

基于Q学习的蜂窝车联网边缘计算系统PC-5/Uu 接口联合卸载策略

冯伟杨¹, 林思雨^{1,2*}, 冯靖涛¹, 李 贇³, 孔繁鹏⁴, 艾 渤^{1,5}

- (1. 北京交通大学电子信息工程学院, 北京 100044; 2. 轨道交通协同创新中心, 北京 100044;
3. 中国铁路信息科技集团有限公司信息调度中心, 北京 100089;
4. 中铁信(北京)网络技术研究院有限公司信息技术研究室, 北京 100089;
5. 智慧高铁系统前沿科学中心, 北京 100044)

摘要: 智能驾驶等智能交通服务对时延要求高, 在车辆本身算力不足的情况下, 车辆需要周围车辆和路旁边缘计算单元帮助其一起完成任务的计算处理. 本文在既有车联网边缘计算卸载策略基础上, 考虑了蜂窝车联网系统5G-NR接口与PC-5接口链路的特征差异, 提出了一种基于Q学习的PC-5/Uu接口联合边缘计算卸载策略. 在对蜂窝车联网PC-5链路传输成功率进行建模的基础上, 推导了PC-5链路的传输速率表征方法. 以最小化蜂窝车联网任务处理时延为目标, 以任务车辆发射功率与边缘计算车辆的计算能量损耗为约束, 构建了系统时延最小化的有约束马尔科夫决策过程. 通过拉格朗日方法, 将有约束马尔科夫决策过程问题转化为一个等价的极小极大的无约束马尔科夫决策过程, 引入Q学习设计卸载策略, 进而提出基于Q学习的蜂窝车联网边缘计算系统卸载策略. 仿真结果表明, 与其他基线方案相比, 本文提出的算法可以降低系统时延27.3%以上.

关键词: 蜂窝车联网; 边缘计算; 有约束马尔科夫过程; 计算迁移; Q学习

基金项目: 国家重点研发计划(No.2022YFB3207400); 国家自然科学基金(No.62221001, No.61971030); 中国国家铁路集团有限公司科技研究开发计划资助项目(No.P2021S005)

中图分类号: TN929.5 文献标识码: A 文章编号: 0372-2112(2024)02-0385-11
电子学报URL: <http://www.ejournal.org.cn> DOI: 10.12263/DZXB.20220922

Q-Learning Based Joint PC-5/Uu Offloading Strategy for C-V2X Based Vehicular Edge Computing System

FENG Wei-yang¹, LIN Si-yu^{1,2*}, FENG Jing-tao¹, LI Yun³, KONG Fan-peng⁴, AI Bo^{1,5}

- (1. School of Electronic and Information Engineering, Beijing Jiaotong University, Beijing 100044, China;
2. Collaborative Innovation Center of Railway Traffic Safety, Beijing 100044, China;
3. Information Dispatch Center, China Railway Information Technology Group Co., Ltd., Beijing 100089, China;
4. Information Technology Laboratory, China Railway Information Engineering Group Network Technology Research Institute Co., Ltd., Beijing 100089, China;
5. Frontiers Science Center for Smart High-Speed Railway System, Beijing 100044, China)

Abstract: Intelligent transportation services, such as smart driving, put forward high requirements for latency. When the vehicle itself has insufficient computing power, the vehicle needs the surrounding vehicles and roadside edge computing units to help it complete the task computation. In this paper, based on the existing vehicular edge computing (VEC) offloading strategy, considering the differences between the 5G-NR interface and PC-5 interface link of cellular-V2X (C-V2X) system, we propose a Q-Learning based joint PC-5/Uu interface edge computing offloading strategy. The successful transmission probability of PC-5 link in C-V2X system is modeled, and then the transmission rate characterization method of PC-5 link is deduced. We formulate a constrained Markov decision process (CMDP) to minimize the system latency, where the objective function is the task processing latency in C-V2X system, and constraints are transmission power at task vehicle

and energy consumption of computation at vehicles with edge computing unit. By Lagrangian approach, the CMDP problem is transformed into an equivalent min-max non-constrained MDP problem, and Q-Learning is introduced to design the offloading strategy, and then the offloading strategy of C-V2X based VEC system based on Q-Learning is proposed. Simulation results show that compared with other baseline schemes, the proposed algorithm can significantly improve the system latency performance by at least 27.3%.

Key words: cellular vehicular-to-everything; edge computing; constrained Markov decision process; computation offloading; Q learning

Foundation Item(s): National Key Research and Development Program of China (No.2022YFB3207400); National Natural Science Foundation of China (No.62221001, No.61971030); China National Railway Group Co., Ltd. Science and Technology Research and Development Plan (No.P2021S005)

1 引言

车联网中各种时延敏感与高计算需求业务的兴起,如机器视觉检测、增强现实等^[1],给车联网系统带来了新的机遇与挑战.为了解决车辆计算能力不足导致的业务的处理时延大的问题,借助于边缘计算技术^[2,3],车联网边缘计算系统(Vehicular Edge Computing, VEC)作为一种新的辅助计算和集成平台应运而生^[4-6],它可以通过在路侧单元(Road Side Unit, RSU)或边缘侧的其他车辆上配置计算单元为业务服务提供计算,从而为智能业务提供性能保障^[7,8].车辆可以将这些任务卸载到边缘计算单元或邻近的空闲车辆进行辅助计算,从而减少任务处理时延,保证车联网业务时延性能要求.车载边缘计算的卸载策略引起了学术界的广泛关注.

针对车联网边缘计算需求,考虑到移动车载网络的动态特性,文献[9]提出了一种基于深度强化学习的任务卸载方法,优化网络资源配置,最小化系统能量消耗.为了减少系统时延,减轻VEC计算单元的计算负担,文献[10]提出了反向卸载框架,设计了二进制卸载和部分卸载的卸载算法和资源分配算法以最小化系统时延.文献[11]构建了任务执行时延和能量损耗的权重和最小化问题,并提出了异步云边协同的深度强化学习算法用于求解该优化问题,以获取边缘计算迁移中计算资源、带宽和迁移决策,并且自适应地调整迁移策略以实现系统总成本的最小化.文献[12]研究了联合联邦学习和计算卸载问题,提出了一种基于进化搜索的遗传算法获取车辆用户的卸载决策,以最小化系统总体延时和能量消耗.文献[13]通过优化组网、缓存和计算的分配来提升车联网集成框架的性能,并且提出了一种新的深度强化学习方法来获取资源分配策略.文献[14]提出了一种新的车辆协同边缘计算网络体系结构,介绍了相应的功能模块、通信流程,以及安装部署思路.此外,文献[14]还分析了协同任务卸载和机动性管理等带来的技术挑战.文献[15]在考虑到车辆交通的随机性、动态计算要求和时变通信条件下,提出了一种车载辅助卸载方案和基于Q学习的方法来

获得最优的计算卸载和调度策略.文献[16]设计了一种部分可观察卸载方案和基于深度递归Q网络的离线算法,使物联网设备能够在信道状态信息不完全的情况下做出最优卸载决策.文献[17]提出了一种高效的移动边缘云计算网络框架,使边缘侧和中心云侧以出售和回购的形式共享计算资源,并从社会福利最大化和各自的利润最大化两个角度提供了最优的云计算资源管理方法.文献[18]在无线供电的合作非正交多址中继网络中利用Lyapunov优化框架,提出了一种新的缓冲辅助传输方案提高能源效率.文献[19]设计了一个基于边缘计算基础设施和深度强化学习的物联网能源管理系统,进而提出了基于深度强化学习的能源高效调度方案.文献[20]考虑了车辆任务特性、无线传输和队列动态以及车辆终端移动性的影响,提出基于深度强化学习方法以最小化任务时延与能量消耗的长期成本.文献[21]在车辆边缘计算架构下提出了一个高效的调度算法,对多个车辆应用进行优先级排序,进而最小化多个应用程序的平均完成时间.

车辆边缘计算的卸载策略已经取得了一定研究成果,但是当前车辆边缘计算的卸载策略在设计时,未考虑蜂窝车联网(Cellular-V2X, C-V2X)链路传输特性,忽略了车辆之间通过PC-5接口进行信息传输时产生的资源碰撞,会过高地估计链路传输速率,导致卸载策略不合理进而增加系统时延.事实上,C-V2X架构^[22,23]下的车辆感知由于拓扑结构的快速变化而不够稳定,与传统的卸载策略相比,对C-V2X的成功传输概率进行刻画以匹配卸载策略是一大挑战.此外,当前车辆边缘计算的卸载策略是基于基站分配带宽,进行统一资源调度与分配,在考虑PC-5/Uu通信方式之后,由于PC-5接口的碰撞特性,且PC-5和Uu接口的资源耦合特性,其卸载策略难以求解.

本文提出了基于Q学习(Q-Learning)的C-V2X车联网边缘计算系统的卸载迁移机制.任务车辆生成一系列任务,可以通过车载C-V2X终端Uu接口卸载到VEC计算单元上,或者通过C-V2X终端的PC-5接口卸

载到附近的车辆上. 为了刻画C-V2X终端的PC-5接口的资源碰撞特征对卸载时延的影响,本文推导了车车通信的成功传输概率. 接着,构建了有约束马尔可夫决策过程(Constrained Markov Decision Process, CMDP),在车辆发射功率和能量损耗的约束下最小化系统时延. 通过拉格朗日方法,将CMDP转化为一个等价的极小极大的无约束马尔可夫决策过程(Markov Decision Process, MDP),然后,提出了一个基于Q学习的方案来求解CMDP问题,可以在不需要系统先验知识的情况下在线学习有效的卸载策略,提高车联网时延性能.

为了本文可读性,我们在表1中列出了所有的符号. 这些符号的含义将在下面几章节中详细定义.

表1 符号意义对照表

符号	定义
\mathcal{N}	边缘计算车辆集合
N	边缘计算车辆数量
τ	单位时隙长度
$A(t)$	到达任务车辆的任务数
λ_T	任务车辆的平均任务到达率
$A_{C,i}(t)$	任务车辆卸载到第 <i>i</i> 个边缘计算车辆的任务数
$A_S(t)$	任务车辆卸载到VEC计算单元的任务数
L	任务数据量
C	任务车辆任务的计算量
B	任务车辆Uu接口带宽
σ^2	噪声功率
$P_S^{Uu}(t)$	任务车辆在Uu接口向VEC计算单元的发射功率
d	任务车辆到RSU的距离
h^{Uu}	瑞利衰落信道因子
α	路径损耗因子
$r_S^{Uu}(t)$	任务车辆到RSU的任务传输速率
$P_{C,i}^{PC-5}(t)$	任务车辆对第 <i>i</i> 个边缘计算车辆的发射功率
$g_i^{PC-5}(t)$	任务车辆和第 <i>i</i> 个边缘计算车辆信道增益.
W_i	任务车辆和第 <i>i</i> 个边缘计算车辆之间的带宽
$C_{v2x,i}^{\max}(t)$	任务车辆和第 <i>i</i> 个边缘计算车辆理想香农信道容量
N_{frame}	1 s内的子帧数目
$\delta_{\text{HD}}(t)$	半双工错误概率
β	车辆密度
k	多车道转换系数
d_{sen}	任务车辆感知距离
$N_{\text{sub-f}}$	C-V2X系统选择窗口中子帧的数量
$N_{\text{sub-c}}$	C-V2X系统选择窗口中子信道的数量
$P_{\text{SEN}}(t)$	任务车辆的PC-5接口的成功感知概率
P^{th}	感知功率阈值
$PL_d(t)$	任务车辆和边缘计算车辆之间的路径损耗
$\text{PSR}_i(t)$	边缘计算车辆的数据包检测率

续表

符号	定义
$P_{\text{STP},i}(t)$	PC-5链路的成功传输概率
$r_{C,i}^{\text{PC5}}(t)$	任务车辆和第 <i>i</i> 个边缘计算车辆的归一化传输速率
$\Gamma_{C,i}(S(t), A(t))$	PC-5接口的等效发射功率
$f_{C,i}(t)$	第 <i>i</i> 个边缘计算车辆的计算频率
$f_S(t)$	VEC计算单元的计算频率
μ	CPU的有效电容系数
$E_{C,i}(t)$	第 <i>i</i> 个边缘计算车辆的能量损耗
Q_T^{\max}	任务车辆的最大队列长度
$Q_{C,i}^{\max}$	边缘计算车辆的最大队列长度
Q_S^{\max}	VEC计算单元的最大队列长度
$Q_T(t)$	任务车辆的队列状态信息
$Q_{C,i}(t)$	第 <i>i</i> 个边缘计算车辆的队列状态信息
$Q_S(t)$	VEC计算单元的队列状态信息
$v_{C,i}(t)$	第 <i>i</i> 个的边缘计算车辆的平均服务速率
λ_i	第 <i>i</i> 个的边缘计算车辆的平均任务到达率
$v_S(t)$	VEC计算单元的平均服务速率
λ_S	VEC计算单元的平均任务到达率

2 系统模型

本文的C-V2X边缘计算系统模型,如图1所示. 该系统包括多辆车和单个RSU,其中RSU与VEC计算单元相连接. 在VEC系统中有两种类型的车辆.

第一类是任务车辆. 这类车辆根据应用场景动态生成计算任务以支持车辆应用,例如地图导航、车辆编队、事故预警等. 任务车辆为不具备计算能力的传统车辆,如未联网的燃油汽车等,其任务为不可分割型任务,其可通过完全卸载方式卸载到周围计算单元进行计算.

第二种类型车辆称为边缘计算车辆,用 $\mathcal{N}=\{1, 2, \dots, N\}$ 表示,一般是公交、出租车等提供公共交通服务的车辆. 在高峰时段,公交车和出租车的数量很多,可以部署微型计算单元,为任务型车辆提供计算资源.

图1中VEC系统由VEC计算单元和多个边缘计算车辆组成,其中任务车辆通过Uu和PC-5接口分别与VEC计算单元和边缘计算车辆交换数据,进而任务车辆通过Uu接口和PC-5接口将任务卸载到VEC服务和边缘计算车辆进行任务计算. 由于任务计算完成后,其计算结果数据量较小,因此不考虑任务处理结果的回传时延. 系统时间被分成大小相等的时隙,每个时隙的持续时间为 τ ,其索引为*t*.

2.1 任务达到模型

任务车辆的任务队列采用先来先服务,任务随机到达任务车辆并存储在队列中. 在第*t*个时隙, $A(t)$ 表示到达任务车辆的任务数,其服从泊松分布,并且在不在




图1 C-V2X车联网系统任务迁移模型

同时隙上满足独立同分布. 在 t 时刻, 到达任务车辆的任务数量的分布表示为

$$p(A(t)=a) \leq \begin{cases} \frac{(\lambda_T \tau)^a \exp(-\lambda_T \tau)}{a!}, & \text{if } a \geq 0 \\ 0, & \text{others} \end{cases} \quad (1)$$

其中, λ_T 表示任务车辆的平均任务到达率. 在 t 时隙, 定义 $A_{C,i}(t)$ 为从任务车辆卸载到第 i 个边缘计算车辆的任务数, $A_S(t)$ 为从任务车辆卸载到 VEC 计算单元的任务数.

2.2 通信模型

C-V2X 系统有两种通信链路可以用于卸载, 分别为 Uu 和 PC-5 接口:

(1) Uu 接口, 车辆与 RSU 之间的通信接口, 支持远距离可靠通信.

(2) PC-5 接口, 车辆间的通信接口. 无论是否有蜂窝网络覆盖, PC-5 接口都可以实现车车之间的传输通信.

2.2.1 Uu 接口的通信链路建模

Uu 接口是任务车辆和 RSU 之间的通信接口, 任务车辆与 RSU 之间的信道接入采用正交频分复用技术. 假设任务车辆可以估计与 RSU 之间的理想信道状态信息. 在 t 时隙内的任务车辆和 RSU 之间的任务传输率可以表示为

$$r_s^{Uu}(t) = B \log_2 \left(1 + \frac{P_s^{Uu}(t) d^{-\frac{\alpha}{2}} h^{Uu}}{\sigma^2} \right) \quad (2)$$

其中, B 表示可用带宽; σ^2 表示噪声功率; $P_s^{Uu}(t)$ 表示任务车辆在 Uu 接口处的发射功率; d 表示任务车辆到 RSU 的距离; h^{Uu} 是瑞利衰落信道因子; α 是路径损耗因子.

另外, 根据队列传输的数量, 在 t 时隙中从任务车辆到 VEC 计算单元的数据传输率可以表示为

$$r_s^{Uu}(t) = \frac{A_S(t)L}{\tau} \quad (3)$$

其中, L 表示任务车辆的任务的数据量. 由式(2)和式(3)可得, 任务车辆在 t 时隙的发射功率为

$$P_s^{Uu}(t) = \frac{\left(2^{\frac{A_S(t)L}{B\tau}} - 1 \right) \sigma^2}{g^{Uu}(t)} \quad (4)$$

2.2.2 PC-5 接口的通信建模

在 3GPP Release16 中首次定义了 5G NR PC-5 接口. 该接口是任务车辆和其他边缘计算车辆之间的通信接口. 其任务包发送频率用 $\lambda_C(t)$ 表示, 表示任务车辆每秒发送的数据包的数目. 任务车辆处的本地发射机的实际发射频率小于理想香农信道容量, 其被表示为

$$C_{v2v,i}^{\max}(t) = W_i \log_2 \left(1 + \frac{P_{C,i}^{PC-5}(t) g_i^{PC-5}(t)}{\sigma^2} \right) \quad (5)$$

其中, $P_{C,i}^{PC-5}(t)$, $g_i^{PC-5}(t)$ 和 W_i 分别表示任务车辆向第 i 个边缘计算车辆卸载任务的发射功率、信道增益和带宽.

在 3GPP Release16 中半持续性调度算法在一段时间内持续地占用资源块, 即在任务车辆的感知范围内, 其他车辆不会改变它们所占用的资源块. 在 C-V2X 中, 任务车辆和边缘计算车辆之间的传输链路质量会影响车车之间的 V2V 传输速率. 接下来, 研究 C-V2X 特性对 V2V 传输速率的影响.

首先, 半双工错误是 C-V2X 传输机制中的一个重要影响因素^[24]. 由于 C-V2X 的半双工传输机制, 车辆在一个子帧内发送该车的数据包时无法接收到数据包, 因此, 定义一秒内子帧数为 N_{frame} , 半双工错误概率可以表示为

$$\delta_{\text{HD}}(t) = \frac{\lambda_C(t)}{N_{\text{frame}}} \quad (6)$$

任务车辆的 PC-5 接口的成功感知概率可以表示为

$$P_{\text{SEN}}(t) = e^{-\lambda_C(t) \frac{K\beta \cdot 2d_{\text{sen}}}{N_{\text{sub-f}} N_{\text{sub-c}}}} \quad (7)$$

其中, β 为交通密度, 单位为车辆数每米; k 是多车道的转换系数, 表征单车道到多车道的映射系数; d_{sen} 是任务车辆的感知距离, $N_{\text{sub-f}}$ 和 $N_{\text{sub-c}}$ 分别表示 C-V2X 系统选择窗口中子帧和子信道的数量.

当接收边缘计算车辆的接收信号功率高于感知功率阈值 P^{th} 时, 边缘计算车辆处的接收机可以解码数据. 因此, 边缘计算车辆的数据包检测率^[23]为

$$\text{PSR}_i(t) = \frac{1}{2} \left[1 + \text{erf} \left(\frac{\sum_{i=1}^M P_{C,i}^{PC-5}(t) - \text{PL}_d(t) - P^{\text{th}}}{\sigma \sqrt{2}} \right) \right] \quad (8)$$

其中, $\text{PL}_d(t)$ 是任务车辆和与距离 d 处的边缘计算车辆之间的路径损耗. 因此, 基于以上分析, PC-5 链路的成

功传输概率为

$$P_{\text{STP},i}(t) = (1 - \delta_{\text{HD}}(t)) \cdot P_{\text{SEN}}(t) \cdot \text{PSR}_i(t) \quad (9)$$

考虑到成功传输概率的影响,任务车辆和第*i*个边缘计算车辆之间的归一化传输速率为

$$r_{C,i}^{\text{PC-5}}(t) = P_{\text{STP},i}(t) \cdot L\lambda_C(t) \quad (10)$$

PC-5接口的任务包发送频率受到理想信道容量的限制,因此存在以下约束:

$$L \cdot r_{C,i}^{\text{PC-5}}(t) \leq C_{\text{v2v},i}^{\text{max}}(t) \quad (11)$$

在时隙*t*中从任务车辆到VEC计算单元的数据传输速率可以表示为

$$r_{C,i}^{\text{PC-5}}(t) = \frac{A_{C,i}(t)L}{\tau} \quad (12)$$

根据式(10)、式(11)和式(12),PC-5接口的等效发射功率可以表示为

$$\Gamma_{C,i}(S(t), A(t)) = \left(\frac{A_{C,i}(t)L}{2^{W_i\tau} - 1} \right) \sigma^2 \quad (13)$$

其中, $A_{C,i}(t) = P_{\text{STP},i}(t)\lambda_C(t)\tau$.

2.3 计算模型

任务车辆任务的计算量用*C*表示,单位为CPU周期/任务,即计算一个任务的CPU周期数.定义第*i*个边缘计算车辆和VEC计算单元的计算频率分别为 $f_{C,i}(t)$ 和 $f_S(t)$,单位为CPU周期数每秒.时隙*t*中第*i*个边缘计算车辆的计算频率可表示为

$$f_{C,i}(t) = \frac{A_{C,i}(t)C}{\tau} \quad (14)$$

第*i*个边缘计算车辆计算一个CPU周期的能量损耗为 $\mu f_{C,i}^2$,其中 μ 是对应CPU的有效电容系数.第*i*个边缘计算车辆的能量损耗^[25]为

$$E_{C,i}(t) = A_{C,i}(t)C\mu(f_{C,i}(t))^2 = \frac{\mu(A_{C,i}(t)C)^3}{\tau^2} \quad (15)$$

由于VEC计算单元连接公共电网,这里本文不考虑VEC计算单元的能量损耗.

2.4 队列模型

C-V2X边缘计算系统模型的队列模型如图2所示.其中任务车辆、边缘计算车辆和VEC计算单元的最大队列长度定义为 Q_T^{max} , $Q_{C,i}^{\text{max}}$ 和 Q_S^{max} ,队列状态信息定义为 $Q_T(t)$, $Q_{C,i}(t)$ 和 $Q_S(t)$,其表示当前时隙内的队列长度,即队列内的任务数目.

任务车辆的队列状态信息随时间演变可以表示为

$$Q_T(t+1) = \min \left\{ \left[Q_T(t) - A_{C,i}(t) - A_S(t) \right]^+ + \lambda_C(t)\tau, Q_T^{\text{max}} \right\} \quad (16)$$

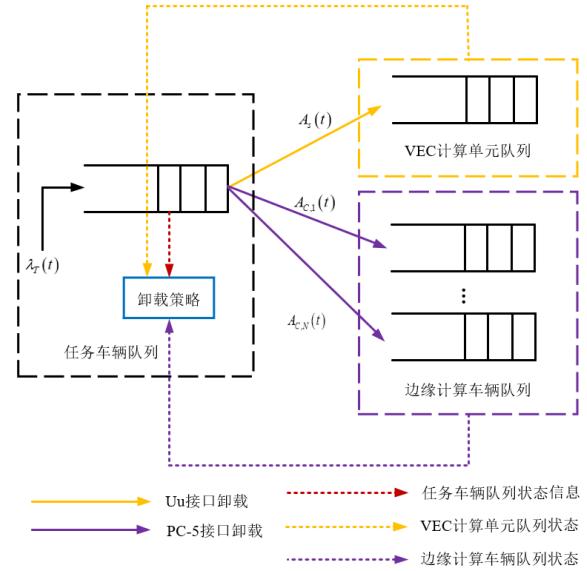


图2 C-V2X车联网系统队列模型

其中,如果*x*为正数,则 $[x]^+$ 返回*x*,否则返回零.

第*i*个边缘计算车辆的队列状态信息随时间演变可以表示为

$$Q_{C,i}(t+1) = \min \left\{ \left[\min \{ Q_{C,i}(t) + A_{C,i}(t), Q_{C,i}^{\text{max}} \} - v_{C,i}(t)\tau \right]^+ + \lambda_i\tau, Q_{C,i}^{\text{max}} \right\} \quad (17)$$

其中, $v_{C,i}(t)$ 和 λ_i 分别表示第*i*个的边缘计算车辆在单位时隙内的平均服务速率和平均任务到达率.VEC计算单元的队列状态信息随时间演变如下:

$$Q_S(t+1) = \min \left\{ \left[\min \{ Q_S(t) + A_S(t), Q_S^{\text{max}} \} - v_S(t)\tau \right]^+ + \lambda_S\tau, Q_S^{\text{max}} \right\} \quad (18)$$

其中, $v_S(t)$ 和 λ_S 分别表示VEC计算单元在单位时隙内的平均服务速率和平均任务到达率.

3 PC-5/Uu接口联合卸载问题

C-V2X边缘计算系统的计算卸载过程可以建模为无限时域的马尔可夫决策过程,将VEC系统的状态空间表示为 \mathcal{S} ,状态空间可以表示为

$$S(t) = \left\{ Q_S(t), \{ Q_{C,i}(t) \}_{i=1}^M \right\} \in \mathcal{S} \quad (19)$$

VEC系统的动作空间被表示为 \mathcal{A} ,动作空间可以表示为

$$A(t) = \left\{ \{ A_S(t), A_{C,i}(t) \}_{i=1}^M \right\} \in \mathcal{A} \quad (20)$$

其中,动作 \mathcal{A} 应满足 $A_S(t) \in \{0, 1, \dots, \min \{ Q_T^{\text{max}}, Q_S^{\text{max}} \} \}$ 和 $A_{C,i}(t) \in \{0, 1, \dots, \min \{ Q_T^{\text{max}}, Q_{C,i}^{\text{max}} \} \}$,即任务车辆卸载到VEC计算单元的任务数量不能超过任务车辆和VEC

计算单元的最大队列长度,同理,任务车辆卸载到边缘计算车辆的任务数量不能超过任务车辆和边缘计算车辆的最大队列长度.此外,任务车辆卸载到边缘计算车辆和 VEC 计算单元的任务数不能超过任务车辆队列中的任务数,因此存在 $A_S(t) + \sum_{i=1}^M A_{C,i}(t) \leq Q_T^{\max}$.

任务车辆的有效任务到达率^[26]为

$$\lambda_T^e = \begin{cases} \lambda_T \left(1 - \frac{(1-\rho_T)\rho_T^{Q_T^{\max}}}{1-\rho_T^{Q_T^{\max}+1}} \right), & \rho_T \neq 1 \\ \lambda_T \frac{Q_T^{\max}}{Q_T^{\max}+1}, & \rho_T = 1 \end{cases} \quad (21)$$

其中, $\rho_T = \lambda_T/\mu_T$ ($0 < \rho_T < \infty$) 是任务车辆队列的流量强度.此外,第 i 个边缘计算车辆的有效任务到达率为

$$\lambda_i^e = \begin{cases} \left(\frac{A_{C,i}(t)\lambda_i}{A_S(t) + \sum_{i=1}^M A_{C,i}(t)} + \lambda_i \right) \left(1 - \frac{(1-\rho_i)\rho_i^{Q_{C,i}^{\max}}}{1-\rho_i^{Q_{C,i}^{\max}+1}} \right), & \rho_i \neq 1 \\ \left(\frac{A_{C,i}(t)\lambda_i}{A_S(t) + \sum_{i=1}^M A_{C,i}(t)} + \lambda_i \right) \frac{Q_{C,i}^{\max}}{Q_{C,i}^{\max}+1}, & \rho_i = 1 \end{cases} \quad (22)$$

其中, $\rho_i = \lambda_i/\mu_i$ ($0 < \rho_i < \infty$) 是第 i 个边缘计算车辆队列的流量强度. VEC 计算单元的有效任务到达率为

$$\lambda_S^e = \begin{cases} \left(\frac{A_S(t)\lambda_s}{A_S(t) + \sum_{i=1}^M A_{C,i}(t)} + \lambda_s \right) \left(1 - \frac{(1-\rho_s)\rho_s^{Q_S^{\max}}}{1-\rho_s^{Q_S^{\max}+1}} \right), & \rho_s \neq 1 \\ \left(\frac{A_S(t)\lambda_s}{A_S(t) + \sum_{i=1}^M A_{C,i}(t)} + \lambda_s \right) \frac{Q_S^{\max}}{Q_S^{\max}+1}, & \rho_s = 1 \end{cases} \quad (23)$$

其中, $\rho_s = \lambda_s/\mu_s$ ($0 < \rho_s < \infty$) 是 VEC 计算单元队列的流量强度.综上,队列时延^[27]为

$$D(t) = \frac{Q_T(t)}{\lambda_T^e} + \max \left\{ \frac{Q_S(t)}{\lambda_S^e}, \frac{Q_{C,i}(t)}{\lambda_{C,i}^e} \right\}, i \in M \quad (24)$$

由式(2)和式(5)可知,任务车辆的发射功率表示为

$$P(S(t), A(t)) = P_S^{\text{Un}}(t) + \sum_{i=1}^M P_{C,i}^{\text{PC-5}}(t) \quad (25)$$

由式(15)可知,第 i 个边缘计算车辆的能量损耗可以表示为

$$E_i(S(t), A(t)) = E_{C,i}(t) \quad (26)$$

本文的目标是在任务车辆的平均发射功率、PC-5 接口的等效发射功率和边缘计算车辆的平均能量损耗的约束下最小化系统时延,因此系统时延最小化问题描述为

$$\min_{A(t)} D = \lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T \mathbb{E}_\pi [D(S(t), A(t))] \quad (27)$$

s. t.

$$P(\pi) = \lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T \mathbb{E}_\pi [P(S(t), A(t))] \leq P^{\max} \quad (27a)$$

$$\Gamma_{C,i}(S(t), A(t)) \leq P_{C,i}(A_{C,i}(t)), \forall i \in M \quad (27b)$$

$$E_i(\pi) = \lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T \mathbb{E}_\pi [E_i(S(t), A(t))] \leq E_i^{\max} \quad (27c)$$

约束式(27a)表示任务车辆的发射功率限制,约束式(27b)对应于由理想信道容量约束的 PC-5 接口的等效发射功率,约束式(27c)指示第 i 个边缘计算车辆的计算能量消耗.

4 基于 Q 学习的卸载策略

在本节中,由于约束的耦合使 CMDP 问题式(27)难以求解,首先通过拉格朗日方法将 CMDP 问题转化为一个无约束的 MDP 问题.然后,由于 Q 学习不需要系统先验知识且收敛性好,引入一种基于 Q 学习的卸载学习算法,系统通过每个卸载决策与环境交互进行学习,获得最优的卸载策略.

4.1 问题转换

通过拉格朗日方法,可以将 CMDP 问题转化为一个等价的极小极大的无约束 MDP 问题^[28].定义拉格朗日乘子向量为 $\bar{\theta} \triangleq (\theta_1, \theta_2, \theta_3)^T$,其表示任务车辆的平均发射功率、PC-5 接口的等效发射功率和边缘计算车辆平均能量损耗对应的拉格朗日乘子.因此,定义奖励值为

$$C(\bar{\omega}, s, a) = -D(s, a) + \theta_1 (P(s, a) - P_{\max}) + \theta_2 (\Gamma_{C,i}(s, a) - P_{C,i}(A_{C,i}(t))) + \theta_3 (E_i(s, a) - \bar{E}_{i,\max}) \quad (28)$$

奖励值与时延为负相关的关系,并综合考虑了 C-V2X 边缘计算系统的性能约束,奖励值越大,系统的时延性能越好,刻画了系统的时延性能.定义 $d^\pi(s)$ 为在策略 π 下状态 s 的稳态概率,则平均奖励值可以表示为

$$G(\pi, \bar{\omega}) = \lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T \mathbb{E}_\pi [C(\bar{\omega}, s, a)] = \sum_{s \in \mathcal{S}, a \in \mathcal{A}} d^\pi(s) \pi(s, a) C(\bar{\omega}, s, a) \quad (29)$$

然后利用拉格朗日松弛方法将 CMDP 问题转化为极小极大的无约束 MDP 问题,先最大化平均奖励值 $G(\pi, \bar{\omega})$,然后最小化其对偶问题,即

$$\arg \min_{\bar{\omega} \geq 0} \left(\arg \max_{\pi} G(\pi, \bar{\omega}) \right) \quad (30)$$

动作-价值函数的贝尔曼最优方程可以表示为

$$Q^{*, \bar{\omega}}(s, a) = C(\bar{\omega}, s, a) - G^{*, \bar{\omega}} + \sum_{s' \in \mathcal{S}} P(s' | s, a) \min_{a' \in \mathcal{A}(s')} Q^{*, \bar{\omega}}(s', a') \quad (31)$$

由于卸载过程中缺少先验知识 $P(s' | s, a)$, 传统的动态规划无法求解该方程. 在这种情况下, 引入一种基于Q学习的VEC系统卸载策略学习算法.

4.2 基于Q学习的C-V2X卸载算法

Q学习是一种无模型的强化学习方法, 学习如何在给定MDP找到最优的动作选择策略. Q学习算法的核心是根据旧的Q值和新的Q值估计进行权重平均的一个值迭代更新, 迭代更新的Q函数最终给出了主体在给定状态下采取给定行动的预期效用, 当这种行动价值函数被学习时, 主体可通过简单地选择在每个状态中具有最高价值的行为来构建最优策略. 基于迭代值更新的Q学习算法^[29, 30], 系统通过每个卸载决策与环境交互进行学习, 获得最优的C-V2X系统下的卸载策略, 具体算法如算法1所示.

算法的相关说明如下: 输入系统的初始的状态空间和动作空间的Q值, 以及拉格朗日乘子 $\theta_k(t)$ 和相关迭代变量 $Z_k(t)$ 的初始值, 在时隙 t 中的当前状态 s , 执行根据 ε -贪婪算法选择的动作 a 之后, 基于对下一个状态 s' 的观察和奖励 $C(\bar{\omega}, s, a)$ 更新动作-价值函数 $Q_{t+1}(s, a)$. 然后, 更新拉格朗日乘子 $\theta_k(t)$ 与相关迭代变量 $Z_k(t)$, 经过周期循环后, 输出最优的卸载策略, 即动作空间 \mathcal{A} .

算法1中的参数说明如下. $\alpha(t) \in [0, 1)$ 是学习率, a' 是下一个状态 s' 的可能发生的动作. 对于拉格朗日乘子的更新, 定义 $g_1(s, a) = P(s, a)$, $g_m(s, a) = \Gamma_{C, i}(s, a)$ ($m \in \{2, 3, \dots, N+1\}$) 和 $g_j(s, a) = E_{C, i}(s, a)$ ($j \in \{N+2, N+3, \dots, 2N+1\}$), 分别表示任务车辆的发射功率、PC-5接口的等效发射功率、第 i 个边缘计算车辆的计算能量消耗. 另外定义 $\Psi_1 = P_{\max}$, $\Psi_2 = P_{C, i}$, $\Psi_3 = E_i^{\max}$ 表示相应的约束. 为了方便描述, 定义 $k \in \{1, 2, \dots, N+1, N+2, \dots, 2N+1\}$ 以统一描述更新过程, 更新过程采用双时间尺度随机逼近算法^[31].

5 仿真结果与分析

本文进行了一系列仿真, 与3种对比方案进行比较, 验证所提的基于Q学习的C-V2X系统卸载策略(CV2XQL)的算法性能. 在本文的仿真系统中, 考虑一个VEC系统, 配备有一个连接VEC计算单元的RSU和

算法1 基于Q学习的C-V2X卸载算法

输入: 输入所有状态空间与动作空间的 $Q(s, a)$, 和 $\theta_k(t), Z_k(t)$,

$k = 1, 2, 3$

输出: 最优卸载策略, 即动作空间 \mathcal{A}

FOR 周期 = 1, 2, 3, ...

 随机选择一个初始状态 s_0 , 赋值给状态空间 s

 FOR $t = 0, 1, 2, \dots$

 随机选择概率 p

 IF $p < \varepsilon$ THEN

$a^* = \arg \min_{a \in \mathcal{A}(s)} Q(s, a)$

 ELSE

 随机选择其他动作

 END IF

 生成 t 时隙内的任务车辆的任务到达数量 $A(t)$

 执行动作 a , 观测下一个状态 s' 和奖励 $C(\bar{\omega}, s, a)$

 更新Q值,

$$Q_{t+1}(s, a) = (1 - \alpha(t))Q_t(s, a) + \alpha(t) \left[C(\bar{\omega}, s, a) + \min_{a' \in \mathcal{A}(s')} Q_t(s', a') - \min_{a_0 \in \mathcal{A}(s_0)} Q_t(s_0, a_0) \right]$$

 FOR $k = 1, 2, 3$

 更新拉格朗日乘子

$$Z_k(t+1) = Z_k(t) + \beta(t)(g_k(s, a) - Z_k(t))$$

$$\theta_k(t+1) = [\theta_k(t) + \gamma(t)(Z_k(s, a) - \Psi_k)]^+$$

 END FOR

 更新状态为 s'

 END FOR

END FOR

多辆车, 包括一辆任务车辆和 N 辆边缘计算车辆. 车辆道路为4条道路, 车辆密度 $\beta = 0.8 \times 84^{-1[32]}$, 任务型车辆的感知距离为1 km, 1 s内的子帧数为 $N_{\text{frame}} = 1000$. 任务车辆的任务数据量为 $L = 1 \times 10^4$ bit, 每个任务的计算量服从均匀分布, 即 $C \in (500, 1000)$ cycle/task. 边缘计算车辆和VEC计算单元的计算频率^[33, 34]分别设置为 $f_{C, i}(t) = 2 \times 10^9$ cycle/s 和 $f_s(t) = 5 \times 10^9$ cycle/s.

对于Uu接口, 任务车辆与RSU之间的带宽为20个RB, 信道模型为瑞利衰落模型, 路径损耗指数设为3, 背景噪声功率设为-70 dBm; 对于PC-5接口, 路径损耗模型^[22]为

$$PL = 38.77 + 16.7 \log_{10}(d) + 18.2 \log_{10}(f_c) \quad (32)$$

其中, f_c 表示载波频率(GHz), d 表示3D空间中发射机和接收机之间的欧几里得距离(m). 任务车辆的最大发射功率分别设置为 $P^{\max} = 23$ dBm, 第 i 辆边缘计算车辆的最大能量损耗为 $E_i^{\max} = 2$ J. 对于C-V2X模型, SW中子帧的数量为 $N_{\text{sub-f}} = 100$, 子信道的数目为 $N_{\text{sub-c}} = 4$, 每个子信道有12个资源块(Resource Block, RB), RB是

可以分配给车辆的最小频率资源单位。

将提出的算法与以下基线情况进行比较,其中各基线情况下的总体计算能力相同,系统共 11×10^9 cycle/s 算力提供给任务车辆:

(1)边缘计算车辆计算方案(CV),任务车辆将所有任务卸载到边缘计算车辆进行计算;

(2)VEC 计算单元计算方案(VEC),任务车辆将所有任务卸载到 VEC 计算单元进行计算;

(3)正交信道分配的计算卸载方案^[9](NRO),任务车辆与边缘车辆通过中央基站进行信道带宽分配,任务车辆根据贪婪算法进行决策,将任务卸载到 VEC 计算单元或者边缘计算车辆进行计算。

图3描述了本文提出的基于Q学习的C-V2X系统卸载策略的收敛性。可以看出系统时延先在前200次迭代中急剧下降,在200次到1000次迭代缓慢下降,进而在1000次迭代左右达到收敛稳定。刚开始的时延波动是因为拉格朗日因子的初始值与最优差距较大,算法中动作的选择使得时延急速下降,随着迭代次数的增多,系统逐渐逼近最优时延性能。

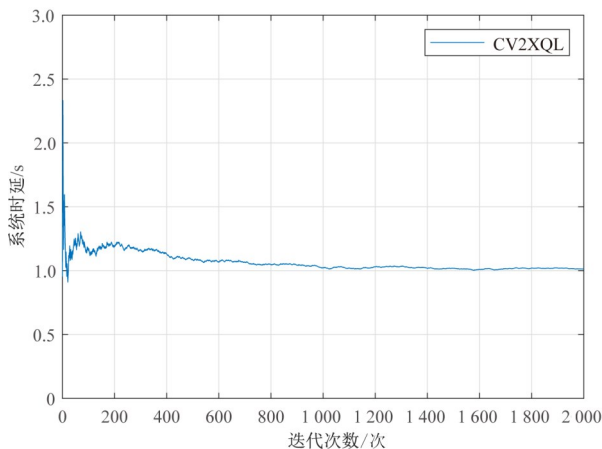


图3 算法收敛性评估

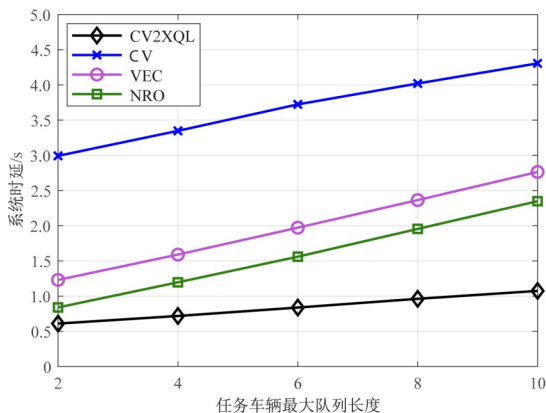


图4 不同任务车辆最大队列长度下的系统时延变化情况

图4和图5描述了任务车辆的最大队列长度对系统时延和平均奖励值的影响。考虑在任务车辆的通信范围内有三辆边缘计算车辆,即 $N=3$ 。在图4中,可以看出当任务车辆的最大队列长度增加时,四种算法的系统时延相应的增加,这是因为本地任务队列挤压增大,会增加排队时延,进而增加总系统时延。此外,实验结果表明本文提出的算法的时延明显低于CV算法、VEC算法和NRO算法,体现出所提算法的时延性能优势。在图5中,可以看出当任务车辆的最大队列长度增加时,三种算法的平均奖励值相应的减少,实验结果表明本文算法的平均奖励值明显高于CV和VEC算法,体现了算法优越性。

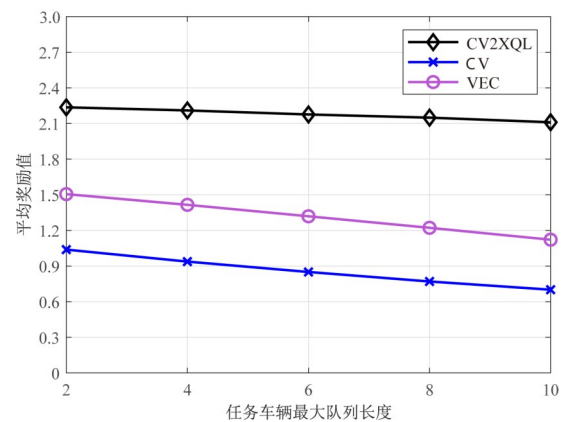


图5 不同任务车辆最大队列长度下的平均奖励值变化情况

图6和图7描述了车辆密度对系统时延和平均奖励值的影响。在图6中,可以看出当周边车辆密度增加时,VEC算法系统时延保持不变,本文算法与CV算法的系统时延相应增加,原因是车辆密度的增加会降低车辆之间的成功传输概率,进而导致系统时延增加。此外,NRO算法的系统时延也随着车辆密度增加而增加,且在车辆密度高(0.2)的时候,NRO算法与VEC算法的时延几乎相同,这是因为车辆增多会使车辆分配的带宽变少,进而影响传输速率。本文算法的系统时延性能明显优于CV算法、VEC算法和NRO算法,此外,车辆密度对CV算法和NRO算法的影响明显大于本文算法,验证了本文算法在车辆密度高的情况下的鲁棒性。在图7中,当车辆密度增加时,本文算法与CV算法的平均奖励值相应减少,而VEC算法则不受影响,因为其与车辆密度无关。此外,本文算法的平均奖励值明显高于CV算法和VEC算法方案,验证了本文算法的算法性能。

6 总结

针对C-V2X的车联网边缘计算系统的时延性能,本文研究了基于Q学习的卸载策略,以降低任务的处

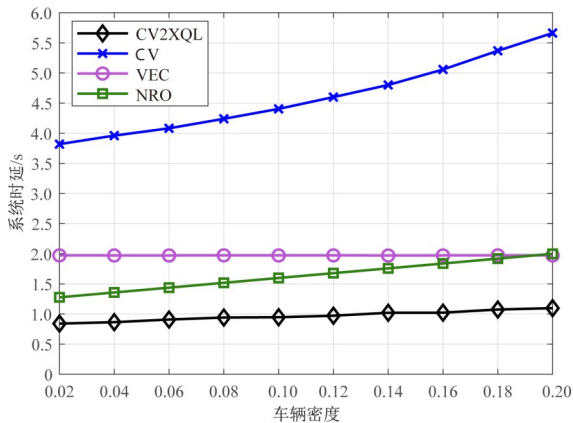


图6 不同车辆密度下的系统时延变化情况




图7 不同车辆密度下的平均奖励值变化情况

理时延. 对基于C-V2X的车车通信的成功传输概率进行建模,进而描述了车车之间的通信速率. 构建了系统时延最小化问题,在发射功率和能量损耗的约束下优化任务卸载策略. 本文提出的基于Q学习的C-V2X系统卸载策略在系统时延和平均奖励值上都有优越性能表现,仿真结果表明本文算法可以显著提高至少27.3%的系统时延性能.

在未来工作中,将对蜂窝车联网的多任务车辆场景下的任务卸载策略进行研究,针对不可分割任务与可分割任务综合考虑在内的混合型业务,对任务优先级与资源竞争分配进行卸载与资源分配方案设计. 此外,将进一步采用Q学习与深度学习网络相结合的DQN算法进行蜂窝车联网的动态任务卸载进行联合设计优化,进一步避免维度灾难问题,提高任务卸载效率.

参考文献

[1] ZHANG N, ZHANG S, YANG P, et al. Software defined space-air-ground integrated vehicular networks: Challenges and solutions[J]. IEEE Communications Magazine, 2017, 55(7): 101-109.

[2] 崔玉亚, 张德干, 张婷, 等. 一种面向移动边缘计算的多用户细粒度任务卸载调度方法[J]. 电子学报, 2021, 49(11): 2202-2207.
CUI Y Y, ZHANG D G, ZHANG T, et al. A multi-user fine-grained task offloading scheduling approach of mobile edge computing[J]. Acta Electronica Sinica, 2021, 49(11): 2202-2207. (in Chinese)

[3] 乐光学, 戴亚盛, 杨晓慧, 等. 海上边缘计算云边智能协同服务建模[J]. 电子学报, 2021, 49(12): 2407-2418.
YUE G X, DAI Y S, YANG X H, et al. Model of cloud-edge cooperative service for maritime edge computing[J]. Acta Electronica Sinica, 2021, 49(12): 2407-2418. (in Chinese)

[4] ZHANG Y X, DUAN S J, ZHANG D Y, et al. Transparent computing: Development and current status[J]. Chinese Journal of Electronics, 2020, 29(5): 793-811.

[5] HUANG C, LU R X, CHOO K K R. Vehicular fog computing: Architecture, use case, and security and forensic challenges[J]. IEEE Communications Magazine, 2017, 55(11): 105-111.

[6] 廖勇, 田肖懿, 蔡志镛, 等. 面向C-V2I的基于边缘计算的智能信道估计[J]. 电子学报, 2021, 49(5): 833-842.
LIAO Y, TIAN X Y, CAI Z R, et al. Intelligent channel estimation based on edge computing for C-V2I[J]. Acta Electronica Sinica, 2021, 49(5): 833-842. (in Chinese)

[7] FENG W Y, YANG S Z, GAO Y, et al. Reverse offloading for latency minimization in vehicular edge computing [C]//ICC 2021 - IEEE International Conference on Communications. Piscataway: IEEE, 2021: 1-6.

[8] FENG W Y, LIN S Y, ZHANG N, et al. Joint C-V2X based offloading and resource allocation in multi-tier vehicular edge computing system[J]. IEEE Journal on Selected Areas in Communications, 2023, 41(2): 432-445.

[9] AHSAN KAZMI S M, OTOUM S, HUSSAIN R, et al. A novel deep reinforcement learning-based approach for task-offloading in vehicular networks[C]//2021 IEEE Global Communications Conference (GLOBECOM). Piscataway: IEEE, 2021: 1-6.

[10] FENG W Y, ZHANG N, LI S C, et al. Latency minimization of reverse offloading in vehicular edge computing[J]. IEEE Transactions on Vehicular Technology, 2022, 71(5): 5343-5357.

[11] 陈思光, 陈佳民, 赵传信. 基于深度强化学习的云边协同计算迁移研究[J]. 电子学报, 2021, 49(1): 157-166.
CHEN S G, CHEN J M, ZHAO C X. Deep reinforcement

- learning based cloud-edge collaborative computation offloading mechanism[J]. *Acta Electronica Sinica*, 2021, 49(1): 157-166. (in Chinese)
- [12] SHINDE S, BOZORGCHENANI A, TARCHI D, et al. On the design of federated learning in latency and energy constrained computation offloading operations in vehicular edge computing systems[J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(2): 2041-2057.
- [13] HE Y, ZHAO N, YIN H X. Integrated networking, caching, and computing for connected vehicles: A deep reinforcement learning approach[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(1): 44-55.
- [14] XIE R C, TANG Q Q, WANG Q N, et al. Collaborative vehicular edge computing networks: Architecture design and research challenges[J]. *IEEE Access*, 2019, 7: 178942-178952.
- [15] LIU Y, YU H M, XIE S L, et al. Deep reinforcement learning for offloading and resource allocation in vehicle edge computing and networks[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(11): 11158-11168.
- [16] XIE R C, TANG Q Q, LIANG C H, et al. Dynamic computation offloading in IoT fog systems with imperfect channel-state information: A POMDP approach[J]. *IEEE Internet of Things Journal*, 2021, 8(1): 345-356.
- [17] ZHANG Y M, LAN X L, REN J, et al. Efficient computing resource sharing for mobile edge-cloud computing networks[J]. *IEEE/ACM Transactions on Networking*, 28(3): 1227-1240.
- [18] LAN X L, ZHANG Y M, CAI L, et al. Energy efficient buffer-aided transmission scheme in wireless powered cooperative NOMA relay network[J]. *IEEE Transactions on Communications*, 2019, 68(3): 1432-1447.
- [19] LIU Y, YANG C, JIANG L, et al. Intelligent edge computing for IoT-based energy management in smart cities [J]. *IEEE Network*, 2019, 33(2): 111-117.
- [20] ZHAN W H, LUO C B, WANG J, et al. Deep-reinforcement-learning-based offloading scheduling for vehicular edge computing[J]. *IEEE Internet of Things Journal*, 2020, 7(6): 5449-5465.
- [21] LIU Y J, WANG S G, ZHAO Q L, et al. Dependency-aware task scheduling in vehicular edge computing[J]. *IEEE Internet of Things Journal*, 2020, 7(6): 4961-4971.
- [22] 3GPP. Release 14: Technical Specifications Group Services and System Aspects: 3GPP TR21.94v0.8.0[S]. Sophia Antipolis Cedex: 3GPP TR, 2017.
- [23] GARCIA M H C, MOLINA-GALAN A, BOBAN M T, et al. A tutorial on 5G NR V2X communications[J]. *IEEE Communications Surveys & Tutorials*, 2021, 23(3): 1972-2026.
- [24] GONZALEZ-MARTIN M, SEPULCRE M, MOLINA-MASEGOSA R, et al. Analytical models of the performance of C-V2X mode 4 vehicular communications[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(2): 1155-1166.
- [25] MAO Y Y, YOU C S, ZHANG J, et al. A survey on mobile edge computing: The communication perspective[J]. *IEEE Communications Surveys & Tutorials*, 2017, 19(4): 2322-2358.
- [26] SHORTLE J F, THOMPSON J M, GROSS D, et al. *Fundamentals of Queueing Theory*[M]. New York: Wiley, 2018: 399.
- [27] MENG X L, WANG W, WANG Y T, et al. Closed-form delay-optimal computation offloading in mobile edge computing systems[J]. *IEEE Transactions on Wireless Communications*, 2019, 18(10): 4653-4667.
- [28] ALTMAN E. *Constrained Markov Decision Processes* [M]. Boca Raton: Chapman & Hall/CRC, 1999.
- [29] ABOUNADI J, BERTSEKAS D, BORKAR V S. Learning algorithms for Markov decision processes with average cost[J]. *SIAM Journal on Control and Optimization*, 2001, 40(3): 681-698.
- [30] FENG J T, FENG W Y, LIN S Y. Reverse computing offloading for enhanced computing capacity in cooperative vehicle infrastructure system[C]//2021 IEEE International Intelligent Transportation Systems Conference (ITSC). New York: ACM, 2021: 1011-1016.
- [31] BORKAR V S. Stochastic approximation with two time scales[J]. *Systems & Control Letters*, 1997, 29(5): 291-294.
- [32] MARTIN-VEGA F J, SORET B, AGUAYO-TORRES M C, et al. Geolocation-based access for vehicular communications: Analysis and optimization via stochastic geometry[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(4): 3069-3084.
- [33] DAI Y Y, XU D, MAHARJAN S, et al. Joint load balancing and offloading in vehicular edge computing and networks[J]. *IEEE Internet of Things Journal*, 2019, 6(3): 4377-4387.
- [34] WANG Z, ZHONG Z D, ZHAO D M, et al. Vehicle-based cloudlet relaying for mobile computation offloading


[J]. IEEE Transactions on Vehicular Technology, 2018, 67(11): 11181-11191.

作者简介



冯伟杨 男,1996年11月出生,山东临沂人。现为北京交通大学电子信息工程学院博士研究生。主要研究方向为车联网与边缘计算。

E-mail: wyfeng@bjtu.edu.cn



林思雨 男,1984年12月出生,北京人。现为北京交通大学电子信息工程学院教授、博士生导师。主要研究方向为无线通信、车联网与轨道交通专用通信。中国电子学会会员编号:E190014444S。

E-mail: sylin@bjtu.edu.cn



冯婧涛 女,1997年12月出生,河北邢台人。2022年获得北京交通大学电子信息工程学院硕士学位。主要研究方向为车联网与边缘计算。

E-mail: 857382473@qq.com



李 贇 男,1982年3月出生,山西太原人。现为中国铁路信息科技集团有限公司信息调度中心副主任、高级工程师。主要研究方向为计算机网络技术。

E-mail: liyun@sinorail.com



孔繁鹏 男,1982年4月出生,北京人。现为中铁信(北京)网络技术研究院有限公司信息技术研究室主任。主要研究方向为信息网络技术、通信技术及网络运维技术。

E-mail: kongfanpeng@sinorail.com



艾 渤 男,1974年2月出生,陕西西安人。现为北京交通大学教授、博士生导师,电子信息工程学院院长。主要研究方向为宽带移动通信系统与专用移动通信。

E-mail: boai@bjtu.edu.cn