为服从 (0,1) 高斯分布的随机变量, L_0 和 ρ 分别是路径损失常数和路径损失指数, d_{ij} 为用户 i 与 LEO _{j} 之间相隔的距离, 即 $d_{ij} = |x_i - y_j|$ 。 h_i 和 $r_{C_i}^{L_j}$ 为随机变量, 因此需计算 $r_{C_i}^{L_j}$ 的期望 $E_{h_i} \{r_{C_i}^{L_j}\}$, 可根据文献[31]中的方法进行计算, 如式(9)和式(10)所示。

$$E_{h_i} \{r_{C_i}^{L_j}\} = \frac{w_{L_j}}{\ln 2} e^{\frac{1}{\text{SNR}_{C_i}^{L_j}}} \left[T_K(t_K) - T_K\left(\frac{1}{\text{SNR}_{C_i}^{L_j}}\right) \right] \quad (9)$$

$$T_K(x) \stackrel{\Delta}{=} \ln x + \sum_{n=1}^K \frac{(-1)^n x^n}{n \cdot n!} \quad (10)$$

其中, K 是控制近似精度的泰勒阶参数, 取值为 3; $\text{SNR}_{C_i}^{L_j}$ 为从用户 i 到 LEO _{j} 的信噪比。

由于 t_K 为 $\sum_{n=0}^K \frac{(-t_K)^n}{n!} = 0$ 的解, 因此可以得到数据传输速率 $r_{C_i}^{L_j}$ 、 $r_{C_i}^{M_k}$ 、 $r_{C_i}^N$ 、 $r_{L_j}^N$ 和 $r_{M_k}^N$ 。如果用户 i

直接从云服务器或地面站获取数据, 则所需时延为

$$T_{M_k} = \frac{\phi_i^{\text{DT}}}{r_{C_i}^{M_k}}, \quad T_N = \frac{\phi_i^{\text{DT}}}{r_{C_i}^N}.$$

在用户请求辅助传输的前提下, 假设其辅助传输任务量为 $\lambda_i \phi_i$, 那么直接传输的任务量为 $(1 - \lambda_i) \phi_i$ 。本文对 3 类数据传输场景中 LEO 卫星、云服务器与用户的效用函数进行分析。

3.2.1 小型数据 ($\phi_i^{\text{DT}} < \phi_1$) 传输效用函数

云服务器直接传输部分数据到用户 i , 再由 LEO 卫星辅助传输剩余的数据, 所需的时延为

$$T' = \max \left[\frac{(1 - \lambda_i) \phi_i^{\text{DT}}}{r_{C_i}^{M_k}}, \frac{\lambda_i \phi_i^{\text{DT}}}{r_{C_i}^{L_j}} \right] \quad (11)$$

其中, $\frac{(1 - \lambda_i) \phi_i^{\text{DT}}}{r_{C_i}^{M_k}}$ 表示云服务器直接传输给用户 $(1 - \lambda_i) \phi_i^{\text{DT}}$ 数据量所产生的时延, $\frac{\lambda_i \phi_i^{\text{DT}}}{r_{C_i}^{L_j}}$ 表示 LEO

卫星辅助传输 $\lambda_i \phi_i^{\text{DT}}$ 数据量所产生的时延, 两者中耗时较长一方所花费的时间即完成该任务所需的总时延。

本次辅助传输能缩短的时延是直接传输与辅助传输之间的时间差, 即 $T_1 = T_{L_k} - T'$ 。满意度函数是随节约时间梯度下降的递增函数, 定义为 $F(T_1) = \ln(1 + T_1)$ 。

用户 i 辅助传输的成本是由 LEO 卫星定价 η_{L_j} 决定的支出, 可定义为

$$H(\eta_{L_j}) = \eta_{L_j} \lambda_i \phi_i^{\text{DT}} \quad (12)$$

U_{C_i} 具体表示为

$$U_{C_i}^{\text{DT}} = \alpha_1 \ln(1 + T_1) - \alpha_2 (\eta_{L_j} \lambda_i \phi_i^{\text{DT}}) \quad (13)$$

其中, α_1, α_2 表示用户 i 对该数据传输任务重视程度的归一化因子, 满足 $\alpha_1 + \alpha_2 = 1$, $0 < \alpha_1 < 1$, $0 < \alpha_2 < 1$ 且 $\alpha_2 \ll \alpha_1$ 。

LEO _{j} 的成本函数为

$$L(\lambda_i) = \varepsilon_{L_j C} \lambda_i \phi_i^{\text{DT}} \quad (14)$$

LEO _{j} 的效用函数为

$$U_{L_j}^{\text{DT}} = (\eta_{L_j} - \varepsilon_{L_j C}) \lambda_i \phi_i^{\text{DT}} \quad (15)$$

当 LEO 卫星辅助传输数据收益大于成本时, $U_{L_j}^{\text{DT}}$ 是正数; 当 LEO 卫星辅助传输数据收益小于成本时, $U_{L_j}^{\text{DT}}$ 是负数。

3.2.2 中型数据 ($\varphi_1 \leq \phi_i^{\text{DT}} < \varphi_2$) 传输效用函数

用户 i 直接从地面站获取部分数据, 再由 LEO 卫星辅助传输所需剩余数据, 其时延定义为

$$T'' = \max \left[\frac{(1 - \lambda_i) \phi_i^{\text{DT}}}{r_{C_i}^N}, \frac{\lambda_i \phi_i^{\text{DT}}}{r_{L_j}^N} + \frac{\lambda_i \phi_i^{\text{DT}}}{r_{C_i}^{L_j}} \right] \quad (16)$$

其中, $\frac{(1 - \lambda_i) \phi_i^{\text{DT}}}{r_{C_i}^N}$ 表示用户 i 直接从地面站获取

$(1 - \lambda_i) \phi_i^{\text{DT}}$ 数据量所产生的时延, $\frac{\lambda_i \phi_i^{\text{DT}}}{r_{L_j}^N} + \frac{\lambda_i \phi_i^{\text{DT}}}{r_{C_i}^{L_j}}$ 表

示 LEO 卫星辅助传输 $\lambda_i \phi_i^{\text{DT}}$ 数据量所产生的时延, 两者之间耗时较长的一方所花费的时间即总时延。

用户 i 的效用函数为

$$U_{C_i}^{\text{DT}} = \alpha_1 \ln(1 + T_2) - \alpha_2 \eta_{L_j} \lambda_i \phi_i^{\text{DT}} \quad (17)$$

其中, $T_2 = T_N - T''$ 。

LEO _{j} 成本函数定义为

$$L(\lambda_i) = (\varepsilon_{L_j N} + \varepsilon_{L_j C}) \lambda_i \phi_i^{\text{DT}} \quad (18)$$

LEO _{j} 的效用函数为

$$U_{L_j}^{\text{DT}} = (\eta_{L_j} - \varepsilon_{L_j N} - \varepsilon_{L_j C}) \lambda_i \phi_i^{\text{DT}} \quad (19)$$

3.2.3 大型数据 ($\phi_i^{\text{DT}} \geq \varphi_2$) 传输效用函数

用户 i 直接从地面站获取部分数据, 由于数据量较大, 可由 LEO 卫星和云服务器联合传输剩余数据, 其时延定义为

$$T''' = \max \left[\frac{(1 - \lambda_i) \phi_i^{\text{DT}}}{r_{C_i}^N}, \frac{\gamma \lambda_i \phi_i^{\text{DT}}}{r_{M_k}^N} + \frac{\gamma \lambda_i \phi_i^{\text{DT}}}{r_{C_i}^{M_k}} \right] \quad (20)$$

其中, $\frac{(1 - \lambda_i) \phi_i^{\text{DT}}}{r_{C_i}^N}$ 表示用户 i 从地面站直接获取

$(1 - \lambda_i) \phi_i^{\text{DT}}$ 数据量任务所产生的时延, $\frac{\gamma \lambda_i \phi_i^{\text{DT}}}{r_{M_k}^N} +$

$\frac{\gamma \lambda_i \phi_i^{\text{DT}}}{r_{C_i}^{M_k}}$ 表示云服务器 k 缓存临时备份 $\lambda_i \phi_i^{\text{DT}}$ 再传输给

用户所产生的时延, 两者耗时较长的一方所花费的时间即用户处理该下载任务的总时延, γ 表示由 LEO 卫星传输任务 $\lambda_i \phi_i^{\text{DT}}$ 的比率, 云服务器承担本次辅助传输任务中大部分数据, 因此应满足条件

$$\frac{\gamma}{r_{M_k}^N} + \frac{\gamma}{r_{C_i}^{M_k}} > \frac{1 - \gamma}{r_{L_j}^N} + \frac{1 - \gamma}{r_{C_i}^{L_j}}$$

用户 i 的效用函数为

$$U_{C_i}^{\text{DT}} = \alpha_1 \ln(1 + T_3) - \alpha_2 [\eta_{L_j} (1 - \gamma) \lambda_i \phi_i^{\text{DT}} + \eta_{M_k} \gamma \lambda_i \phi_i^{\text{DT}}] \quad (21)$$

其中, $\eta_{L_j} (1 - \gamma) \lambda_i \phi_i^{\text{DT}}$ 是用户对 LEO _{j} 的支付费用, $\eta_{M_k} \gamma \lambda_i \phi_i^{\text{DT}}$ 是用户对云服务器 k 的支付费用, 且 $T_3 = T_N - T'''$ 。

LEO _{j} 和云服务器 k 的效用函数分别为

$$U_{L_j}^{\text{DT}} = [\eta_{L_j} (1 - \gamma) - \varepsilon_{L_j N} - \varepsilon_{L_j C}] \lambda_i \phi_i^{\text{DT}} \quad (22)$$

$$U_{M_k}^{\text{DT}} = (\eta_{M_k} \gamma - \varepsilon_{M_k N} - \varepsilon_{M_k C}) \lambda_i \phi_i^{\text{DT}} \quad (23)$$

其中, $\eta_{L_j} (1 - \gamma) \lambda_i \phi_i^{\text{DT}}$ 为 LEO _{j} 通过收取辅助传输任务费用所产生的效益, $(\varepsilon_{L_j N} + \varepsilon_{L_j C}) \lambda_i \phi_i^{\text{DT}}$ 为 LEO _{j} 在本次任务中消耗的单位成本, $\eta_{M_k} \gamma \lambda_i \phi_i^{\text{DT}}$ 为云服务器 k 通过收取辅助传输任务费用所产生的效益, $(\varepsilon_{M_k N} + \varepsilon_{M_k C}) \lambda_i \phi_i^{\text{DT}}$ 为 LEO _{j} 在本次任务中消耗的单位成本。

3.3 EOSN 任务卸载

用户 i 进行任务卸载时效用函数与数据传输时不同, 考虑用户对卸载满意度, 具体表示为

$$U_{C_i}^{\text{OT}} = F(t_i^l, t_i^o, e_i^l, e_i^o) - H(\eta) \quad (24)$$

其中, $F(t_i^l, t_i^o, e_i^l, e_i^o)$ 是用户 i 对本次计算卸载的满意度函数, t_i^l 是用户 i 本地计算任务产生的时延, t_i^o 是卸载任务的时延, e_i^l 是用户 i 本地计算任务产生的能耗, e_i^o 是用户 i 卸载任务的能耗, $H(\eta)$ 是用户 i 对卸载 LEO 卫星的支出。

LEO _{j} 的效用函数为

$$U_{L_j}^{\text{OT}} = H(\eta_{L_j}) - L(\lambda) \quad (25)$$

其中, $H(\eta_{L_j})$ 为 LEO _{j} 从用户 i 处获得的直接收益, $L(\lambda)$ 为 LEO _{j} 根据任务卸载比率的能耗成本函数。

任务 OT _{i} 由用户本地计算处理所需的时间为

$$t_i^l = \frac{\psi_i^{\text{OT}}}{f_i^l} \quad (26)$$

用户 i 的 CPU 功率 p_i^l 可以看作 CPU 频率 f_i^l 的超线性函数, 如式(27)所示。

$$p_i^l = \xi (f_i^l)^\mu \quad (27)$$

其中, ξ 为功率消耗系数, 一般取 $\xi = 10^{-11}$; μ 为功率消耗指数, 取值为 2。

用户 i 单独处理任务所需能耗为

$$e_i^l = p_i^l t_i^l = \zeta \psi_i^{\text{OT}} (f_i^l)^{\mu-1} \quad (28)$$

将数据传输时间设为 t_i^{tx} , 那么卸载数据量 $\lambda_i \phi_i^{\text{OT}}$ 与传输时间 t_i^{tx} 的关系为

$$t_i^{\text{tx}} = \frac{\lambda_i \phi_i^{\text{OT}}}{r_{C_i}^{L_j}} \quad (29)$$

传输能耗 e_i^{tx} 为

$$e_i^{\text{tx}} = p_i t_i^{\text{tx}} \quad (30)$$

用户 i 将部分任务卸载至 LEO _{j} 计算, 计算时间可表示为

$$t_i^{\text{ex}}(f_j^o) = \frac{\lambda_i \psi_i^{\text{OT}}}{f_j^o} \quad (31)$$

用户 i 卸载任务所需总时间为本地处理剩余任务时间与卸载任务时间的最大值, 如式(32)所示。

$$t_i^o = \max \left\{ \frac{(1 - \lambda_i) \psi_i^{\text{OT}}}{f_i^l}, t_i^{\text{tx}} + t_i^{\text{ex}} \right\} \quad (32)$$

用户 i 的总能耗为本地处理剩余任务的能耗与传输数据能耗之和, 如式(33)所示。

$$e_i^o = (1 - \lambda_i) \zeta \psi_i^{\text{OT}} (f_i^l)^{\mu-1} + e_i^{\text{tx}} \quad (33)$$

用户 i 的效用函数为

$$U_{C_i}^{\text{OT}} = \ln \left\{ 1 + \left[\beta_1 \left(\frac{t_i^l - t_i^o}{t_i^l} \right) + \beta_2 \left(\frac{e_i^l - e_i^o}{e_i^l} \right) \right] \right\} \psi_i^{\text{OT}} - \delta_1 \lambda_i \psi_i^{\text{OT}} \eta_{L_j} \quad (34)$$

其中, β_1 和 β_2 为用户 i 对任务能耗和时延的优先级参数, δ_1 为用户 i 对 LEO _{j} 支付的调整因子。值得注意的是,

用户 i 的任务卸载收益为 $\frac{\beta_1(t_i^l - t_i^o)}{t_i^l} + \frac{\beta_2(e_i^l - e_i^o)}{e_i^l}$, 代表用户任务卸载体验相对于本地执行的改进程度。时延和能耗的改进程度分别用 $\frac{t_i^l - t_i^o}{t_i^l}$ 和 $\frac{e_i^l - e_i^o}{e_i^l}$ 衡量。当任务在本地执行时, 用户效用函数等于 0。如果卸载执行任务比本地执行的时间

和能耗更少, 那么 $\frac{\beta_1(t_i^l - t_i^o)}{t_i^l} + \frac{\beta_2(e_i^l - e_i^o)}{e_i^l}$ 是正的。但由于大量资源争用或 LEO 承担了过多卸载任务, 因此任务时延更大。在该情况下,

$\frac{\beta_1(t_i^l - t_i^o)}{t_i^l} + \frac{\beta_2(e_i^l - e_i^o)}{e_i^l}$ 可以是负数。此外, 本文将任务优先级分为时延优先和能耗优先。若用户对任务时延要求较高, 则在运行卸载算法时可以设置

较高的 β_1 ; 若用户对能耗比较关注, 想减少任务卸载能耗, 可以设置较高的 β_2 。 β_1 和 β_2 满足条件 $\beta_1 + \beta_2 = 1$, $\beta_1 \geq 0$, $\beta_2 \geq 0$ 。

LEO _{j} 的 CPU 功率和能耗分别为

$$p_j^o = \xi (f_j^o)^\mu \quad (35)$$

$$e_{L_j}^o = p_j^o t_i^{\text{ex}} = \xi \lambda_i \psi_i^{\text{OT}} (f_j^o)^{\mu-1} \quad (36)$$

效用函数为收入与能耗间的差值, 如式(37)所示。

$$U_{L_j}^{\text{OT}} = \delta_2 \lambda_i \psi_i^{\text{OT}} \eta_j - \xi \lambda_i \psi_i^{\text{OT}} (f_j^o)^{\mu-1} \quad (37)$$

其中, δ_2 为 LEO _{j} 收入与能耗之间的调整因子, 定价 $\eta_j \leq \eta_{\max}$ 。

3.4 问题建模及最优决策

用户和卫星之间的博弈可以建模为一个 Stackelberg 博弈, 其中卫星作为领导者, 用户作为追随者。博弈分为 2 个阶段: 每个卫星提供服务定价 η ; 用户根据定价 η 确定任务处理百分比 λ 。用户选择定价最低的卫星节点来辅助处理任务, 因此, 本文提出 EOSN 差异化数据传输和任务卸载的问题建模和最优决策。

3.4.1 EOSN 差异化数据传输

在 EOSN 差异化数据传输过程中, 根据其类型分别建模为以下 3 种优化问题。

问题 1 小型数据 ($\phi_i^{\text{DT}} < \phi_1$) 传输

$$\begin{aligned} \max_{\lambda_i} U_{C_i}^{\text{DT}} &= \alpha_1 \ln(1 + T_1) - \alpha_2 \eta_{L_j} \lambda_i \phi_i^{\text{DT}} \\ \text{s.t. C1: } &0 < \lambda_i < 1 \\ &\text{C2: } 0 < T_1 \end{aligned} \quad (38)$$

$$\begin{aligned} \max_{\eta_{L_j}} U_{L_j}^{\text{DT}} &= (\eta_{L_j} - \varepsilon_{L_j C}) \lambda_i \phi_i^{\text{DT}} \\ \text{s.t. C1: } &0 < \eta_{L_j} < \eta_{L_j, \max} \end{aligned} \quad (39)$$

问题 2 中型数据 ($\phi_1 \leq \phi_i^{\text{DT}} < \phi_2$) 传输

$$\begin{aligned} \max_{\lambda_i} U_{C_i}^{\text{DT}} &= \alpha_1 \ln(1 + T_2) - \alpha_2 \eta_{L_j} \lambda_i \phi_i^{\text{DT}} \\ \text{s.t. C1: } &0 < \lambda_i < 1 \\ &\text{C2: } 0 < T_2 \end{aligned} \quad (40)$$

$$\begin{aligned} \max_{\eta_{L_j}} U_{L_j}^{\text{DT}} &= (\eta_{L_j} - \varepsilon_{NL_j} - \varepsilon_{L_j C}) \lambda_i \phi_i^{\text{DT}} \\ \text{s.t. C1: } &0 < \eta_{L_j} < \eta_{L_j, \max} \end{aligned} \quad (41)$$

问题 3 大型数据 ($\phi_i^{\text{DT}} \geq \phi_2$) 传输

$$\begin{aligned} \max_{\lambda_i} U_{C_i}^{\text{DT}} &= \alpha_1 \ln(1 + T_3) - \\ &\alpha_2 (\eta_{L_j} (1 - \gamma) \lambda_i \phi_i + \eta_{M_k} \gamma \lambda_i \phi_i) \\ \text{s.t. C1: } &0 < \lambda_i < 1 \\ &\text{C2: } 0 < T_3 \end{aligned} \quad (42)$$

$$\begin{aligned} \max_{\eta_{L_j}} U_{L_j}^{DT} &= (\eta_{L_j} - \varepsilon_{L_jN} - \varepsilon_{L_jC}) (1 - \gamma) \lambda_i \phi_i^{DT} \\ \text{s.t. C1: } 0 &< \eta_{L_j} < \eta_{L_j \max} \end{aligned} \quad (43)$$

$$\begin{aligned} \max_{\eta_{M_k} > 0} U_{M_k}^{DT} &= (\eta_{M_k} - \varepsilon_{M_kN} - \varepsilon_{M_kC}) \gamma \lambda_i \phi_i^{DT} \\ \text{s.t. C1: } 0 &< \eta_{M_k} < \eta_{M_k \max} \end{aligned} \quad (44)$$

其中, η_{\max} 是卫星的最高定价。

综上所述, 可以得到3种优化问题中用户最优传输比率和卫星节点最优定价决策, 分别如定理1、引理1和引理2所示。

定理1 满足问题1的用户*i*最优传输比率为

$$\eta_{L_j}^* = \begin{cases} \max \left(\frac{\alpha_1 W}{\alpha_2 (r_{C_i}^{L_j} \phi_i^{DT} + r_{C_i}^{M_k} W)}, \varepsilon_{L_jC} \right), \eta_{L_j}^{\#} \leq \max \left(\frac{\alpha_1 W}{\alpha_2 (r_{C_i}^{L_j} \phi_i^{DT} + r_{C_i}^{M_k} W)}, \varepsilon_{L_jC} \right) \\ \eta_{L_j}^{\#}, \max \left(\frac{\alpha_1 W}{\alpha_2 (r_{C_i}^{L_j} \phi_i^{DT} + r_{C_i}^{M_k} W)}, \varepsilon_{L_jC} \right) < \eta_{L_j}^{\#} < \min \left(\frac{\alpha_1}{\alpha_2 r_{C_i}^{M_k}}, \eta_{L_j \max} \right) \\ \min \left(\frac{\alpha_1}{\alpha_2 r_{C_i}^{M_k}}, \eta_{L_j \max} \right), \eta_{L_j}^{\#} \geq \min \left(\frac{\alpha_1}{\alpha_2 r_{C_i}^{M_k}}, \eta_{L_j \max} \right) \end{cases} \quad (46)$$

其中, $\max \left(\frac{\alpha_1 W}{\alpha_2 (r_{C_i}^{L_j} \phi_i^{DT} + r_{C_i}^{M_k} W)}, \varepsilon_{L_jC} \right)$ 和 $\min \left(\frac{\alpha_1}{\alpha_2 r_{C_i}^{M_k}}, \eta_{L_j \max} \right)$ 分别代表云服务器*j*的定价 η_{L_j} 的最小值和最大值, 且 $W = r_{C_i}^{L_j} + r_{C_i}^{M_k}$ 。

证明 详见附录1。

引理1 满足问题2的用户*i*最优传输比率和云服务器*j*最优数据传输定价策略为

$$\lambda_i^* = \begin{cases} 0, \eta_{L_j} \geq \frac{\alpha_1}{\alpha_2 r_{C_i}^N} \\ \lambda_i^{\#}, D < \eta_{L_j} < \frac{\alpha_1}{\alpha_2 r_{C_i}^N} \\ \lambda_i^0, \eta_{L_j} \leq D \end{cases} \quad (47)$$

$$\eta_{L_j}^* = \begin{cases} \max \left(D, \varepsilon_{L_jN} + \varepsilon_{L_jC} \right), \eta_{L_j}^{\#} \leq \max \left(D, \varepsilon_{L_jN} + \varepsilon_{L_jC} \right) \\ \eta_{L_j}^{\#}, \max \left(D, \varepsilon_{L_jN} + \varepsilon_{L_jC} \right) < \eta_{L_j}^{\#} < \min \left(\frac{\alpha_1}{\alpha_2 r_{C_i}^N}, \eta_{L_j \max} \right) \\ \min \left(\frac{\alpha_1}{\alpha_2 r_{C_i}^N}, \eta_{L_j \max} \right), \eta_{L_j}^{\#} \geq \min \left(\frac{\alpha_1}{\alpha_2 r_{C_i}^N}, \eta_{L_j \max} \right) \end{cases} \quad (48)$$

$$\lambda_i^* = \begin{cases} 0, \eta_{L_j} \geq \frac{\alpha_1}{\alpha_2 r_{C_i}^{M_k}} \\ \lambda_i^{\#}, \frac{\alpha_1 (r_{C_i}^{L_j} + r_{C_i}^{M_k})}{\alpha_2 (r_{C_i}^{L_j} \phi_i + r_{C_i}^{M_k} r_{C_i}^{L_j} + r_{C_i}^{M_k} r_{C_i}^{M_k})} < \eta_{L_j} < \frac{\alpha_1}{\alpha_2 r_{C_i}^{M_k}} \\ \lambda_i^0, \eta_{L_j} \leq \frac{\alpha_1 (r_{C_i}^{L_j} + r_{C_i}^{M_k})}{\alpha_2 (r_{C_i}^{L_j} \phi_i + r_{C_i}^{M_k} r_{C_i}^{L_j} + r_{C_i}^{M_k} r_{C_i}^{M_k})} \end{cases} \quad (45)$$

其中, $\frac{\alpha_1 (r_{C_i}^{L_j} + r_{C_i}^{M_k})}{\alpha_2 (r_{C_i}^{L_j} \phi_i^{DT} + r_{C_i}^{M_k} r_{C_i}^{L_j} + r_{C_i}^{M_k} r_{C_i}^{M_k})}$ 为 $\lambda_i^0 = \lambda_i^{\#}$ 时 η_{L_j} 的值。

云服务器*j*的最优定价策略为

其中, $D = \frac{\alpha_1 W^*}{\alpha_2 (\phi_i^{DT} r_{L_j}^N + W^* r_{C_i}^N)}$ 表示满足条件 $\lambda_i^0 = \lambda_i^{\#}$ 时云服务器*j*定价 η_{L_j} 所取的值, 且 $W^* = r_{L_j}^N r_{C_i}^{L_j} + r_{C_i}^N r_{C_i}^{L_j} + r_{C_i}^N r_{L_j}^N$, $\max (D, \varepsilon_{L_jN} + \varepsilon_{L_jC})$ 和 $\min \left(\frac{\alpha_1}{\alpha_2 r_{C_i}^N}, \eta_{L_j \max} \right)$ 分别代表云服务器*j*定价 η_{L_j} 的最小值和最大值。

证明 该情况与问题1类似, 因此引理1的证明过程与定理1类似。

引理2 满足问题3的用户*i*最优传输比率为

$$\lambda_i^* = \begin{cases} 0, \left\{ \eta_{L_j}, \eta_{M_k} \mid \alpha_2 [\eta_{L_j} (1 - \gamma) + \eta_{M_k} \gamma] \geq \frac{\alpha_1}{r_{C_i}^N} \right\} \\ \lambda_i^{\#}, \left\{ \eta_{L_j}, \eta_{M_k} \mid \alpha_2 [\eta_{L_j} (1 - \gamma) + \eta_{M_k} \gamma] < \frac{\alpha_1}{r_{C_i}^N} \right\} \\ \lambda_i^0, \left\{ \eta_{L_j}, \eta_{M_k} \mid \alpha_2 [\eta_{L_j} (1 - \gamma) + \eta_{M_k} \gamma] < \frac{\alpha_1}{r_{C_i}^N} \right\} \end{cases} \quad (49)$$

其中, $\alpha_2 [\eta_{L_j} (1 - \gamma) + \eta_{L_k} \gamma]$ 为用户*i*请求辅助下载的单位成本。

LEO_j和云服务器k的联合最优定价策略为

$$\left(\eta_{L_j}^*, \eta_{M_k}^*\right) = \begin{cases} (A_1, B_1), & \eta_{L_j}^\# \leq A_1, \eta_{M_k}^\# \leq B_1 \\ \left(\eta_{L_j}^\#, \eta_{M_k}^\#\right), & A_1 < \eta_{L_j}^\# < A_2, B_1 < \eta_{M_k}^\# < B_2 \\ (A_2, B_2), & \eta_{L_j}^\# > A_2, \eta_{M_k}^\# > B_2 \end{cases} \quad (50)$$

其中, (A₁, B₁)和(A₂, B₂)分别表示LEO_j和云服务器k定价η_{L_j}和η_{M_k}的最大值和最小值, 满足

$$\begin{aligned} A_1 &= \max(\eta_{L_j}', \varepsilon_{L_j N} + \varepsilon_{L_j C}) \\ B_1 &= \max(\eta_{M_k}', \varepsilon_{M_k N} + \varepsilon_{M_k C}) \\ A_2 &= \min(\eta_{L_j}'', \eta_{L_j, \max}) \\ B_2 &= \min(\eta_{M_k}'', \eta_{M_k, \max}) \end{aligned} \quad (51)$$

其中, η_{L_j}'和η_{M_k}'分别为满足条件λ_i[#] = λ_i⁰的η_{L_j}和η_{M_k}的值, η_{L_j}''和η_{M_k}''分别为满足条件α₂[η_{L_j}(1 - γ) + η_{M_k}γ] = $\frac{\alpha_1}{r_{C_i}^N}$ 的η_{L_j}和η_{M_k}的值。

证明 该情况与问题1类似, 因此引理2的证明过程与定理1类似。

3.4.2 EOSN任务卸载

将EOSN任务卸载过程建模为受卸载比率λ_i影响的用户i的效用和受定价η_{L_j}影响的LEO_j的效用函数。

问题4 EOSN任务卸载

$$\begin{aligned} \max_{\lambda_i} U_{C_i}^{\text{OT}} &= \ln \left\{ 1 + \left[\beta_1 \left(\frac{t_i^l - t_i^o}{t_i^l} \right) + \beta_2 \left(\frac{e_i^l - e_i^o}{e_i^l} \right) \right] \right\} \psi_i^{\text{OT}} - \\ &\delta_1 \lambda_i \psi_i^{\text{OT}} \eta_{L_j} \\ \text{s.t. C1:} &0 < \lambda_i < 1 \\ \text{C2:} &t_i^l > t_i^o \\ \text{C3:} &e_i^l > e_i^o \end{aligned} \quad (52)$$

$$\begin{aligned} \max_{\eta_{L_j}} U_{L_j}^{\text{OT}} &= \delta_2 \lambda_i \psi_i^{\text{OT}} \eta_{L_j} - \zeta \lambda_i \psi_i^{\text{OT}} (f_j^o)^\mu - 1 \\ \text{s.t. C1:} &0 < \eta_{L_j} < \eta_{L_j, \max} \end{aligned} \quad (53)$$

优化问题4中用户的最优卸载决策和卫星的最优卸载定价决策如定理2所示。

定理2 用户任务卸载策略与任务优先级参数β₁和β₂相关, 可分为以下2种情况讨论。

令 $Q = 1 - \frac{p_i \phi_i^{\text{OT}}}{\zeta \psi_i^{\text{OT}} (f_i^l)^\mu - 1 r_{C_i}^{L_j}}$, 当β₁和β₂满足

$$\beta_2 Q - \beta_1 \left(\frac{f_i^l}{f_i^o} + \frac{f_i^l \phi_i^{\text{OT}}}{r_{C_i}^{L_j} \psi_i^{\text{OT}}} \right) \leq 0 \text{ 时, 则有} \quad (54)$$

$$\lambda_i^* = \begin{cases} 0, & \eta_{L_j} \geq \frac{\beta_1 + \beta_2 Q}{\delta_1} \\ \lambda_i^\#, & Y_1 < \eta_{L_j} < \frac{\beta_1 + \beta_2 Q}{\delta_1} \\ \lambda_i^0, & \eta_{L_j} \leq Y_1 \end{cases}$$

其中, Y₁表示λ_i⁰ = λ_i[#]时η_{L_j}的值。

当β₁和β₂满足β₂Q - β₁ $\left(\frac{f_i^l}{f_i^o} + \frac{f_i^l \phi_i^{\text{OT}}}{r_{C_i}^{L_j} \psi_i^{\text{OT}}} \right) > 0$ 时,

则有

$$\lambda_i^* = \begin{cases} 0, & \eta_{L_j} \geq \frac{\beta_1 + \beta_2 Q}{\delta_1} \\ \lambda_i^\#, & Y_1 < \eta_{L_j} < \frac{\beta_1 + \beta_2 Q}{\delta_1} \\ \lambda_i^0, & Y_2 \leq \eta_{L_j} \leq Y_1 \\ \hat{\lambda}_i, & Y_3 < \eta_{L_j} < Y_2 \\ 1, & \eta_{L_j} \leq Y_3 \end{cases} \quad (55)$$

其中, Y₁表示λ_i⁰ = λ_i[#]时η_{L_j}的值, Y₂表示λ_i⁰ = λ_i[^]时η_{L_j}的值, Y₃表示λ_i[^] = 1时η_{L_j}的值。

LEO_j的最优定价策略如下。

当β₁和β₂满足β₂Q - β₁ $\left(\frac{f_i^l}{f_i^o} + \frac{f_i^l \phi_i^{\text{OT}}}{r_{C_i}^{L_j} \psi_i^{\text{OT}}} \right) \leq 0$ 时,

则有

$$\eta_{E_j}^* = \begin{cases} \max(Y_1, 0), & \eta_{L_j}^\# \leq \max(Y_1, 0) \\ \eta_{L_j}^\#, & \max(Y_1, 0) < \eta_{L_j}^\# < \min\left(\frac{\beta_1 + \beta_2 Q}{\delta_1}, \eta_{L_j, \max}\right) \\ \min\left(\frac{\beta_1 + \beta_2 Q}{\delta_1}, \eta_{L_j, \max}\right), & \eta_{L_j}^\# \geq \min\left(\frac{\beta_1 + \beta_2 Q}{\delta_1}, \eta_{L_j, \max}\right) \end{cases} \quad (56)$$

其中, max(Y₁, 0)和min($\frac{\beta_1 + \beta_2 Q}{\delta_1}$, η_{L_j}, max)分别代表LEO_j定价η_{L_j}的最小值及最大值。

当β₁和β₂满足β₂Q - β₁ $\left(\frac{f_i^l}{f_i^o} + \frac{f_i^l \phi_i^{\text{OT}}}{r_{C_i}^{L_j} \psi_i^{\text{OT}}} \right) > 0$ 时,

则有

$$\eta_{L_j}^* = \begin{cases} \max(Y_3, 0), \eta_{L_j}^{\hat{}} \leq \max(Y_3, 0) \\ \eta_{L_j}^{\hat{}}, \max(Y_3, 0) < \eta_{L_j}^{\hat{}} < \max(Y_2, 0) \\ \max(Y_1, 0), \max(Y_2, 0) \leq \eta_{L_j}^{\hat{}} < \eta_{L_j}^{\#} \leq \max(Y_1, 0) \\ \eta_{L_j}^{\#}, \max(Y_1, 0) < \eta_{L_j}^{\#} < \min\left(\frac{\beta_1 + \beta_2 Q}{\delta_1}, \eta_{L_j, \max}\right) \\ \min\left(\frac{\beta_1 + \beta_2 Q}{\delta_1}, \eta_{L_j, \max}\right), \eta_{L_j}^{\#} \geq \min\left(\frac{\beta_1 + \beta_2 Q}{\delta_1}, \eta_{L_j, \max}\right) \end{cases} \quad (57)$$

其中, $\max(Y_1, 0)$ 和 $\max(Y_2, 0)$ 表示LEO_j定价 η_{L_j} 在2种任务卸载情况下的最小值, $\min\left(\frac{\beta_1 + \beta_2 Q}{\delta_1}, \eta_{L_j, \max}\right)$ 代表 η_{L_j} 的最大值。

证明 详见附录2。

4 仿真分析

本节主要对本文所提LSTM-ARIMA流量预测模型及2种EOSN通信服务算法进行仿真评估,通过观察仿真结果对预测模型及算法的性能进行讨论。仿真结果表明,LSTM-ARIMA流量预测算法具有较高的准确性。以预测的不同区域内不同时间段的数据流量为输入,本文所提的LEO卫星互联网资源分配策略可以有效节省通信资源,并为网络终端用户及卫星带来更高收益。

本文选取远洋航运数据作为测试和预测数据集,该场景符合卫星通信网络未来的应用需求。首先,根据船只在航行过程中定时与港口、周围船只以及船上人员、物品的通信需求,模拟了单个船只数据流量随时间的变化,时间单位为小时。仿真数据划分为训练集(70%)和测试集(30%),对ARIMA模型与本文所提的改进ARIMA模型分别进行为期一周(Day15~Day21)的网络流量预测,其中Day1~Day14为真实网络流量。通过观察自相关函数(ACF, autocorrelation function)图和偏自相关函数(PACF, partial autocorrelation function)图,设置模型阶数为 $p = 25$ 、 $q = 1$ 、 $s = 1$ 。实验结果如图4所示,通过与测试集对比可以观察到,原始ARIMA模型虽然能预测流量变化趋势,但是峰值预测准确性较差。本文提出的改进ARIMA模型通过引入误差补偿函数 $f(t)$,使得改进后ARIMA模型的均方根误差(RMSE, root mean squared error)相比原ARIMA模型提升了5.7%,达到了良好的预测效果。

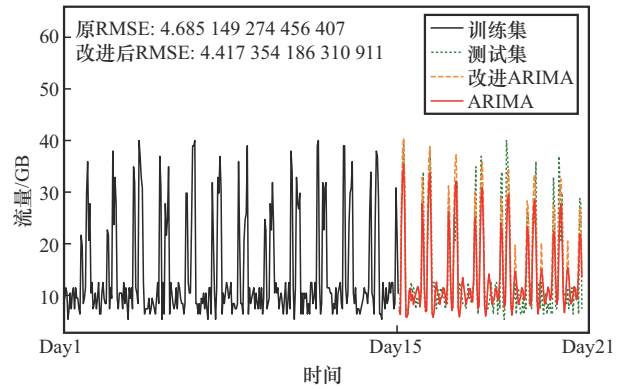


图4 改进ARIMA模型数据流量预测

本文训练改进LSTM-ARIMA模型的目标是将前60 min的海洋航运船只数据作为输入,从而有效预测后60 min指定时间和位置的船只数据流量,并生成流量热力图,然后将该热力图作为输入指导LEO卫星互联网进行资源优化。

本文中的AIS数据集文件来自美国海岸警卫队导航中心官网,所选取的区域是洛杉矶港及其附近海域(经度 -120.00° ~ -117.90° ,纬度 33.00° ~ 33.80°)。具体地,选取2022年12月10日一天中所有船只的AIS数据,这块区域包含整个洛杉矶港及其周边小型岛屿,可以完整反映港口船只进出的情况。

将处理后的数据集序列按照60个时间段(即120 min)为一组进行划分,前30个时间段的数据作为LSTM-ARIMA模型的输入,后30个时间段的数据用于与模型的预测输出进行比较。数据集中的所有数据序列被分成80%的训练集和20%的测试集。改进LSTM-ARIMA模型训练过程包括前向传播和反向传播,在前向传播过程中,建立输入向量和输出向量之间的预测模型。首先,输入层按照数据序列顺序接收输入。然后,经过LSTM单元提升模型的表达能力,在LSTM单元后添加dropout单元,丢弃率设置为0.2,通过在训练过程中随机关闭一部分神经元,防止模型过拟合,增强模型泛化能力。最后,通过全连接层导出预测结果。

在反向传播过程中,本文使用Adam优化器调整权重参数,以优化预测模型。该优化器使用自适应学习率方法,初次设定学习率为0.001。优化器的目标是通过使均方差损失函数最小化(即真实向量和预测向量之间的偏差)微调模型参数,提高模型预测精度。模型训练的迭代次数设置为10次。

如图 5 所示，本文选取 4 个典型区域生成 4 幅流量热力图。首先 LSTM-ARIMA 模型预测一个区域在各个时间段内每个数据块的船只数量，然后流量模型预测不同船只数量的数据块产生的数据流量，最后将每个时间段内所有数据块流量叠加，得到此区域在 17:00—18:00 时间段内的流量密度图，图 5 中的颜色深浅表现了数据流量密度分布，颜色越深表示流量越大。图 5(a) 选取了经度为 $[-118.25^\circ, -118.00^\circ]$ 、纬度为 $[33.600^\circ, 33.775^\circ]$ 所覆盖的海港周边海域，流量密度图表明，离港口越近流量密度越大，通过此图还得到了港口附近流量密度的分布差异。图 5(b) 选取了经度为 $[-119.65^\circ, -119.45^\circ]$ 、纬度为 $[33.08^\circ, 33.15^\circ]$ 所覆盖的空旷海域，流量密度图中只有一条线，表明只有一条船经过此空旷海域，流量只在船的轨迹上产生。图 5(c) 选取了经度为 $[-118.8^\circ, -118.2^\circ]$ 、纬度为 $[33.50^\circ, 33.80^\circ]$ 所覆盖的航线交汇海域，流量密度图中流量最密集的区域是航线交汇中心，离交汇中心越近流量密度越大，同时也可以得到不同方向航线的流量密度的分布差异。图 5(d) 选取了经度为 $[-118.5^\circ,$

$-118.1^\circ]$ 、纬度为 $[33.10^\circ, 33.25^\circ]$ 所覆盖的海峡中央海域，流量密度图中流量较密集的区域是海峡中央航线，通过此图可获得海峡中船只所产生较密集流量的具体位置。此外，在训练集中预测区域的船只数量时，LSTM 预测模型的结果与真实船只数量的均方误差值稳定在 0.019 左右，可以说明模型在预测指定区域船只数量的准确性。

本文根据得到的网络终端的数据流量，对卫星网络差分化数据传输优化算法进行仿真验证，并与随机 (Random) 算法、先到先得 (FCFS, first come first served) 算法、任务卸载与多维资源分配 (TOMRA, task offloading and multidimensional resources allocation) 算法进行对比^[11]，图 6 和图 7 分别描述了 t 时刻 LEO_{*j*} 覆盖流量 $x_j(t)$ 对用户 i 和 LEO_{*j*} 效用的影响。当 $x_j(t)$ 增加时，该差分化算法为用户 i 和 LEO_{*j*} 带来的效用会降低，主要原因在于 $x_j(t)$ 越大，用户 i 所分配的带宽会越少，导致用户 i 传输比率 λ_i 减小，用户 i 和 LEO_{*j*} 的效用也降低。而 $x_j(t)$ 越小， λ_i 值越大，用户 i 和 LEO_{*j*} 效用就会增加。同时，归一化因子 α_i 的占比越大，表示用户 i

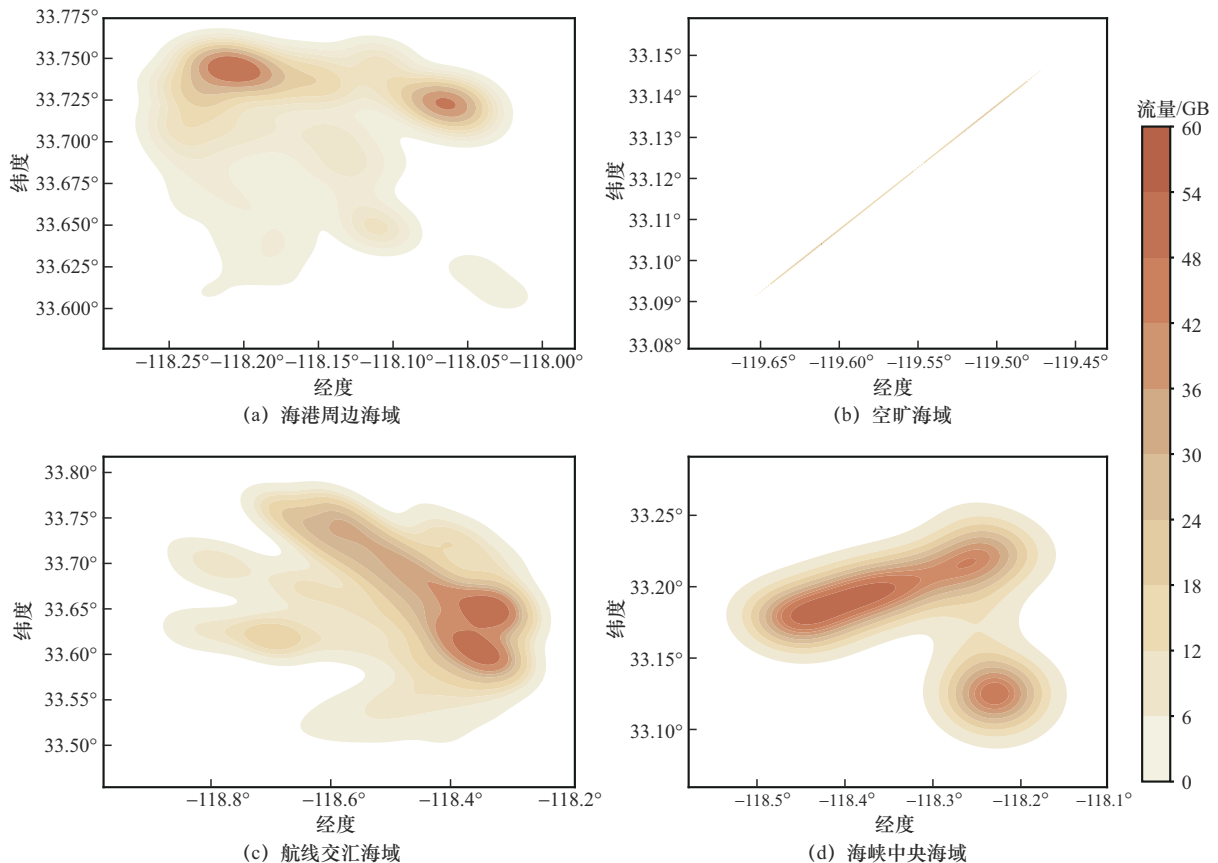


图 5 LSTM-ARIMA 模型预测不同区域流量密度

对任务越重视,其收益就越高。在相同归一化因子条件下,该算法在优化用户和LEO卫星收益方面的表现明显优于Random算法、FCFS算法和TOMRA算法。该算法与Random算法相比用户收益可提高20%~200%,与FCFS算法相比用户和LEO的收益分别可提高5%~40%和60%~120%,与TOMRA算法相比用户和LEO卫星的收益分别可提高0~10%和5%~40%,且使用改进LSTM-ARIMA预测算法的效用明显高于不使用预测算法。

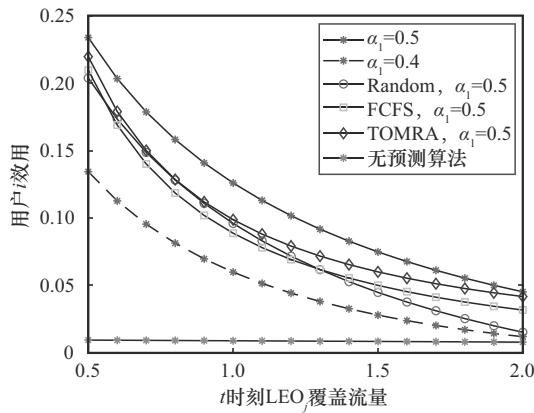


图6 差分化数据传输服务用户*i*效用




图7 差分化数据传输服务LEO_{*j*}效用

EOSN任务卸载服务可根据计算量与数据量的比率分为大计算量任务和小计算量任务。本文对小计算量任务进行仿真,用户*i*和LEO_{*j*}的效用随*t*时刻LEO_{*j*}覆盖流量 $x_j(t)$ 的变化情况分别如图8和图9所示。图8的仿真结果表明,在小计算量任务卸载过程中,用户*i*设置高时延优先级带来的收益比高能耗优先级的收益更高,这是因为用户卸载任务时传输数据所消耗的能耗占总能耗的比率较大,所以卫

星提供的卸载服务可为用户节省的能耗较少。此外,效用函数还随着 $x_j(t)$ 的增大而减小,其原因与差异化下载服务类似,由于 $x_j(t)$ 越小,用户*i*所分配的带宽会越少,导致用户*i*卸载比率 λ_i 减小。该算法明显优于FCFS算法和TOMRA算法,与FCFS算法相比用户收益提高约20%~50%,与TOMRA算法相比用户收益提高约5%~40%。但随着 $x_j(t)$ 的增大,用户卸载任务比率 λ_i 越来越小,其收益差距也逐渐缩小。图9的仿真结果表明,高时延优先级为LEO_{*j*}带来的收益比高能耗优先级更高,且收益也随着 $x_j(t)$ 增大而减少。同样,在卸载服务时使用改进LSTM-ARIMA预测算法为用户与LEO卫星带来的收益明显高于不使用预测算法。




图8 小计算量任务卸载服务用户*i*效用




图9 小计算量任务卸载服务LEO_{*j*}效用

5 结束语

本文针对地面网络覆盖盲区和卫星网络资源利

用率低等问题,提出了基于网络终端数据流量预测的LEO卫星互联网资源分配策略。该策略可以通过准确预测地面区域未来一定时间内产生的数据流量,合理分配EOSN有限的带宽,有效应对未来LEO卫星互联网对资源配置的应用前景与发展趋势。本文提出了基于改进LSTM-ARIMA算法的数据流量预测模型以及差分化数据传输和任务卸载通信服务模型,建立了Stackelberg博弈模型以确定用户通过卫星传输数据或卸载任务的比率。通过求解纳什均衡,得到用户的最优决策和卫星提供网络服务的最优定价。通过仿真验证了该策略在数据传输服务中收益能提高约40%,在任务卸载服务中收益能提高约50%,且使用改进LSTM-ARIMA数据流量预测算法为用户与LEO带来的收益均明显高于不使用预测算法。在未来的研究中,将进一步优化流量预测算法,使其适用于更多卫星通信场景。

附录1 EOSN 差分化数据传输最优决策

证明 当LEO_j确定自身定价时,用户*i*根据观察LEO_j定价来确定从辅助传输数据的卸载比率 λ_i ,以最大化发挥辅助传输功能。设 λ_i^0 为满足条件 $\frac{1-\lambda_i}{r_{C_i}^{M_k}} = \frac{\lambda_i}{r_{C_i}^{L_j}}$ 时 λ_i 的值,如式(58)所示。

$$\lambda_i^0 = \frac{r_{C_i}^{L_j}}{r_{C_i}^{L_j} + r_{C_i}^{M_k}} \quad (58)$$

当 $0 < \lambda_i < \lambda_i^0$ 时,计算 $U_{C_i}^{DT}(\lambda_i)$ 关于 λ_i 的一阶导数和二阶导数,可证明 $U_{C_i}^{DT}(\lambda_i)$ 为严格凸函数,将满足一阶导数为0的 λ_i 值设为 $\lambda_i^\#$,如式(59)所示。

$$\lambda_i^\# = \frac{1}{\phi_i^{DT}} \left(\frac{\alpha_1}{\alpha_2 \eta_{L_j}} - r_{C_i}^{M_k} \right) \quad (59)$$

当 $\lambda_i^0 \leq \lambda_i \leq 1$ 时, $U_{C_i}^{DT}(\lambda_i)$ 关于 λ_i 的一阶导数为负数。因此, $\lambda_i = \lambda_i^0$ 时 $U_{C_i}^{DT}(\lambda_i)$ 取最大值。由式(58)和式(59)可得,用户*i*的最佳辅助传输策略为式(45)。

根据用户*i*的最优辅助传输策略,可以反向归纳第一阶段中LEO_j的最优定价策略, λ_i^* 的取值为 $\lambda_i^* \in \{0, \lambda_i^\#, \lambda_i^0\}$ 。

当 $\lambda_i^* = 0$ 时,用户*i*不通过卫星辅助传输数据。当 $\lambda_i^* = \lambda_i^0$ 时,LEO_j的最佳定价策略为 $\eta_{L_j}^* = \eta_{L_j, \max}$ 。当 $\lambda_i^* = \lambda_i^\#$ 时, $U_{L_j}(\eta_{L_j}) = (\eta_{L_j} - \varepsilon_{L_j C}) \lambda_i \phi_i$ 。

计算 $U_{L_j}^{DT}$ 关于 η_{L_j} 的一阶导数和二阶导数,同样可以证明 $U_{L_j}^{DT}$ 为严格凸函数。令 $\eta_{L_j}^\#$ 为满足一阶导数为0时 η_{L_j} 的值,如式(60)所示。

$$\eta_{L_j}^\# = \sqrt{\frac{\alpha_1 \varepsilon_{L_j C}}{\alpha_2 r_{C_i}^{L_j}}} \quad (60)$$

由式(60)可得,LEO_j的最佳数据传输定价策略为式(46)。

证毕。

附录2 EOSN 任务卸载最优决策

证明 设 λ_i^0 为满足 $\frac{(1-\lambda_i)\psi_i^{OT}}{f_i^l} = t_i^{ex} + t_i^{ex}$ 的 λ_i 值,表示为

$$\lambda_i^0 = \frac{\psi_i^{OT} f_j^o r_{C_i}^{L_j}}{f_i^l f_j^o \phi_i^{OT} + \psi_i^{OT} r_{C_i}^{L_j} (f_i^l + f_j^o)} \quad (61)$$

$U_{C_i}(\lambda_i)$ 可表示为

$$U_{C_i}^{OT} = \begin{cases} \ln\{1 + [\lambda_i \beta_1 + \lambda_i \beta_2 Q]\} \psi_i^{OT} - \delta_1 \lambda_i \psi_i^{OT} \eta_{L_j}, & 0 < \lambda_i < \lambda_i^0 \\ \ln\left\{1 + \left[\beta_1 \left(1 - \frac{\lambda_i f_i^l}{f_j^o} - \frac{\lambda_i f_i^l \phi_i^{OT}}{r_{C_i}^{L_j} \psi_i^{OT}}\right) + \lambda_i \beta_2 Q\right]\right\} \psi_i - & \\ \delta_1 \lambda_i \psi_i^{OT} \eta_{L_j}, \lambda_i^0 < \lambda_i < 1 & \end{cases} \quad (62)$$

其中, $Q = 1 - \frac{p_i \phi_i^{OT}}{\xi \psi_i^{OT} (f_i^l)^{\mu-1} r_{C_i}^{L_j}}$ 。

当卸载任务比率为 $0 < \lambda_i < \lambda_i^0$ 时,计算 $U_{C_i}^{OT}(\lambda_i)$ 关于 λ_i 的一阶导数和二阶导数,可证明 $U_{C_i}^{OT}(\lambda_i)$ 为严格凸函数,再将满足一阶导数为0的 λ_i 值设为 $\lambda_i^\#$,如式(63)所示。

$$\lambda_i^\# = \frac{\beta_1 + \beta_2 Q - \delta_1 \eta_{L_j}}{\delta_1 \eta_{L_j} (\beta_1 + \beta_2 Q)} \quad (63)$$

当 $\lambda_i^0 \leq \lambda_i \leq 1$ 时,计算 $U_{C_i}^{OT}(\lambda_i)$ 关于 λ_i 的一阶导数,如式(64)所示。

$$\frac{\partial U_{C_i}^{OT}}{\partial \lambda_i} = \psi_i^{OT} \frac{\beta_2 Q - \beta_1 \left(\frac{f_i^l}{f_i^o} + \frac{f_i^l \phi_i^{OT}}{r_{C_i}^{L_j} \psi_i^{OT}} \right)}{1 + \left\{ \beta_1 + \lambda_i \left[\beta_2 Q - \beta_1 \left(\frac{f_i^l}{f_i^o} + \frac{f_i^l \phi_i^{OT}}{r_{C_i}^{L_j} \psi_i^{OT}} \right) \right] \right\}} - \delta_1 \psi_i^{OT} \eta_{L_j} \quad (64)$$

此时,可分2种情况进行考虑,具体如下。

若 $\beta_2 Q - \beta_1 \left(\frac{f_i^l}{f_i^o} + \frac{f_i^l \phi_i^{OT}}{r_{C_i}^{L_j} \psi_i^{OT}} \right) \leq 0$,则 $\frac{\partial U_{C_i}^{OT}}{\partial \lambda_i} < 0$,当 $\lambda_i = \lambda_i^0$ 时, $U_{C_i}^{OT}(\lambda_i)$ 取最大值。

若 $\beta_2 Q - \beta_1 \left(\frac{f_i^l}{f_i^o} + \frac{f_i^l \phi_i^{OT}}{r_{C_i}^{L_j} \psi_i^{OT}} \right) > 0$,可以证明 $U_{C_i}^{OT}(\lambda_i)$ 为凸函数,将满足一阶导数为0的 λ_i 值设为 λ_i^\wedge ,如式(65)所示。

$$\lambda_i^\wedge = \frac{P - (1 + \beta_1) \delta_1 \eta_{L_j}}{\delta_1 \eta_{L_j} P} \quad (65)$$

其中, $P = \beta_2 Q - \beta_1 \left(\frac{f_i^l}{f_i^o} + \frac{f_i^l \phi_i^{OT}}{r_{C_i}^{L_j} \psi_i^{OT}} \right)$ 。

由式(63)和式(65)可得,用户*i*的最佳卸载策略为式(54)

和式(55)。

通过本文得到的用户 i 最优卸载策略, 可以利用反向归纳法得到第一阶段中 LEO_j 的最优定价策略, 同样将其分为如下2种情况进行讨论。

当 β_1 和 β_2 满足 $\beta_2 Q - \beta_1 \left(\frac{f_i^l}{f_i^o} + \frac{f_i^l \phi_i^{OT}}{r_{C_i}^{L_j} \psi_i^{OT}} \right) < 0$ 时, λ_i^* 的取

值为 $\lambda_i^* \in \{0, \lambda_i^{\#}, \lambda_i^0\}$ 。

当 $\lambda_i^* = 0$ 时, 用户 i 不通过 LEO 卫星进行任务卸载, 其本地执行全部所需任务。当 $\lambda_i^* = \lambda_i^0$ 时, LEO_j 的最优定价决策为 $\eta_{L_j}^* = \eta_{L_j, \max} \leq Y_1$ 。当 $\lambda_i^* = \lambda_i^{\#}$ 时, $U_{L_j}^{OT}(\eta_{L_j}) = \delta_2 \lambda_i \psi_i^{OT} \eta_{L_j} - \xi \lambda_i \psi_i^{OT} (f_j^o)^{\mu-1}$ 。

计算 $U_{L_j}^{OT}(\eta_{L_j})$ 关于 η_{L_j} 的一阶导数和二阶导数, 可以证明 $U_{L_j}^{OT}(\eta_{L_j})$ 为严格凸函数。令 $\eta_{L_j}^{\#}$ 为满足一阶导数为0的 η_{L_j} 值, 如式(66)所示。

$$\eta_{L_j}^{\#} = \sqrt{\frac{\xi(\beta_1 + \beta_2 Q)(f_j^o)^{\mu-1}}{\delta_1 \delta_2}} \quad (66)$$

在该情况下, 由式(66)可得 LEO_j 最优定价策略为式(56)。

当 β_1 和 β_2 满足 $\beta_2 Q - \beta_1 \left(\frac{f_i^l}{f_i^o} + \frac{f_i^l \phi_i^{OT}}{r_{C_i}^{L_j} \psi_i^{OT}} \right) > 0$ 时, λ_i^* 的取

值为 $\lambda_i^* \in \{0, \lambda_i^{\#}, \lambda_i^0, \lambda_i^1\}$ 。

当 $\lambda_i^* = 0$ 时, 用户 i 不通过卫星进行任务卸载, 本地执行全部所需任务。当 $\lambda_i^* = \lambda_i^0$ 时, LEO_j 的最优定价决策为 $\eta_{L_j}^* = \eta_{L_j, \max} \leq Y_1$ 。当 $\lambda_i^* = \lambda_i^{\#}$ 时, 求得 $\eta_{L_j}^{\#}$ 为该情况下满足一阶导数为0的 η_{L_j} 值。当 $\lambda_i^* = 1$ 时, 可得 $U_{L_j}^{OT}(\eta_{L_j})$ 为单调递增函数, LEO_j 的最佳卸载策略为 $\eta_{L_j}^* = \eta_{L_j, \max} \leq Y_3$ 。当 $\lambda_i^* = \lambda_i^1$ 时, 计算 $U_{L_j}^{OT}(\eta_{L_j})$ 关于 η_{L_j} 的一阶导数和二阶导数, 可以证明 $U_{L_j}^{OT}(\eta_{L_j})$ 为严格凸函数。令 $\eta_{L_j}^{\wedge}$ 为满足一阶导数为0的 η_{L_j} 值, 如式(67)所示。

$$\eta_{L_j}^{\wedge} = \sqrt{\frac{\xi P (f_j^o)^{\mu-1}}{(1 + \beta_1) \delta_1 \delta_2}} \quad (67)$$

可以证明 $\eta_{E_j}^{\wedge} < \eta_{E_j}^{\#}$ 。由式(67)可得, LEO_j 最优定价策略为(57)。

证毕。

参考文献:

- [1] ABDELSADEK M Y, CHAUDHRY A U, DARWISH T, et al. Future space networks: toward the next giant leap for humankind[J]. IEEE Transactions on Communications, 2023, 71(2): 949-1007.
- [2] ALHILAL A, BRAUD T, HUI P. The sky is NOT the limit anymore: future architecture of the interplanetary Internet[J]. IEEE Aerospace and Electronic Systems Magazine, 2019, 34(8): 22-32.
- [3] VILA-VALLS J, NAVARRO M, CLOSAS P, et al. Synchronization challenges in deep space communications[J]. IEEE Aerospace and Electronic Systems Magazine, 2019, 34(1): 16-27.
- [4] FOURATI F, ALOUINI M S. Artificial intelligence for satellite communication: a review[J]. Intelligent and Converged Networks, 2021, 2(3): 213-243.
- [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, 2021, 23(1): 70-109.
- [6] LIU Y, JIANG L, QI Q, et al. Energy-efficient space-air-ground integrated edge computing for Internet of remote things: a federated DRL approach[J]. IEEE Internet of Things Journal, 2023, 10(6): 4845-4856.
- [7] CHEN Y L, AI B, NIU Y, et al. Energy-constrained computation offloading in space-air-ground integrated networks using distributionally robust optimization[J]. IEEE Transactions on Vehicular Technology, 2021, 70(11): 12113-12125.
- [8] LIAO H J, ZHOU Z Y, ZHAO X W, et al. Learning-based queue-aware task offloading and resource allocation for space-air-ground-integrated power IoT[J]. IEEE Internet of Things Journal, 2021, 8(7): 5250-5263.
- [9] GONG Y K, YAO H P, WU D, et al. Computation offloading for rechargeable users in space-air-ground networks[J]. IEEE Transactions on Vehicular Technology, 2023, 72(3): 3805-3818.
- [10] YU S, GONG X W, SHI Q, et al. EC-SAGINS: edge-computing-enhanced space-air-ground-integrated networks for Internet of vehicles[J]. IEEE Internet of Things Journal, 2022, 9(8): 5742-5754.
- [11] CUI G F, DUAN P F, XU L X, et al. Latency optimization for hybrid GEO-LEO satellite-assisted IoT networks[J]. IEEE Internet of Things Journal, 2023, 10(7): 6286-6297.
- [12] QIN Z Y, YAO H P, MAI T L, et al. Multi-agent reinforcement learning aided computation offloading in aerial computing for the Internet-of-things[J]. IEEE Transactions on Services Computing, 2023, 16(3): 1976-1986.
- [13] STHAPIT S, LAKSHMINARAYANA S, HE L G, et al. Reinforcement learning for security-aware computation offloading in satellite networks[J]. IEEE Internet of Things Journal, 2022, 9(14): 12351-12363.
- [14] DING C F, WANG J B, CHENG M, et al. Dynamic transmission and computation resource optimization for dense LEO satellite assisted mobile-edge computing[J]. IEEE Transactions on Communications, 2023, 71(5): 3087-3102.
- [15] WAQAR N, ALI H S, MAHMOOD A, et al. Computation offloading and resource allocation in MEC-enabled integrated aerial-terrestrial vehicular networks: a reinforcement learning approach[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(11): 21478-21491.
- [16] JIA H G, JIANG C X, KUANG L L, et al. Adaptive random access and data transmission scheme with mixed traffic in NGSO satellite networks[J]. IEEE Transactions on Vehicular Technology, 2023, 72(5): 6765-6777.
- [17] WANG C Y, LIU L, MA H D, et al. A joint optimization scheme for hybrid MAC layer in LEO satellite supported IoT[J]. IEEE Internet of Things Journal, 2021, 8(15): 11822-11833.
- [18] LU Y, ZHAO Y J, SUN F C, et al. Enhancing transmission efficiency of mega-constellation LEO satellite networks[J]. IEEE Transactions on Vehicular Technology, 2022, 71(12): 13210-13225.
- [19] CAO B, ZHANG J T, LIU X, et al. Edge-cloud resource scheduling in space-air-ground-integrated networks for Internet of vehicles[J]. IEEE Internet of Things Journal, 2022, 9(8): 5765-5772.
- [20] TANG F X, WEN C, CHEN X H, et al. Federated learning for intelligent transmission with space-air-ground integrated network toward 6G[J].

- IEEE Network, 2023, 37(2): 198-204.
- [21] ZHANG P Y, ZHANG Y, KUMAR N, et al. Dynamic SFC embedding algorithm assisted by federated learning in space-air-ground-integrated network resource allocation scenario[J]. IEEE Internet of Things Journal, 2023, 10(11): 9308-9318.
- [22] ZHANG P Y, YANG P, KUMAR N, et al. Space-air-ground integrated network resource allocation based on service function chain[J]. IEEE Transactions on Vehicular Technology, 2022, 71(7): 7730-7738.
- [23] ABDU T S, KISSELEFF S, LAGUNAS E, et al. Flexible resource optimization for GEO multibeam satellite communication system[J]. IEEE Transactions on Wireless Communications, 2021, 20(12): 7888-7902.
- [24] YUAN A F, XU Y L, ZHANG Q Y, et al. Optimal energy efficiency for relay selection via power allocation in L2 halo-orbital cislunar communication network[J]. IEEE Transactions on Vehicular Technology, 2022, 71(3): 3155-3170.
- [25] CHEN X J, LI X M, WANG X W, et al. Task scheduling method for data relay satellite network considering breakpoint transmission[J]. IEEE Transactions on Vehicular Technology, 2021, 70(1): 844-857.
- [26] LI J X, WU G H, LIAO T J, et al. Task scheduling under a novel framework for data relay satellite network via deep reinforcement learning[J]. IEEE Transactions on Vehicular Technology, 2023, 72(5): 6654-6668.
- [27] ZHANG S H, CUI G F, WANG W D. Joint data downloading and resource management for small satellite cluster networks[J]. IEEE Transactions on Vehicular Technology, 2022, 71(1): 887-901.
- [28] DAVARIAN F, ASMAR S, ANGERT M, et al. Improving small satellite communications and tracking in deep space—a review of the existing systems and technologies with recommendations for improvement. part II: small satellite navigation, proximity links, and communications link science[J]. IEEE Aerospace and Electronic Systems Magazine, 2020, 35(7): 26-40.
- [29] EL A S, RAMAMURTHY B. MARS: a multi-attribute routing and scheduling algorithm for DTN interplanetary networks[J]. IEEE/ACM Transactions on Networking, 2020, 28(5): 2065-2076.
- [30] CHONDRODIMA E, MANDALIS P, PELEKIS N, et al. Machine learning models for vessel route forecasting: an experimental comparison[C]//Proceedings of the 2022 23rd IEEE International Conference on Mobile Data Management (MDM). Piscataway: IEEE Press, 2022: 262-269.

- [31] ZHAN W H, LUO C B, MIN G Y, et al. Mobility-aware multi-user offloading optimization for mobile edge computing[J]. IEEE Transactions on Vehicular Technology, 2020, 69(3): 3341-3356.


[作者简介]



沈斐 (1983–), 女, 江苏南京人, 博士, 中国科学院上海微系统与信息技术研究所研究员、博士生导师, 主要研究方向为无线资源管理、边缘智能计算、卫星互联网、元宇宙技术。



吕承丞 (1997–), 男, 浙江金华人, 中国科学院上海微系统与信息技术研究所博士生, 主要研究方向为边缘智能计算、卫星互联网、网络优化。



张嘉璇 (1999–), 男, 河南洛阳人, 中国科学院上海微系统与信息技术研究所博士生, 主要研究方向为强化学习、边缘智能计算、无线通信。



阮小婷 (1999–), 女, 福建漳州人, 中国科学院上海微系统与信息技术研究所硕士生, 主要研究方向为边缘计算、流量预测、网络优化。