

6-20-2023

Joint Optimization Strategy of Computing Offloading and Edge Caching for Intelligent Connected Vehicles

Fei Ding

School of Internet of things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China; Key Laboratory of Broadband Wireless Communication and Internet of Things of Jiangsu Province, Nanjing University of Posts and Telecommunications, Nanjing 210003, China; National Engineering Research Center for Communication and Network Technology, Nanjing University of Posts and Telecommunications, Nanjing 210003, China, dingfei@njupt.edu.cn

Yuchen Sha

School of Internet of things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China; Key Laboratory of Broadband Wireless Communication and Internet of Things of Jiangsu Province, Nanjing University of Posts and Telecommunications, Nanjing 210003, China, 554320330@qq.com

Ying Hong

School of Internet of things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China; Key Laboratory of Broadband Wireless Communication and Internet of Things of Jiangsu Province, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

Xiao Kuai

School of Internet of things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China; Key Laboratory of Broadband Wireless Communication and Internet of Things of Jiangsu Province, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Joint Optimization Strategy of Computing Offloading and Edge Caching for Intelligent Connected Vehicles

Abstract

To guarantee the low-delay communication of intelligent connected vehicles, the V2X channel model and the multi-access edge computing (MEC) technology, are used to carry out the research of the joint optimization strategy of computing offloading and edge caching. *An intelligent connected vehicle with task offloading and edge caching model least-deep deterministic policy gradient(L-DDPG) is developed.* By integrating the vehicular local and edge computing resources, the classification processing of different computing tasks in V2X scenarios is supported. *The vehicular computing request is prejudged by edge platform to ensure the rapid response of continuous homogeneous computing tasks. Combining with the least recently used strategy, the new computing tasks are efficiently managed. A joint offloading decision for computing offloading and edge caching is carried out based on deep deterministic policy gradient(DDPG) algorithm.* Simulation results show that the performance of L-DDPG model is better than that of traditional models, which can effectively improve the system performance, ensure the service quality, and reduce the time delay and resource consumption.

Keywords

intelligent connected vehicle, vehicle to everything(V2X), multi-access edge computing, deep reinforcement learning, computing offloading, edge caching

Authors

Fei Ding, Yuchen Sha, Ying Hong, Xiao Kuai, and Dengyin Zhang

Recommended Citation

Fei Ding, Yuchen Sha, Ying Hong, Xiao Kuai, Dengyin Zhang. Joint Optimization Strategy of Computing Offloading and Edge Caching for Intelligent Connected Vehicles[J]. Journal of System Simulation, 2023, 35(6): 1203-1214.

智能网联汽车计算卸载与边缘缓存联合优化策略

丁飞^{1,2,3}, 沙宇晨^{1,2*}, 洪莹^{1,2}, 蒯晓^{1,2}, 张登银^{1,2,3}

(1. 南京邮电大学 物联网学院, 江苏 南京 210003; 2. 南京邮电大学 江苏省宽带无线通信和物联网重点实验室, 江苏 南京 210003;
3. 南京邮电大学 通信与网络技术国家工程研究中心, 江苏 南京 210003)

摘要: 为了保障智能网联汽车的低时延通信, 利用蜂窝车联网中 V2X(vehicle to everything)信道模型、边缘计算技术, 研究计算卸载与边缘缓存联合优化策略。设计了一种智能网联汽车计算卸载与边缘缓存协同模型 L-DDPG(least-deep deterministic policy gradient), 通过对车载本地与边缘计算资源的整合, 支持 V2X 场景下对不同计算任务的分类处理。由边缘平台对车载计算请求进行预判决, 确保对连续的计算任务快速响应; 结合基于最近最少使用(least recently used, LRU)的边缘缓存策略, 实现对新计算任务的高效管理; 基于 DDPG 算法对计算卸载与边缘缓存进行联合卸载决策。仿真结果表明: L-DDPG 模型性能优于传统模型, 能够有效提升系统的工作效能, 在保障业务服务质量的同时降低时延和系统资源消耗。

关键词: 智能网联汽车; V2X(vehicle to everything); 多接入边缘计算; 深度强化学习; 计算卸载; 边缘缓存

中图分类号: TP393

文献标志码: A

文章编号: 1004-731X(2023)06-1203-12

DOI: 10.16182/j.issn1004731x.joss.22-0147

引用格式: 丁飞, 沙宇晨, 洪莹, 等. 智能网联汽车计算卸载与边缘缓存联合优化策略[J]. 系统仿真学报, 2023, 35(6): 1203-1214.

Reference format: Ding Fei, Sha Yuchen, Hong Ying, et al. Joint Optimization Strategy of Computing Offloading and Edge Caching for Intelligent Connected Vehicles[J]. Journal of System Simulation, 2023, 35(6): 1203-1214.

Joint Optimization Strategy of Computing Offloading and Edge Caching for Intelligent Connected Vehicles

Ding Fei^{1,2,3}, Sha Yuchen^{1,2*}, Hong Ying^{1,2}, Kuai Xiao^{1,2}, Zhang Dengyin^{1,2,3}

(1. School of Internet of things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China;

2. Key Laboratory of Broadband Wireless Communication and Internet of Things of Jiangsu Province, Nanjing University of Posts and Telecommunications, Nanjing 210003, China; 3. National Engineering Research Center for Communication and Network Technology, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: To guarantee the low-delay communication of intelligent connected vehicles, the V2X channel model and the multi-access edge computing (MEC) technology, are used to carry out the research of the joint optimization strategy of computing offloading and edge caching. An intelligent connected vehicle with task offloading and edge caching model least-deep deterministic policy gradient(L-DDPG) is developed. By integrating the vehicular local and edge computing resources, the classification processing of different computing tasks in V2X scenarios is supported. The vehicular computing request is prejudged by edge platform to ensure the rapid response of continuous homogeneous computing tasks. Combining

收稿日期: 2022-03-01 修回日期: 2022-04-25

基金项目: 国家自然科学基金(61871446, 61872423); 江苏省重点研发计划(BE2020084-1); 江苏省“六大人才高峰”高层次人才培养(DZXX-008); 中国博士后科学基金面上资助项目(2019M661900); 江苏省博士后科研资助计划(2019K026)

第一作者: 丁飞(1981-), 男, 副教授, 博士, 研究方向为物联网与信息系统、边缘智能与协同计算等。E-mail: dingfei@njupt.edu.cn

通讯作者: 沙宇晨(1996-), 女, 博士生, 研究方向为车载计算与边缘智能。E-mail: 554320330@qq.com

with the least recently used strategy, the new computing tasks are efficiently managed. A joint offloading decision for computing offloading and edge caching is carried out based on deep deterministic policy gradient(DDPG) algorithm. Simulation results show that the performance of L-DDPG model is better than that of traditional models, which can effectively improve the system performance, ensure the service quality, and reduce the time delay and resource consumption.

Keywords: intelligent connected vehicle; vehicle to everything(V2X); multi-access edge computing; deep reinforcement learning; computing offloading; edge caching

0 引言

蜂窝车联网C-V2X(cellular-vehicle to everything)及其智能网联交通系统是我国交通强国战略的重要发展内涵。C-V2X技术基于蜂窝网络进行组网并服务, V2X业务场景丰富, 包括车对车通信V2V、车与网络V2N通信、车与基础设施V2I通信和车与人V2P通信等多种模式^[1]。随着智能网联汽车的大规模接入、并发服务及V2X业务的混合作用加强, 给智能网络汽车的单车V2X通信和区域V2X组网均带来了不稳定因素。

欧洲电信标准协会ETSI早期提出移动边缘计算(mobile edge computing, MEC)技术, 通过部署靠近用户的边缘计算平台以改善用户接入服务体验。为适应泛在接入需要, ETSI将MEC技术扩展为多接入边缘计算(multi-access edge computing, MEC), 发布典型业务场景标准^[2-3], 并制定了服务、架构和应用程序接口规范^[4-6]。多接入边缘计算不同于传统集中式云计算范式, 通过对边缘设施资源的实时监测并动态分配, 不仅可增强端-边-云协同场景下的任务计算能力, 而且能优化终端接入与系统服务性能。

在C-V2X实际环境下, 大规模智能网联汽车接入的同时会产生大量的计算密集型业务, 而单车车载单元(on board unit, OBU)的计算、存储和通信能力有限。MEC网络架构为用户层的分布式计算需求提供了有利支撑条件, 前期围绕MEC赋能的边缘计算服务方面已取得较多研究进展。文献[7-8]分别在异构网络框架下, 配置MEC服务器用于业务卸载, 以此提升用户侧的服务体验。文献

[9]针对不同业务进行分类卸载, 在计算能力受限的条件下实现时延最小化的目的。针对差异化业务卸载场景, 文献[10-11]将软件定义网络(software defined network, SDN)和MEC技术相结合, 支持对全局网络信息进行实时感知, 前者定义了一种业务重要度模型, 可实现对不同优先级业务进行优化卸载; 后者为V2X组网系统设计了计算卸载与资源分配方案。上述研究重点考虑了MEC平台的计算能力, 但未综合利用MEC平台的缓存能力。

为进一步提高卸载效率、降低成本代价, 通过对边缘资源进行整合并引入机器学习方法完成协同计算决策, 可以改善大规模用户接入造成的网络传输压力^[12]。文献[13]阐述了大规模无线网络在边缘计算与缓存赋能下造成的新型关键问题及对应的解决方案。文献[14]将深度强化学习引入车联网架构和应用设计中, 增强了车联网系统的智能决策能力。文献[15]针对边缘云存在大量的重复计算任务问题, 提出一种边缘抵近式缓存方法, 以多播的方式将缓存内容高效地分发给对应用户。文献[16]考虑了业务到达的随机性, 为MEC业务卸载系统设计了一种基于李雅普诺夫和遗传算法的时延优化方案。文献[17]将随机几何理论用于边缘云的大规模接入场景下的时延分析, 旨在为车联网接入与大规模部署提供设计参考。文献[18]提出了一种V2X协同缓存与资源分配机制, 重点研究了缓存机制中的内容流行度模型, 分别利用图着色模型及拉格朗日乘法对信道及计算资源合理分配, 实现V2X场景下计算、缓存和通信资源的合理利用。上述基于机器学习的计算卸载方法, 均采用独立的深度学习或强化学习模型, 当智能

网联汽车存在连续的异质计算任务时, 往往会制约智能计算卸载算法的决策性能。

现有边缘协同计算研究已取得较多有益成果, 任务卸载可以有效地解决车载 OBU 资源受限的问题, 但没考虑 MEC 平台的缓存状态, 而将计算任务全部卸载到边缘服务, 并非最优。同时, MEC 平台资源有限, 需要为其设计边缘缓存排队调度策略以满足卸载控制策略的高效实施。现有融入无线通信模型的边缘卸载研究大多采用传统 H2H 模型^[19], 无法很好地描述蜂窝车联网 V2X 通信性能。

本文面向高实时性的车路云协同的车联网场景, 提出了一种计算卸载与边缘缓存协同模型 L-DDPG (least-deep deterministic policy gradient), 联合 MEC 平台制定协同缓存策略; 植入 3GPP 定义的 LTE/5G 系统面向车联网服务的 V2X 通信模型, 利用最近最少使用法 LRU 和深度确定性策略梯度 DDPG 算法, 通过计算卸载与边缘缓存协同以提升车载计算的工作性能, 在最大容忍时延和计算资源等约束条件下, 同时使系统成本最小化。该方案主要特点是在大规模动态接入的蜂窝车联网场景下, 充分利用 MEC 平台的架构优势, 助力实现车载计算任务的自适应卸载与高效处理。

1 系统模型

1.1 网络模型

智能网络汽车计算卸载与边缘缓存协同服务系统模型如图 1 所示。在这个模型中, 道路侧部署信号灯、路侧单元设施 (road side unit, RSU) 和摄像头, 同时, 区域云包括了信号灯控制器、边缘服务器和视频录像机等, 可以协同处理智能网络汽车通过蜂窝网络传来的业务, 将业务卸载到计算、缓存资源充足的边缘服务器。目标研究区域部署 L 个路侧设施单元, 每个 RSU 与 MEC 服务器之间采用光纤连接以保证实时性。车辆与 MEC

服务器配备不同的计算资源, 两者隶属于 V2X 系统中的不同服务节点。网联车辆在 V2X 组网过程中, 发起的业务可与 MEC 平台之间进行 V2R 卸载。




图 1 系统模型
Fig. 1 System model

假设车辆部署满足 Poisson 分布, 表示为 $V = \{v_1, v_2, \dots, v_i\}$ 。各车辆在 V2X 组网过程中, 将网联车辆 v_i 发起的计算任务定义为 $\tau_i = d_i$, d_i 表示计算任务 τ_i 对应的数据量。边缘计算与缓存协同的卸载目标是充分利用以网联车辆组建的 V2X 网络以及所处道路区域的 MEC 服务器的有限资源, 车辆卸载决策定义为 $Z = \{z_1, z_2, \dots, z_i\}$ 。

由于车辆用户在业务请求卸载过程中, 对时延、能耗、功率、计算能力等约束条件的要求不同, 因此, 本文利用 MEC 服务器的缓存功能更好地为用户提供服务。定义 MEC 服务器的资源空间为 $C = \{c_1, c_2, \dots, c_i\}$, 其中, $i \geq L$, 即 RSU 可以配置 1 个或多个 MEC 服务器, $c_i = 1$ 表示第 L 个 MEC 服务器节点里已缓存了车联网 V2X 任务的计算结果; $c_m = 0$ 表示 MEC 服务器节点未缓存该业务。边缘计算与缓存协同卸载场景包括: ① V2V 计算

任务卸载；②V2R计算任务卸载；③MEC给出该计算任务的历史执行结果，无需重复计算，直接传输结果给用户。基站的传输功率远大于终端用户设备，计算任务的结果回传时延可以忽略不计^[20]。

1.2 V2X通信模型

智能网联汽车在V2X组网体系结构下，本车发起的计算任务将在邻车与MEC平台之间进行联合卸载与优化。假设智能网联汽车均配备工作于同一频段的专用天线，通过支持冲突避免的载波侦听多路访问CSMA/CA(carrier sense multiple access with collision detection)机制竞争信道，保障链路共享信道传输^[21]。

根据3GPP TR 37.885^[22]和TR 38.901^[23]对LTE/NR-V2X用例评估方法的定义，高速公路场景下V2V链路视距条件下的路径损耗模型为

$$PL_{V2V} = 32.4 + 20 \lg d_{2D} + 20 \lg f_c \quad (1)$$

式中： d_{2D} 为源车辆与目标车辆之间的平面距离； f_c 为载波频率。

考虑到天线高度与部署差异，将V2R链路视距条件下的路径损耗模型分类为^[22]

$$PL_{V2R} = \begin{cases} PL_1, & 10 \text{ m} \leq d_{2D} \leq d_{BP} \\ PL_2, & d_{BP} \leq d_{2D} \leq 5 \text{ km} \end{cases} \quad (2)$$

当 $10 \text{ m} \leq d_{2D} \leq d_{BP}$ 时，将V2R链路的视距条件下路径损耗模型定义为

$$PL_1 = 28 + 22 \lg d_{3D} + 20 \lg f_c \quad (3)$$

当 $d_{BP} \leq d_{2D} \leq 5 \text{ km}$ 时，将V2R链路的视距条件下路径损耗模型定义为^[23]

$$PL_2 = 28 + 40 \lg d_{3D} + 20 \lg f_c - 9 \lg (d_{BP}^2 + (h_{BS} - h_{UT})^2) \quad (4)$$

式中： h_{BS} 和 h_{UT} 分别为路侧基站和智能网联汽车天线的部署高度； d_{3D} 为源车辆和目标基站之间的3D距离； c 为光速； $d_{BP} = 4h_{BS}h_{UT}f_c/c$ 为中断距离。

根据香农公式^[24]，将车辆 v_i 的数据上传速率定义为

$$R_{i,j} = B \lg \left(1 + \frac{p_v PL_{V2X}^{-\delta} h_{ij}^2}{\sigma^2} \right) \quad (5)$$

式中： p_v 为车辆 v_i 的发射功率； $PL_{V2X}^{-\delta}$ 为车辆与目标节点(邻车或路侧基站)之间的路径损耗； δ 为路径损耗因子； h_{ij}^2 为任务请求车辆 v_i 与服务设备之间的信道增益； σ^2 为高斯白噪声功率； B 为信道带宽。

1.3 边缘决策模型

在5G NR-V2X架构下，网络功能虚拟化使网络部署更加灵活，边缘云将更多的数据从“核心”下沉到道路“边缘”，使时延敏感业务无需经过接入网送至云服务端处理，可以保障时延约束的同时优化网络负载。智能网联汽车发起的计算请求，边缘缓存模型实时解析并缓存。缓存决策时，若存在历史执行结果，则直接推送给当前车辆，否则执行计算卸载与服务缓存的联合优化。

边缘缓存模型通过队列组建和队列更新，以实现对上述计算请求的连续处理。在队列组建过程中，引入LRU算法对边缘缓存数据链表进行管理，在设定的最大缓存空间 H_m 内，车辆发来的新请求数据和缓存命中数据，均会不断填入链表头部。在缓存队列更新阶段，数据链表将动态加入高频次访问的计算任务，而动态淘汰低频次计算任务。考虑到边缘缓存空间的有限性，为保障实时请求和活跃任务的处理，队列尾部的链路数据也将不断被丢弃。

假设智能网络汽车发起计算任务的请求概率服从Zipf分布，该计算请求被边缘缓存解析，LRU队列中存在对应历史执行结果的概率为

$$p'_{LRU} = 1 - (1 - p_{LRU})^{H_m} \quad (6)$$

式中： p_{LRU} 为网联车辆请求业务出现在队首的概率； H_m 为最大缓存空间。

LRU算法缓存命中率为

$$\pi = p_{LRU} p'_{LRU} \quad (7)$$

在边缘服务器中，由于缓存能力有限，因此，缓存空间总量不能超过 H_m 。

1.4 计算模型

智能网联汽车 v_i 在行驶过程中, 若本地计算任务在边缘侧存在缓存结果, 则从边缘平台直接获取对应结果; 否则, 通过执行本地计算与边缘服务缓存相结合, 再采用权重融合上述2个分量, 从而获得计算模型的代价函数评估值。考虑到智能网联汽车的低时延约束要求, 为其V2X通信系统设定最大容忍时延。

(1) 本地计算模型

假设本地计算时延小于最大容忍时延条件, 计算任务 τ_i 采用本地卸载方案, 此时计算任务 τ_i 的本地执行时延与车载计算平台的处理性能有关, 计算时延为^[25]

$$t_i^1 = (1 - \mu_i) \frac{d_i}{f_i^v} \quad (8)$$

式中: f_i^v 为网联车载平台的计算能力。

车载计算平台在执行该计算任务时的资源消耗评价函数为

$$e_i^1 = p_c t_i^1 \quad (9)$$

式中: p_c 为CPU的能耗功率。

将本地计算的代价函数表示为^[26]

$$C_i^1 = \alpha \bar{t}_i^1 + (1 - \alpha) \bar{e}_i^1 \quad (10)$$

式中: α 和 $1 - \alpha$ 分别为计算任务的时延和资源消耗权重, $\alpha \in [0, 1]$; \bar{t}_i^1 为归一化后的本地计算时延; \bar{e}_i^1 为归一化后的本地资源消耗。车载计算任务为同质业务时, α 取值为0.5; 车载计算任务为异质业务(时延敏感型业务与资源消耗型业务)时, 将时延敏感型业务占全量业务的比例设为 α 权重值。

考虑到时延和能耗量纲不一致, 为了消除量纲对加权的影响, 针对时延和能耗作归一化处理, 即获得归一化后的时延 \bar{t}_i^1 和归一化后的能耗 \bar{e}_i^1 , 然后加权求和作为目标函数。

(2) 边缘计算模型

当计算任务本地计算时延大于最大容忍时延时, 该智能网联汽车将协同边缘缓存资源, 将部分计算任务卸载到MEC服务器, 以满足最低时延

的约束要求。

计算任务 τ_i 卸载至边缘服务器的计算时延为^[25]

$$t_i^{\text{off}} = \mu_i \left(\frac{d_i}{R_{i,j}} + \frac{s_i}{f_i^m} \right) \quad (11)$$

式中: f_i^m 为MEC服务器的计算能力; s_i 为计算任务所需的CPU周期数。

计算任务卸载至边缘节点的资源消耗评价函数为

$$e_i^{\text{off}} = p_v t_i^{\text{off}} \quad (12)$$

得出边缘协同计算的代价函数为

$$C_i^{\text{off}} = \alpha \bar{t}_i^{\text{off}} + (1 - \alpha) \bar{e}_i^{\text{off}} \quad (13)$$

式中: \bar{t}_i^{off} 为归一化后的边缘计算时延; \bar{e}_i^{off} 为归一化后的边缘资源消耗。

2 L-DDPG 协同卸载模型

2.1 问题描述

智能网络汽车采用的边缘卸载与服务缓存联合优化的处理流程如图2所示, 当车辆有计算任务请求时, 该请求发至边缘服务器, 图2中步骤①若边缘服务器缓存了该计算任务的执行结果, 则采用步骤②将缓存结果直接推送给车辆计算平台; 若边缘服务器识别为新计算请求, 则由车辆调用步骤③和④, 通过本地计算或协同计算的方式实现计算任务的卸载。

假设智能网联汽车存在计算任务 τ_i 时, 车载本地计算与边缘缓存卸载可以建模为本地计算资源、MEC计算资源和缓存空间联合优化问题, 求解在最大容忍时延和通信、计算、缓存资源限制条件下的最优服务策略。因此, 优化目标为

$$\min C_{ij} = \sum_{i=1}^N [(1 - z_i) C_i^1 + z_i C_i^{\text{off}}] \quad (14)$$

s.t.

$$C_1: 0 \leq z_i \leq 1, \forall i \in N$$

$$C_2: 0 < f_i \leq F_j^{\text{max}}, \forall i \in N, j \in L$$

$$C_3: \sum_{i \in N} p_i d_i \leq H_m, \forall i \in N$$

$$C_4: 0 < t_i^1 + t_i^{\text{off}} \leq t_i^{\text{max}}, \forall i \in N$$

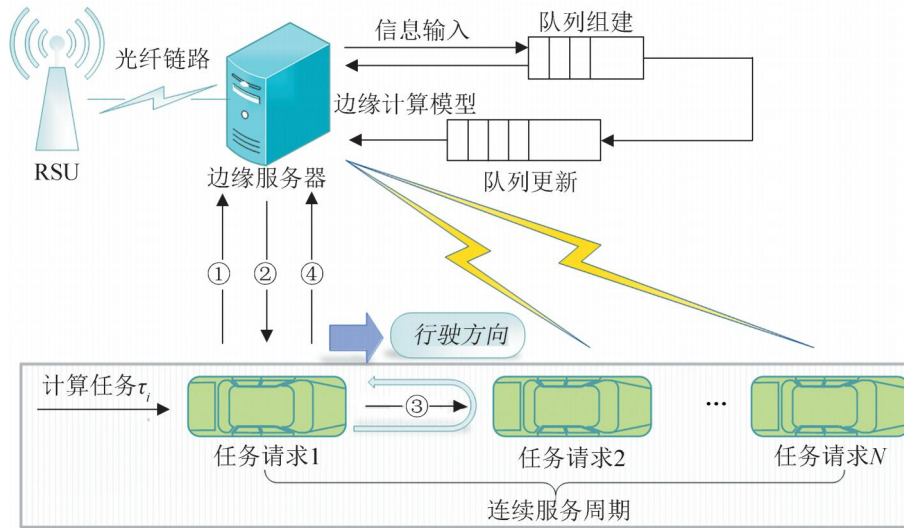


图2 车载计算卸载的优化流程

Fig. 2 Optimization process of vehicular computing offloading

约束条件 C_1 表示卸载决策为 $[0, 1]$ 的连续变量； C_2 表示计算资源之和不超过服务节点的最大计算能力； C_3 表示缓存至边缘服务器的数据内容不能超过最大缓存空间 H_m ； C_4 表示车辆用户满足计算卸载的时延容忍度，保障车辆 V2X 通信系统的服务质量。

2.2 基于 LRU 的边缘缓存算法

智能网联汽车在 V2X 组网中，生成的计算任务由 RSU 上报给边缘服务器进行数据分析及决策，然后将决策结果回传到 RSU 并广播给车辆。边缘服务器配置了多线程哈希队列机制，从而满足区域网联车辆的分布式计算任务的请求。在单个线程处理中，车辆 v_i 发起的计算任务 τ_i 请求到达时，哈希队列将先进行任务识别，当存在未处理的相同缓存任务时，哈希队列将移除原任务，并将新任务插入队首；否则，新任务将直接添加到队首，同时移出溢出的队尾任务。

通过上述分析可以看出，将 LRU 算法作为边缘服务器的基准置换算法，可以为边缘服务器节省空间，为更多的业务提供资源。边缘处理过程如算法 1 所示。

算法 1 基于 LRU 算法的边缘计算与缓存协同算法

初始化：车辆数为 N ，计算任务 τ_i ，缓存空间 H_m

for $i = 1: N$ do

判断边缘缓存空间是否有对应结果

if 命中任务 τ_i 结果

then 直接返回结果值

end if

if 识别为新任务

then 将任务插入队首

end if

end for

2.3 L-DDPG 协同卸载决策

在智能网联组网服务场景中，车辆数为 N ，每辆车随机产生计算任务为 d_i ，L-DDPG 协同卸载决策的目标是充分利用车载平台和边缘服务器的计算资源，达到优化系统时延和能量消耗的目的。基于 L-DDPG 算法的边缘计算与缓存协同的卸载框架如图 3 所示。




图 3 L-DDPG 协同卸载框架
Fig. 3 L-DDPG collaborative offloading framework

假定 t 时刻执行的策略为 A_t 、工作状态为 S_t ，可获得奖励为 R_t 。上述策略、状态和奖励分别定义为^[27]

状态空间：网联汽车在时间 $t=\{0, 1, \dots, T-1\}$ ，状态可以描述为 $S_t = \tau_i(t)$, $t \in t_i^{\max}$ 。

策略空间：定义为卸载决策向量 $A_t = \{z_1, z_2, \dots, z_i\}$ 。

奖励函数：奖励函数定义为 $R_t = - \sum_{i \in t_i^{\max}} C_{ij}(t)$ 。

DDPG 算法是基于 Actor-Critic 架构的深度强化学习算法，由 Actor 网络和 Critic 网络对系统的值函数和最终策略进行估计，其中隐藏层均由 360 个神经元组成^[26]。该模型通过神经网络的梯度反向传播更新 Critic 当前网络的参数 ω 及 Actor 当前网络的参数 θ ，从而更新 Critic 目标网络和 Actor 目标网络。

在 t 时刻，Actor 网络基于当前状态 S_t 执行的策略 A_t ，通过迭代计算进行策略更新，获得奖励

值 R_t 并进入下一状态 S_{t+1} 。Actor 将状态转换过程存储到经验回放池。

智能网联汽车并发入网时，车辆发起的计算任务为 τ_i , $i \in N$ ，输入 DNN 进行训练，提取最优参数值，最大迭代次数设为 1 000 次。为了提高训练效率，引入不相关的非 0 高斯噪声来探索策略，并使用梯度下降法进行参数更新。

DNN 利用双曲正切函数表示边缘计算与缓存协同模型的激活函数，损失函数结合了神经网络的特性及大规模接入业务场景做出调整与优化。对于 Critic 网络采用最小均方差损失函数^[28]：

$$U(\omega) = \frac{1}{L} \sum_{j=1}^L (y_j - Q(S_t, A_t, \omega))^2 \quad (15)$$

式中： L 为路侧单元数量； $j \in \{1, 2, \dots, L\}$ 为经验回放池随机采样的数据； y_j 为 Critic 目标网络中计算的当前目标 Q 值； $Q(\omega)$ 为 Critic 网络所选策略的当

前 Q 值。

Actor 网络的损失函数为^[28]

$$J(\theta) = -\frac{1}{L} \sum_{j=1}^L Q(S_j, A_j, \omega) \quad (16)$$

经过 DDPG 算法训练后，可以获得模型的最大奖励值。由于强化学习的目标是获得最大奖励，因此该奖励值与成本代价之间呈负相关。

DDPG 算法的执行过程如算法 2 所示。

算法 2 基于 DDPG 的边缘计算与缓存协同算法

输入：计算任务大小 d_i ，最大容忍时延 t_i^{\max} ；

输出：最优卸载策略。

begin

初始化：经验回放池，每个 Agent 的 Actor 策略网络和 Critic 评价网络

for $i = 0$ to Z do

初始化非 0 高斯噪声和初始状态 S_i

for $t = 0$ to T do

在状态 S_t 选择策略 A_t ，迭代出奖励 R_t ，进入下一状态 S_{t+1}

在经验回放池中存储计算样本值，即组合参量 (S_t, A_t, R_t, S_{t+1})

状态更新 $S_t = S_{t+1}$

从经验回放池中选取样本并计算 Q 值

依据最小化损失函数，更新 Critic 评价网络

参数 ω

通过最大化决策目标函数更新 Actor 网络

参数 θ

end for

end for

获得计算任务的卸载路径与任务分配策略

end

3 仿真结果与分析

为了评估 L-DDPG 协同卸载模型的有效性与工作性能，基于 Python 开发环境搭建仿真系统并测试验证。L-DDPG 研究智能网联汽车异构网络

中基于 MEC 的计算卸载和边缘缓存协同问题，利用 MEC 服务器增强边缘缓存能力，对体系架构内计算、缓存和通信资源进行有效整合。从车辆数、计算任务量和路侧边缘节点数等方面，将 L-DDPG 卸载模型与车辆本地(Local)卸载、服务器(Server)卸载和 LOO(local or offloading)卸载机制^[29]进行性能对比，评价不同卸载方案的优劣。假设每个 RSU 配置一个边缘服务器、多个边缘节点和每个边缘服务器之间采用边缘云部署结构实现互联互通。仿真实验的配置参数详见表 1。

表 1 仿真参数
Table 1 Simulation parameters

参数	数值
RSU 覆盖半径/m	300
车辆发射功率 p_v /dBm	20
CPU 能耗功率 p_c /W	5
路侧边缘节点数	[3, 7]
单个 MEC 节点的计算能力 f_i^m /GHz	[5, 9]
上行传输信道数量 K	10
信道总带宽 B /MHz	20
高斯白噪声功率 σ^2 /dBm	-100
车辆计算能力 f_i^v /GHz	1
计算任务大小 d_i /MB	20
权重因子 α	0.5
缓存空间 H_m /MB	500
最大容忍时延 t_i^{\max} /s	0.003
载波频率 f_c /GHz	5.915
基站的高度 h_{BS} /m	35
车辆的高度 h_{UT} /m	1.5
发送信号功率 P_{tx} /dBm	23
天线增益 $G_{antenna}$ /dBi	3
噪声功率 P_{noise} /W	3×10^{-13}

为了验证 L-DDPG 卸载模型引入 DDPG 算法对 MEC 计算任务进行优化处理的可行性与算法的性能，进行了收敛性对比实验，其中学习率是决定目标函数的收敛性能之一。由图 4 可以看出，该算法可以收敛，证明了该算法用于解决该问题是可行的。当迭代次数超过 392 次时，L-DDPG 卸载模型收敛到局部最优值阶段。同时，不同学习率条件下奖励值的震荡差异较大，其中学习率为 0.001 时的奖励值曲线稳定性更优，学习率配置过

小时,会导致算法的迭代优化效率过低;当学习率过大时,会造成过度学习并引起奖励值的上下波动幅度过大。




图4 不同学习率下迭代次数与奖励关系

Fig. 4 Iteration times and rewards under different learning rates

DDPG模型在强化学习过程中,通过折扣率避免产生状态的无限循环。图5显示了在不同折扣率下,迭代次数与奖励之间的关系变化。通过对比发现,折扣率设为0.9时,算法最先进入收敛阶段,即具有更快的收敛速度。折扣率为0.9,迭代次数在接近396次时,奖励值已开始进入收敛状态,最终趋于平稳;折扣率为0.7,迭代次数为534次后开始收敛;折扣率为0.5,从奖励值的收敛值来看,迭代次数为879次后开始收敛,此时收敛速度最慢。




图5 不同折扣率下迭代次数与奖励关系

Fig. 5 Iteration times and rewards under different discount rates

不同边缘节点数量将影响智能网联汽车计算任务的卸载,图6显示边缘节点数与奖励之间的关系。仿真结果表明,在3种情况下,边缘节点配置为7个时,L-DDPG模型最先进入收敛(迭代次数为245时),其次为5个(迭代次数为341时),最后是3个。在边缘云部署架构下,随着边缘节点数量的增加,计算、存储和网络资源的统一管理与应用,将可以提升智能网联汽车V2X组网的卸载效率。




图6 不同边缘节点时的奖励

Fig. 6 Rewards for different edge nodes

从不同学习率和折扣率的仿真结果来看,L-DDPG模型可以在396次迭代次数中实现收敛。因此,在对不同计算任务的卸载方案的性能对比时,学习率统一配置为0.001、折扣率配置为0.9,边缘节点配置为7个,并在396次迭代纬度上找到最优值进行性能对比,确保L-DDPG模型具有较好的处理效率。

图7给出了MEC计算能力与系统成本关系的仿真结果,可以看出,相比车辆本地卸载、服务器卸载及LOO卸载模型,本文所采用的L-DDPG模型在降低系统成本方面优于其他模型,随着MEC计算能力的增加,服务器卸载、LOO卸载模型和L-DDPG模型的系统成本均处于下降趋势,而车辆本地卸载由于未引入边缘服务器,造成系统成本无法获得优化。LOO模型在对车联网业务进行卸载决策时,输出了本地和服务器2类卸载

方案, 由于未实施计算任务卸载与边缘缓存联合优化, 故其系统成本高于L-DDPG模型。L-DDPG模型将车路资源充分利用, 因此可以获得更优的系统成本。

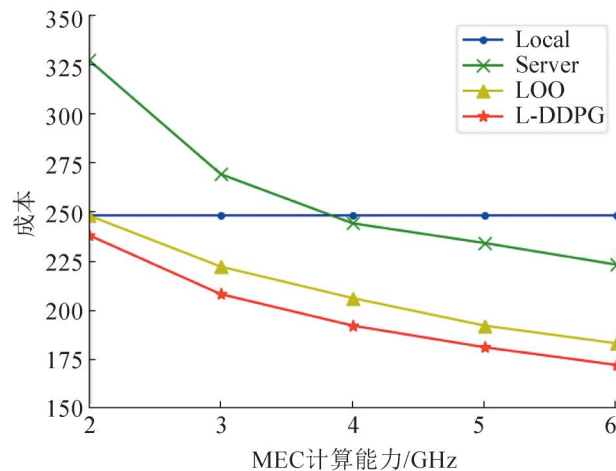


图7 MEC计算能力与系统成本关系

Fig. 7 MEC computing capability v.s. system cost

智能网联汽车与C-V2X技术的融合, 极大地丰富了V2X业务场景与服务类型。图8为任务量与系统成本关系的仿真结果, 可以看出, 系统中的成本代价随着任务量的增加而增加, 4种卸载模型产生的系统成本均处于上升趋势。传统的车辆本地卸载由于车辆本身计算能力有限而带来较大的时延开销。在相同任务量时, 车辆本地卸载模型的成本增加速度最快, 服务器卸载模型次之; LOO卸载模型和L-DDPG模型的成本线性增长率基本一致, 但DDPG模型产生的绝对成本代价均优于LOO卸载策略。

图9给出了车辆数与系统成本关系图的仿真结果, 可以看出, 随着车辆不断增加, 4种卸载策略下系统成本均处于上升趋势。并且, 在不同车辆数场景下, L-DDPG模型均可获得最优的系统成本。由图8和9可以看出, 计算任务和智能网联汽车数据量对成本代价影响较大。其中, 计算任务在车辆本地卸载时, 由于大量V2X业务的并发, 造成对有限资源的竞争激烈, 系统成本增长速度最快, 最大达到7%; 服务器卸载模型时的系

统成本增长率次之, 最大达到6%; LOO和L-DDPG模型的系统成本增长速度最慢, 最大增长率分别为4%和3%。




图8 任务数与系统成本关系

Fig. 8 System cost with different tasks

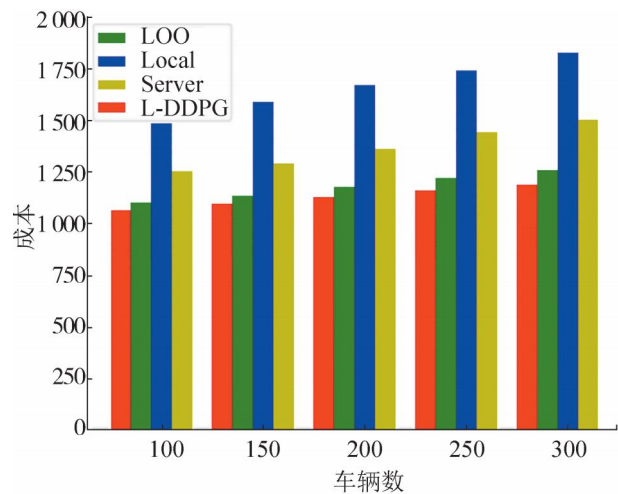


图9 车辆数目与系统成本关系

Fig. 9 System cost with different number of vehicles

4 结论

本文针对MEC赋能下智能网络汽车计算卸载与边缘缓存联合优化策略进行研究, 通过约束车辆计算任务的最大服务时延, 建立系统成本最优化的协同卸载模型与算法。车辆V2X计算请求卸载时, 由边缘缓存进行任务识别, 充分利用服务器计算缓存结果, 可以提升对相同计算任务的处

理效率; 针对新技术任务, 在边缘侧采用LRU算法对任务队列进行优化处理, 同时建立基于深度学习的协同卸载决策算法求解本地计算与边缘缓存卸载的最优决策。对比传统车辆本地卸载模型、服务器卸载模型和LOO卸载模型, L-DDPG卸载模型可以获得更优的计算卸载性能。研究结果为下一步部署智能网联汽车、综合边缘基础设施和技术演进、统一协调车路云协同系统的落地并应用提供理论基础与技术参考。

参考文献:

- [1] 王君, 纪晓东, 张欣然, 等. 5G蜂窝车联网组网性能研究[J]. 电信科学, 2020, 36(1): 49-57.
Wang Jun, Ji Xiaodong, Zhang Xinran, et al. Performance Evaluation of 5G Cellular Vehicle Networks[J]. Telecommunications Science, 2020, 36(1): 49-57.
- [2] European Telecommunications Standards Institute. ETSI GS MEC 002, Mobile Edge Computing(MEC); Technical Requirements: V1.1.1[S]. Valbonne-sophia Antipolis France: European Telecommunications Standards Institute, 2016.
- [3] European Telecommunications Standards Institute. ETSI GS MEC 001, Mobile Edge Computing(MEC); Terminology: V1.1.1[S]. Valbonne-sophia Antipolis France: European Telecommunications Standards Institute, 2016.
- [4] European Telecommunications Standards Institute. ETSI GS MEC-IEG 004, Mobile Edge Computing(MEC); Service Scenarios: V1.1.1[S]. Valbonne-Sophia Antipolis France: European Telecommunications Standards Institute, 2015.
- [5] European Telecommunications Standards Institute. ETSI GS MEC 009, Mobile Edge Computing (MEC); General principles for Mobile Edge Service APIs: V1.1.1[S]. Valbonne-sophia Antipolis France: European Telecommunications Standards Institute, 2017.
- [6] European Telecommunications Standards Institute. ETSI GS MEC 011, Mobile Edge Computing(MEC); Mobile Edge Platform Application Enablement: V1.1.1[S]. Valbonne-sophia Antipolis France: European Telecommunications Standards Institute, 2017.
- [7] Zhang Ke, Mao Yuming, Leng Supeng, et al. Optimal Delay Constrained Offloading for Vehicular Edge Computing Networks[C]//2017 IEEE International Conference on Communications(ICC). Piscataway, NJ, USA: IEEE, 2017: 1-6.
- [8] Liu Yujiong, Wang Shangguang, Huang Jie, et al. A Computation Offloading Algorithm Based on Game Theory for Vehicular Edge Networks[C]//2018 IEEE International Conference on Communications(ICC). Piscataway, NJ, USA: IEEE, 2018: 1-6.
- [9] Wang Hansong, Li Xi, Ji Hong, et al. Federated Offloading Scheme to Minimize Latency in MEC-Enabled Vehicular Networks[C]//2018 IEEE Globecom Workshops(GC Wkshps). Piscataway, NJ, USA: IEEE, 2018: 1-6.
- [10] 张海波, 荆昆仑, 刘开健, 等. 车联网中一种基于软件定义网络与移动边缘计算的卸载策略[J]. 电子与信息学报, 2020, 42(3): 645-652.
Zhang Haibo, Jing Kunlun, Liu Kaijian, et al. An Offloading Mechanism Based on Software Defined Network and Mobile Edge Computing in Vehicular Networks[J]. Journal of Electronics & Information Technology, 2020, 42(3): 645-652.
- [11] 张海波, 王子心, 贺晓帆. SDN和MEC架构下V2X卸载与资源分配[J]. 通信学报, 2020, 41(1): 114-124.
Zhang Haibo, Wang zi Xin, He Xiaofan. V2X Offloading and Resource Allocation Under SDN and MEC Architecture[J]. Journal on Communications, 2020, 41(1): 114-124.
- [12] Huang Xumin, Yu Rong, Kang Jiawen, et al. Distributed Reputation Management for Secure and Efficient Vehicular Edge Computing and Networks[J]. IEEE Access, 2017, 5: 25408-25420.
- [13] 黄永明, 郑冲, 张征明, 等. 大规模无线通信网络移动边缘计算和缓存研究[J]. 通信学报, 2021, 42(4): 44-61.
Huang Yongming, Zheng Chong, Zhang Zhengming, et al. Research on Mobile Edge Computing and Caching in Massive Wireless Communication Network[J]. Journal on Communications, 2021, 42(4): 44-61.
- [14] Ji Hongjing, Alfarraj O, Tolba A. Artificial Intelligence-empowered Edge of Vehicles: Architecture, Enabling Technologies, and Applications[J]. IEEE Access, 2020, 8: 61020-61034.
- [15] 兰巨龙, 王鹏, 申涓, 等. 大规模接入汇聚网络的抵近式缓存技术研究[J]. 物联网学报, 2017, 1(1): 50-54.
Lan Julong, Wang Peng, Shen Juan, et al. Research on Push Cache of Large-scale Converging Access Networks [J]. Chinese Journal on Internet of Things, 2017, 1(1): 50-54.
- [16] El Haber E, Nguyen T M, Assi C. Joint Optimization of Computational Cost and Devices Energy for Task Offloading in Multi-tier Edge-clouds[J]. IEEE Transactions on Communications, 2019, 67(5): 3407-3421.
- [17] Zhang Ni, Guo Songtao, Dong Yifan, et al. Joint Task

- Offloading and Data Caching in Mobile Edge Computing Networks[J]. *Computer Networks*, 2020, 182: 107446.
- [18] Ko S W, Han Kaifeng, Huang Kaibin. Wireless Networks for Mobile Edge Computing: Spatial Modeling and Latency Analysis[J]. *IEEE Transactions on Wireless Communications*, 2018, 17(8): 5225-5240.
- [19] Ebrahimzadeh A, Maier M. Cooperative Computation Offloading in FiWi Enhanced 4G HetNets Using Self-organizing MEC[J]. *IEEE Transactions on Wireless Communications*, 2020, 19(7): 4480-4493.
- [20] Deng Maofei, Tian Hui, Lü Xinchun. Adaptive Sequential Offloading Game for Multi-cell Mobile Edge Computing[C]//2016 23rd International Conference on Telecommunications(ICT). Piscataway, NJ, USA: IEEE, 2016: 1-5.
- [21] Li Yongfu, Chen Wenbo, Peeta S, et al. Platoon Control of Connected Multi-vehicle Systems under V2X Communications: Design and Experiments[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21(5): 1891-1902.
- [22] The Alliance for Telecommunications Industry Solutions. ATIS. 3GPP. 37.885. V1530, Study on Evaluation Methodology of New Vehicle-to-everything (V2X) Use Cases for LTE and NR [S]. Washington, DC, US: ATIS, 2019.
- [23] 3rd Generation Partnership Project. TR 38.901, Study on Channel Model for Frequencies from 0.5 to 100 GHz: V14.0.0[S]. Valbonne-sophia Antipolis France: 3rd Generation Partnership Project, 2017.
- [24] 刘雷, 陈晨, 冯杰, 等. 车载边缘计算中任务卸载和服务缓存的联合智能优化[J]. *通信学报*, 2021, 42(1): 18-26.
- Liu Lei, Chen Chen, Feng Jie, et al. Joint Intelligent Optimization of Task Offloading and Service Caching for Vehicular Edge Computing[J]. *Journal on Communications*, 2021, 42(1): 18-26.
- [25] Li S L, Du J B, Zhai D S, et al. Task Offloading, Load Balancing, and Resource Allocation in MEC Networks [J]. *IET Communications*, 2020, 14(9): 1451-1458.
- [26] Meng Hao, Chao Daichong, Huo Ru, et al. Deep Reinforcement Learning Based Delay-sensitive Task Scheduling and Resource Management Algorithm for Multi-User Mobile-edge Computing Systems[C]// Proceedings of the 2019 4th International Conference on Mathematics and Artificial Intelligence. New York, NY, USA: Association for Computing Machinery, 2019: 66-70.
- [27] Lillicrap T P, Hunt J J, Pritzel A, et al. Continuous Control with Deep Reinforcement Learning[C]//4th International Conference on Learning Representations, ICLR 2016. New York, USA: ICLR, 2016: 1-14.
- [28] Ye Junhong, Zhang Yingjun. DRAG: Deep Reinforcement Learning Based Base Station Activation in Heterogeneous Networks[J]. *IEEE Transactions on Mobile Computing*, 2020, 19(9): 2076-2087.
- [29] Tong Minglei, Wang Xiaoxiang, Wang Yulong, et al. Computation Offloading Scheme with D2D for MEC-enabled Cellular Networks[C]//2020 IEEE/CIC International Conference on Communications in China (ICCC Workshops). Piscataway, NJ, USA: IEEE, 2020: 111-116.