

面向高速公路场景的边缘车联网任务卸载优化策略研究

梁国铭¹

LIANG Guoming

摘要

高速公路场景中存在车辆高速移动、RSU 部署稀疏、通信链路易中断等状况,文章提出一种面向边缘车联网的任务卸载优化策略。建立多目标优化模型,其中考虑任务时延、能耗、经济成本,还引入协作货车中继机制来扩大通信覆盖范围。针对不同任务规模和网络状态,设计了一种基于 Q-Learning 和 DQN 的单智能体任务卸载算法,达成车辆在动态环境里的自适应决策。进而结合博弈论思想,提出改进的 Friend-or-Foe Q-learning 算法与合作式 Q-learning 算法,用于多车辆场景下的资源竞争和协同优化。仿真结果显示,该算法在收敛速度、任务时延与系统公平性方面都比传统 MA Q-learning 与 MADQN 更优,能有效提高系统整体性能与稳定性,为车联网中任务卸载与资源管理提供了高效可行的解决办法。

关键词

车联网;边缘计算;任务卸载;多智能体强化学习;博弈论

doi: 10.3969/j.issn.1672-9528.2026.05.045

0 引言

随着移动通信技术的快速发展,智能网联汽车正逐步成为现实。高级别自动驾驶、实时环境感知、交互式车载娱乐等新兴应用,对车载计算能力提出了极高要求,这类任务普遍具有计算密集、时延敏感的特性^[1]。然而车载终端的本地计算资源有限,难以独立承载全部计算任务。传统云计算模

式虽可提供强大算力,但由于核心网传输距离较远,难以满足车联网场景下的极低时延严苛要求。

面对这一挑战,移动边缘计算也就是 MEC 技术出现了。它把云计算能力下沉到网络边缘,在离数据源更近的地方给车辆提供计算服务,有效降低了任务处理延迟^[2]。车联网和边缘计算结合形成车辆边缘计算网络即 VECNs,借助 V2X 通信,车辆能把计算任务卸载到路侧单元也就是 RSU 或者周边有空闲资源的协作车辆,这构成了支撑未来智能交通系统

1. 荆门职业学院 湖北荆门 448000

[8] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Piscataway:IEEE,2016:1646-1654.

[9] Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution[PP/OL] .(2017-07-10) [2026-05-06].https://doi.org/10.48550/arXiv.1707.02921.

[10] Caballero J, Ledig C, Aitken A, et al. Real-time video super-resolution with spatio-temporal networks and motion compensation[PP/OL] .(2017-04-10)[2026-05-06].https://doi.org/10.48550/arXiv.1611.05250.

[11] Jo Y, Oh S W, Kang J, et al. Deep video super-resolution network using dynamic upsampling filters without explicit motion compensation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition.Piscataway:IEEE,2018: 3224-3232.

[12] Wang Xintao, Chan K C K, Yu K, et al. EDVR: video restoration with enhanced deformable convolutional networks[PP/OL] .(2019-05-07)[2026-05-06].https://doi.org/10.48550/arXiv.1905.02716.

[13]Chen Xiaolei, Cao Baoning, Lu Yubing, et al. Live VR panoramic video Streaming method combing viewport Prediction and super-resolution[J]. Journal of Computer-Aided Design & Computer Graphics, 2024, 36(9): 1394-1406.

【作者简介】

林海(1976—),男,广东湛江人,硕士,副教授,研究方向:人工智能、VR 虚拟仿真。

陈国珍(1989—),女,广东湛江人,本科,助教,研究方向:计算机应用、人工智能与大数据技术研究。

(收稿日期:2025-09-13 修回日期:2026-05-09)

也是,另外车辆行驶方向与信号传播方向夹角也是相关要素之一。

相干时间约为:

$$T_c \approx \frac{1}{f_d} \quad (4)$$

若符号周期相较于相干时间明显短很多,信号包络的变化情形会比较缓慢,此时会呈现出慢衰落特性。大尺度衰落主要是路径损耗所引发的结果,能够借助天线高度、发射功率来予以补偿。

1.2.2 RSU 卸载模型

在任务车辆做出把任务卸载到 RSU 的决策这个时候,整体时延是由传输时延和计算时延一起构成的。

(1) 传输时延:

$$T_{a,comm}^R = \frac{L_a}{v_{a,comm}^R} \quad (5)$$

式中: $v_{a,comm}^R$ 表示任务车辆 a 与 RSU 之间的数据传输速率。

(2) 计算时延:

$$T_{a,comp}^R = \frac{C_a}{f_R} \quad (6)$$

式中: f_R 为 RSU 为任务分配的 CPU 频率。

因此,RSU 卸载的总时延为:

$$T_{a,total}^R = T_{a,comm}^R + T_{a,comp}^R \quad (7)$$

1.2.3 本地计算模型

车辆选择在本地执行任务,因本地 CPU 资源有限,适合那种任务量较小或者通信条件恶劣的情况。

本地计算时延为:

$$T_{a,local} = T_{a,comp}^{local} = \frac{C_a \cdot \zeta_l}{f_l} \quad (8)$$

在这些信息当中,存在一个参数,是车辆自身 CPU 的频率,用来表征在多任务竞争的状况下,分配给该特定任务的计算比例系数。

对应的计算速率为:

$$v_{a,comp}^{local} = \frac{L_a}{T_{a,local}} \quad (9)$$

1.2.4 协作货车卸载模型

在车联网这一特定场景当中,存在着部分货车,它们具备比较突出的计算能力或者转发能力。假设存在一个协作货车集合,而任务车辆会依据货车自身所拥有的可用计算能力、彼此之间的距离、当前任务的负载状态,来挑选出最为合适的卸载节点。

根据是否中继,可分为三种情况:

(1) 直接卸载至货车计算

任务直接传输至货车 M , 传输时延与计算时延分别为:

$$T_{a,comm}^M = \frac{L_a}{v_{a,comm}^M}, T_{a,comp}^M = \frac{C_a}{\zeta_M f_M} \quad (10)$$

式中: f_M 为货车 CPU 频率, ζ 为任务资源分配系数。

总时延为:

$$T_{a,total}^M = T_{a,comm}^M + T_{a,comp}^M \quad (11)$$

(2) 货车中继至 RSU

当货车充当中继节点时,任务将经过两段传输。

任务车辆 $\rightarrow$ 货车 $\rightarrow$ RSU。其总时延为:

$$T_{a,total}^{M-R} = T_{a,comm}^M + T_{M,comm}^R + T_{a,comp}^R \quad (12)$$

(3) 货车中继至另一货车

若货车 M_{j1} 将任务转发给另一货车 M_{j2} 进行计算,则:

$$T_{a,total}^{M_{j1}-M_{j2}} = T_{a,comm}^{M_{j1}} + T_{M_{j1},comm}^{M_{j2}} + T_{a,comp}^{M_{j2}} \quad (13)$$

通信速率 v 依据香农公式计算:

$$v = B \log_2 \left(1 + \frac{P_t h}{N_0} \right) \quad (14)$$

信道增益是由弗里斯传输模型来确定的,还要综合考量高速公路场景下大尺度、小尺度的衰落效应。

1.3 优化目标

本文将最小化系统的长期开销当作优化目标,此开销由时延、能耗、经济成本通过加权组合而成。任务传输效用的定义是,代理的网络接入收益减掉频谱资源租用成本:

$$U_{comm}(t) = a(\lambda_1 v_{a,comm}^R + \lambda_2 v_{a,comm}^M + \lambda_3 v_{a,comm}^{R/M}) - \lambda_1 \delta_a^R B_a^R - \lambda_2 \delta_a^M B_a^M - \lambda_3 \delta_a^{R/M} B_a^{R/M} \quad (15)$$

任务计算效用为边缘端处理收益减去计算资源消耗:

$$U_{comp}(t) = b(\lambda_1 v_{a,comp}^R + \lambda_2 v_{a,comp}^{local} + \lambda_3 v_{a,comp}^M + \lambda_4 v_{M,comp}^{R/M}) - \lambda_1 \eta_{a,R} \beta f_R - \lambda_2 \eta_{a,local} \beta f_l - \lambda_3 \eta_{a,M} \beta f_M - \lambda_4 \eta_{M,R/M} \beta f_{R/M} \quad (16)$$

系统总体效用为:

$$U(t) = U_{comm}(t) + U_{comp}(t) \quad (17)$$

此优化问题受到通信带宽、计算资源、任务时限等约束条件的限制,属于典型的混合整数非线性规划问题,也就是 MINLP 问题,其求解复杂度较高,具有 NP-Hard 特性。

2 算法设计

2.1 单智能体任务卸载策略

对于单车任务卸载这一问题,本文将其建成一个马尔可夫决策过程即 MDP。系统状态由车辆当下的位置、任务的大小、剩余的计算能力、信道带宽与 RSU 的距离等特征共同构成的,动作集合有三类卸载决策,分别是本地计算、卸载到 RSU、卸载到协作货车。每当车辆执行动作之后,环境就会返回即时奖励,这个奖励综合考量了时延、能耗与任务成功率这三个因素,经由权重加权形成系统效用函数,以此来引导车辆挑选最优卸载方案。

于算法设计工作中，一开始运用 Q-Learning 对离散状态空间进行策略学习，且借助下述更新规则。

$$\begin{aligned} Q(s_t, a_t) &\leftarrow Q(s_t, a_t) + \\ &\alpha \left[r_t + \gamma \max_{a'} Q(s_{t+1}, a') - Q(s_t, a_t) \right] \end{aligned} \quad (18)$$

达成状态－动作值的迭代优化工作。为了应对高维连续状态空间的情况，本文进一步引入深度 Q 网络即 DQN 结构，运用多层感知机也就是 MLP 来做非线性拟合。DQN 引入经验回放机制以此来打破样本相关性，同时借助目标网络参数冻结、周期更新，增强训练的稳定性。车辆智能体依据 ϵ -贪心策略在探索跟利用之间进行动态权衡，实时挑选最优卸载目标。最终，这样的设计能让车辆在动态信道、计算资源变化时，自主完成任务决策，达成低延迟与高能效的单智能体任务卸载。

2.2 多智能体任务卸载策略

在有多辆车一同参与任务卸载的场景里，系统环境并非平稳不变，而是会随着各个智能体的决策发生变化，这就使得单智能体强化学习难以直接运用。所以本文把任务卸载过程建立成多智能体随机博弈模型也就是 Stochastic Game，每个智能体独立选择卸载对象，并且依据联合策略所确定的收益函数来进行学习。这个模型能够体现出车辆之间在频谱与计算资源竞争状况下的动态交互特性。

在具体实现过程中，运用分布式多智能体 Q-learning 框架，每一辆车都独立地维护本地的 Q 表或者深度网络，借助局部状态观测、有限的交互来达成联合策略的优化。智能体会依据收益反馈对自身的卸载决策作出调整，进而逐步达成资源分配的均衡、系统效用的提高。该策略并不需要集中式控制，对于车联网的动态分布式环境比较适配。

2.3 博弈论增强策略

为了应对多智能体之间存在的竞争、协调方面的问题，在本文当中引入了经过改进的，基于博弈论的 Friend-or-Foe Q-learning 算法。这种算法会把车辆之间的交互关系划分成两类，一类是“朋友”关系，另一类是“对手”关系，然后借助轮流贪心响应机制来模拟对抗性的博弈过程。每一个智能体在处于最不利情形的时候，会去选择能够让自身收益达到最大化的动作，以此来实现“最优对抗策略”的学习，防止陷入非均衡状态。

算法实现过程中，智能体一开始会随机对动作集合进行初始化，接着依据他车策略轮流进行响应更新，借助最大化最小收益的方式来逼近纳什均衡。针对具有协同关系的车辆集群，运用合作 Q-learning 思想，通过分享部分状态信息、联合收益，达成多车间的协同决策、资源互补，在竞争与合作并存的车联网环境当中实现高效且稳定的任务卸载策略。

3 实验结果与结论

3.1 性能评估指标

为了对所提出的任务卸载算法的性能进行验证，在本文之中，选取了平均奖励值、任务总时延、能耗开销、纳什均衡性指标等当作主要的评估指标。

平均奖励值能够展现系统综合效用的优化成果，其可对算法在长时间运行时，在时延、能耗、资源成本等方面的综合平衡能力予以衡量。

任务的总时延由任务传输时延、计算时延这两部分构成，它能够反映系统实时性方面的性能，是用于评价边缘计算任务处理能力的一项关键指标。

能耗开销所涉及的内容为，车辆或者 RSU 在进行任务传输、计算的过程当中所消耗的全部能量，通过这一能耗开销能够对算法在能效管理方面的优劣程度予以衡量。

多车辆在竞争资源过程中所采用策略的稳定性情况，能够通过均衡性指标来进行评估。当 ΔT 的数值较小时，这意味着系统正在朝着纳什均衡的方向逐步靠近，车辆之间的资源分配会展现出更加公平合理的趋势。

依据上述各项指标，能够针对效用优化、时延性能、能效表现、博弈稳定四个方面，来对不同的任务卸载策略展开全面的比较、验证工作。

3.2 仿真结果分析

于 Python 仿真环境之内，构造出一段长度为 4 km 的高速公路场景，在其中部署 4 个 RSU、3 辆协作货车、4 辆任务车辆。车辆以对向行驶的方式作移动，并且依据本文所提出的任务卸载模型进行多轮训练。关键系统参数呈现于表 1 中。

表 1 模型参数表

参数	符号	数值
协作货车的 CPU 频率	f_M	1.5 GHz
RSU 的 CPU 频率	f_R	2.5 GHz
本地计算的 CPU 频率	f_I	1 GHz
传输信道带宽	B_a^R	20 MHz
传输信道波长	λ	15 m
任务车辆天线发射增益	G_a	10
RSU 的接收增益	G_r	10
任务车辆 a 初始发射功率	P_a	0.5 W
高斯白噪声	σ^2	2×10^{-12} W
任务处理所需 CPU 周期数	C_a	2 500 /kbit
单次卸载任务容量	L_a	[500, 2 000]kB
每相邻任务时间间隔	T_{step}	5 s
任务最大处理延迟	τ	12 s
拥堵折算系数	ζ	0.8
每个 CPU 周期消耗能量	β	10^{-8} J/周期
任务传输成本	δ_a^R, δ_a^M	1 unit/MHz
强弱信号边界	D	1 000 m

通过图 2~4 可以发现, 本文所提出的改进 FFQ 算法, 在收敛速度、平均奖励这两个方面, 均展现出了最为出色的表现。当迭代进行到大约 250 轮的时候, 该算法逐渐趋向于稳定状态, 其平均奖励值明显高于 MA Q-learning 算法、MADQN 算法, 这说明在复杂的车联网环境当中, 改进 FFQ 算法拥有更为优秀的策略收敛能力、全局最优搜索能力。




图 2 不同算法的平均奖励值随训练回合数的变化曲线




图 3 四种任务卸载方法平均每回合总延迟




图 4 不同算法下的时延差方值对比

在任务处理时延这个指标方面, 改进后的 FFQ 算法同中继机制相结合, 让任务的总时延降低不少。和 MA Q-learning 算法、MADQN 算法相比, 其任务总时延分别大概减少了 18% 和 15%, 这对缓解高负载时网络出现的拥塞问题很有效。在验证纳什均衡性的过程中, 改进后的 FFQ 算法产生的 ΔT 值是最低的。这意味着该算法在车辆间的竞争中, 能达成资源分配的动态均衡状态, 从而让系统稳定且高效地运行。

本文所提出的依靠博弈论的多智能体任务卸载算法, 在收敛性、计算效率方面有着一定优势, 并且在时延与公平性方面能够达成性能的最优状态, 可为未来车联网环境里的智能卸载、资源协同给予有效的理论和方法方面的支持。

4 结论

高速公路场景中会出现边缘车联网任务卸载的情形, 本文给出一种借助博弈论的多智能体深度强化学习优化策略。建立多目标优化模型, 把任务时延、能耗及经济成本都考虑其中, 完成了对卸载决策过程的精准建模。

在单车与多车辆这两种不同场景下, 分别设计了 DQN 算法、改进的 FFQ 算法。基于此, 智能体便能够在处于动态变化的信道条件、具备一定限制的计算资源状况下, 达成自主学习、优化决策的目标。经过仿真得出的结果显示, 所提出的算法在收敛速度、平均奖励值、任务处理时延等多个方面, 都展现出比较突出的优势, 能够切实提高系统的能效、均衡性。

今后的工作会对异构车载节点、自适应中继机制的联合优化展开进一步探究, 把联邦学习与协同推理框架相结合, 以此达成更为高效且更为鲁棒的车联网任务卸载系统。

参考文献:

- [1] 梁国铭. 高速公路场景下边缘车联网任务卸载策略研究 [D]. 广州: 广东工业大学, 2023.
- [2] Zhang Ke, Zhu Yongxu, Leng Supeng, et al. Deep learning empowered task offloading for mobile edge computing in urban informatics[J]. IEEE Internet of Things Journal, 2019, 6(5): 7635-7647.
- [3] 李文浩. 合作促进多智能体强化学习 [D]. 上海: 华东师范大学, 2022.
- [4] 陈静. 基于策略梯度优化的深度强化学习及其在智能体控制中的应用 [D]. 广州: 广东技术师范大学, 2022.
- [5] Huang Xinyu, He Lijun, Chen Xing, et al. Revenue and energy efficiency-driven delay constrained computing task offloading and resource allocation in a vehicular edge computing network: a deep reinforcement learning approach[J]. IEEE Internet of Things Journal, 2022, 9(11): 8852-8868.

【作者简介】

梁国铭 (1996—), 男, 湖北荆门人, 硕士, 研究方向: 车联网、边缘计算、应用电子。

(收稿日期: 2025-11-18 修回日期: 2026-05-15)