

# 基于深度强化学习的车联网任务卸载策略研究进展\*

杨纪龙<sup>1,2</sup> 李陶深<sup>1,2\*\*</sup>

1. 南宁学院信息工程学院, 南宁 530200  
2. 广西大学计算机与电子信息学院, 南宁, 530004

**摘要** 车联网任务卸载决策不仅是提升车联网系统效率、降低能耗、延长车辆续航的必要手段,也是推动智能交通、自动驾驶等应用领域发展的关键技术。本文从基于传统算法的车联网任务卸载策略、基于深度强化学习的车联网任务卸载策略等2个方面,阐述车联网的任务卸载策略的国内外技术研究现状,对当前研究存在的问题进行分析,给出未来研究工作的思路。

**关键字** 移动边缘计算, 服务资源, 任务卸载, 联合卸载策略

## Research Progress on Task Offloading Strategy for the Internet of Vehicles based on Deep Reinforcement Learning\*

Yang Jilong<sup>1,2</sup> Li Taoshen<sup>1,2\*\*</sup>

1. School of Information Engineering, Nanning University, Nanning 530200, China  
2. School of Computer, Electronics and Information, Guangxi University, Nanning 530004, China  
lts@unn.edu.cn

**Abstract**—The task offloading decision in the Internet of Vehicles is not only a necessary means to improve the efficiency of the system, reduce energy consumption, and extend vehicle range, but also a key technology to promote the development of applications such as intelligent transportation and autonomous driving. This paper summarizes and reviews the existing researches on the traditional algorithm based task offloading strategies and deep reinforcement learning based task offloading strategies, analyzes the existing problems in current research and provides ideas for future research work.

**Keywords**—Mobile edge computing(MEC), service resource, task offloading, joint offloading strategy

### 1 引言

计算机技术和传感器技术的发展使汽车逐渐发展成为更加智能的自动驾驶汽车<sup>[1]</sup>。随着人工智能技术的不断进步,无人驾驶汽车逐渐从愿景走向现实,成为学术界和工业界近年来的研究热点<sup>[2]</sup>。在自动驾驶服务中,配备了许多电子设备的车辆执行复杂的计算任务会导致能源需求与时延需求的增加,使得相应的车载服务和应用变成了数据饥渴、计算密集、延迟敏感的应用<sup>[3]</sup>。所以,降低自动驾驶汽车的功耗与时延已成为近年来的研究热点。

车联网 (Vehicle-to-everything, V2X) 技术通过无线通信实现车辆与其他设备、车辆、基础设施之间的互联互通,它作为一种新型通信技术受到了学术界和产业界的广泛关注。在 5G 系统下的自动驾驶需要使用 V2X 进行通信和监控,同时需要大量的数据计算和数

据通信。然而,对于计算资源有限的终端车辆来说,使用 V2X 技术执行计算密集型任务一直是一个挑战。随着 V2X 技术的快速发展,车载通信网络和智能交通系统正在朝着更加复杂、智能化的方向发展。在车联网环境中,车辆不仅需要进行复杂的计算任务,如自动驾驶、环境感知、交通流量预测等,还需要处理大量的数据传输任务。然而,随着车载设备计算需求的不断增加,单纯依赖车辆本地的计算资源和电力供给,已经难以满足车联网系统中高效、低延迟的实时需求。任务卸载 (Task offloading) 技术应运而生,它可以通过将车辆的计算任务卸载到远程的云计算平台,减轻车载设备的负担,提高计算效率和系统资源的利用率。

移动边缘计算 (Mobile edge computing, MEC) 被认为是实现下一代互联网各种愿景的关键技术<sup>[4]</sup>。在路边部署 MEC 环境可以实现移动车辆之间的双向通信。一辆车可以与其他接近的车辆进行通信,并通知他们任何预期的风险或交通堵塞,以及任何行人和骑自行车的人的存在<sup>[5]</sup>。目前,移动边缘计算已成为将任务卸

\*基金资助: 本文得到广西重点科技攻关项目 (桂科 AD20297125) 的资助。

\*\*通信作者: 李陶深, lts@unn.edu.cn

载到 MEC 服务器上以解决车辆计算能力不足问题的关键技术<sup>[6]</sup>。

在边缘计算中,主要有三种动作:一是计算卸载,决定一个任务是卸载到边缘还是云上处理<sup>[7]</sup>;二是资源分配,即为任务分配通信、存储资源和计算资源<sup>[8]</sup>;三是资源发放,从用户的角度决定用户-资源对的关联,或者从服务提供商的角度积极进行资源放置<sup>[9-10]</sup>。边缘计算作为一种重要的分布式计算架构,能够在离车辆较近的地方提供计算服务,有效降低了任务卸载的延迟。在车联网中,边缘计算节点(如路边单元、基站等)承担了计算和存储任务的卸载工作。相关研究认为处理大量数据的潜力需要满足两个要求:一是有效的计算卸载策略,以便处理复杂的任务;二是适当的存储策略,以便快速有效地存储和交付数据和计算结果<sup>[11]</sup>。高效的卸载策略一直是一个研究热点,尤其在高度动态的车辆环境中是相当具有挑战性的<sup>[12]</sup>,

可以说,车联网中的任务卸载决策是一个重要的研究方向,在车联网中如何高效地将任务卸载到云端或边缘计算平台,成为车联网研究中的一个核心问题。现在已经有许多相关方面的研究,但一个更安全、更高效、更适合当下环境的车联网任务卸载方案依旧是值得研究的。基于上述考虑,本文将对基于传统算法的车联网任务卸载策略、基于深度强化学习的车联网任务卸载策略的国内外技术研究现状进行研究,分析存在的问题,讨论拟要开展的研究工作。

## 2 国内外研究现状、水平及发展趋势

车联网任务卸载策略研究旨在通过高效的任务分配和资源管理优化车联网中的计算任务执行,减少延迟、降低能耗、提高系统效率。车联网任务卸载策略的研究主要集中在任务分配与调度、异构资源管理、网络负载均衡等方面。

### 2.1 基于传统算法的车联网任务卸载研究

传统的任务卸载方法主要依赖于数学建模和优化算法,其核心是根据车联网系统的特定参数,设计合适的任务卸载策略。常见的方法包括基于启发式算法的方法、基于博弈论的方法、基于模型优化的方法等。

在文献[13]中,作者引入无人机辅助卸载并针对多用户环境下的多层边缘云计算提出了一种延迟最优的任务卸载方法,利用整数线性规划技术将问题表述为一个优化模型,以最小化无人机的总服务时间。文献[14]研究了联合任务卸载、功率分配和资源分配的多目标优化问题,以最大化用户的卸载增益为目标并构造了一个多变量、多目标的三目标优化问题,提出了一种高效的多目标进化算法,用于求解最小化响应时间、最小化能耗和最小化成本的问题。文献[15]的作

者提出了一种基于激励的车辆雾边缘计算卸载和资源分配方案,以最大限度地提高系统的统一效用函数,同时在最后期限和激励约束下,实体满足延迟和激励。该文献引出了一个混合整数非线性规划问题,通过使用连续松弛和凸子问题之间的交替优化来解决。文献[16]提出了一种车辆-无人机协同感知架构,以感知大范围的交通环境;然后提出了一种综合考虑卸载决策和动态计算资源分配的计算卸载策略,采用逐次凸逼近(Successive convex approximation, SCA)算法将非凸表述问题转化为可处理的凸逼近问题。在文献[17],作者提出了一种计算资源和通信资源的联合调度算法,该算法利用蚁群算法(Ant colony optimization, ACO),综合考虑车辆和 MEC 服务器的计算能力、通信带宽以及成功卸载的概率,为每个计算任务寻找最优的卸载路径。文献[18]提出了一种基于蜂窝车辆到外界(Cellular vehicle-to-everything, C-V2X)的多层车辆边缘计算(Vehicular edge computing, VEC)卸载策略,针对双 UU/PC5 接口通信资源的耦合问题,对目标函数进行了转换,并将转换后的问题分解为两个子问题,即资源分配和卸载策略子问题,通过备选优化,提出了基于贪婪算法的 PC5-GO 算法,以获得最优的通信和计算资源分配,以及任务部分卸载的卸载策略。文献[19]研究了动态环境下移动云计算的多用户计算卸载问题,其中移动用户动态地变为活跃或不活跃,移动用户卸载计算的无线通道随机变化。针对移动用户在向移动云卸载计算任务时具自私自利性,将动态环境下移动用户的卸载决策过程表述为随机博弈,并证明了所建立的随机对策等价于至少有一个纳什均衡的加权势对策,量化了纳什均衡的效率,并进一步提出了一种多智能体随机学习算法,以保证收敛率达到纳什均衡。文献[20]的作者利用城市环境中车辆因红绿灯或感兴趣区域停车而聚集的时间段,充分挖掘聚集车辆的空闲资源,提出了一种仅依靠车对车通信的任务卸载方案,通过将任务执行问题转化为一个任务与多个协作车辆之间的最大最小(Min-Max)问题,采用最大最小(Min-Max)公平性策略优化任务执行时间,并采用粒子群优化(Particle swarm optimization, PSO)算法进行求解。

由上述的研究可见,近些年人们提出了许多基于传统方法的解决方案,用传统方法来解决车联网任务卸载策略依旧是一个热门的解决思路。但传统方案存在着它固有的问题,如模型假设限制高,等等。

### 2.2 基于深度强化学习的车联网任务卸载研究

考虑到任务卸载场景下由于通道快速变化和计算负荷的复杂性和高度动态的车辆网络,大多数利用一次性优化的经典方案可能无法获得稳定的长期优化性能<sup>[21]</sup>。相比之下,基于历史经验,深度强化学习(Deep

reinforcement learning, DRL)可以实时学习到最优决策策略。虽然DRL的试错训练是一个耗费时间和资源的过程,但一旦融合, DRL代理可以在毫秒内对车辆环境的变化做出反应,从而实现实时决策。此外,与传统的启发式算法相比,经验驱动的DRL不假设环境模型。特别是通过新经验的积累, DRL可以在卸载操作中改进策略,快速适应车载环境变化,可满足延迟敏感应用的需求。随着人工智能(AI)技术的发展,由于深度强化学习所具有的独特的优点,现在用深度强化学习来解决任务卸载决策问题的研究越来越多。在车联网领域,已经有多个研究采用了深度强化学习的方法。下面将介绍基于深度强化学习方法的车联网任务卸载研究现状。

文献[22]考虑了一种上行链路无人机辅助的V2X通信系统,通过应用信息年龄(Age of information, AoI)指标来表征UAV与车辆之间的信息新鲜度,并针对高维动作空间中的非凸AoI最小化问题,提出了一种基于经验存储的深度q网络(deep Q-network, dqn)方案来优化发射功率和卸载比率。文献[23]提出了一种符合机动模式和计算能力要求的多跳车辆任务卸载机制,它的V2V卸载程序使用基于5G的毫米波通信模式考虑许多跳数,为此,设计了一种基于近端策略优化(Proximal Policy Optimization, PPO)的多跳车载任务卸载算法,具有较低的复杂度,能够提供最优解,通过减少卸载延迟来提高系统性能。在文献[24]中,作者重点关注依赖于三条卸载路径的三层V2X网络,即车辆到基础设施(Vehicle to infrastructure, V2I),车辆到云(Vehicle to cloud, V2C)和基础设施到云(Infrastructure to cloud, I2C),提出了一种基于深度强化学习的卸载策略,其目标是减少任务的平均延迟。文献[25]针对实际的车辆运行环境,联合考虑了移动车载网络中的通信和计算资源来解决任务卸载问题,提出了一种基于深度强化学习的方法来解决所提出的问题,并通过数值评估来证明所提出方案的有效性。文献[26]的作者提出了一种深度强化学习辅助的无线接入网(Radio access network, RAN)切片和任务卸载联合优化方法,设计了一种多时间尺度、多维资源切片框架,为不同类型任务的卸载提供差异化服务质量(Quality-of-Service, QoS)保障。首先将任务完成数量最大化问题建模为一个带约束的长时累积优化问题,并将该优化问题分解为大时间尺度上的RAN切片子问题与小时间尺度上的任务调度子问题;然后利用一种最优化方法为切片分配频谱和计算资源,设计一种基于深度强化学习的任务调度算法来决定切片窗口内各个时隙的工作流调度,并根据网络态势变化动态地在不同基站之间分配任务,实现了全网资源的高效利用。文献[27]构建了大规模异构移动边缘计算中具有多服务节点和移动任务内部具有多依赖关系的卸载模型,结合移动边缘计算的实际应用场景,提出了利用改进的深度强化学习算法来

优化任务卸载策略,最后通过综合比较任务卸载策略的能耗、成本、负载均衡、延迟、网络使用量和平均执行时间等指标,分析了各卸载策略的优缺点。研究说明了基于长短期记忆(Long short-term memory, LSTM)网络和事后经验回放(Hindsight experience replay, HER)改进的HERDRQN算法在能耗、费用、负载均衡和延迟上都有很好的效果。在文献[28],作者考虑了分布式车辆到对辆(Vehicle to vehicle, V2V)任务卸载方式,将车辆作为协作节点来执行任务,提出了一种基于双深度Q网络(Double deep Q network, DDQN)的协同车辆辅助任务卸载策略,利用多车辆协作的并行计算,在不超过能量约束的情况下提供低延迟计算服务,在选择协同车辆后获得最优的任务分流率。研究表明,使用缓存存储流行任务的计算结果可以避免重复处理造成的开销。文献[29]研究了多个地区用户的计算卸载问题,以最小化所有区域的总延迟和能耗作为优化目标,使用深度强化学习的深度确定性策略梯度(Deep deterministic policy gradient, DDPG)框架来解决单个区域中的计算卸载问题,并提出了一种新的协作缓存算法(CCA)来提高系统的整体缓存命中率。为了求解任务卸载决策,文献[30]的作者构建一个基于软件定义网络的边云协作任务卸载架构,将动态环境中的任务卸载决策问题建模为马尔可夫决策过程,从而最大化由时延和成本构成的任务平均效用。为了求解任务卸载决策,提出了一种基于DDQN的任务卸载决策算法以及基于优先级的资源分配方案,并设计一种卸载比例计算方法,以保障卸载的任务量能够在通信时间内上传完成的同时最小化任务处理时延。

大多数采用DRL方法的研究考虑的是单智能体强化学习,最近几年也有研究考虑了多智能体下的新方法,即多智能体强化学习(Multi-agent reinforcement learning, MARL),为研究系统提供了另一种视角。与单个智能体相比, MARL利用多个在车联网中智能体之间的沟通来加速任务学习,并获得更好的性能。此外,并行化技术也可以加速智能体探索环境的效率。MARL决策过程可以表示为部分可观察马尔可夫决策过程(Partially observable markov decision process, POMDP),每个智能体智能地获得对环境的部分观察结果,所有智能体根据观察结果选择行动,形成联合行动。然后,利用联合动作与环境进行交互,从而获得整体的奖励。

在文献[31]中,作者建立了基于不同速度和任务类型的车速感知延迟约束模型,然后计算真实车辆边缘计算(Vehicular edge computing, VEC)服务器和本地终端执行任务的延迟和能源成本,提出了一种车辆速度感知任务卸载和资源分配策略,以降低执行任务的能耗,并采用多智能体深度确定性策略梯度(Multi agent deep deterministic policy gradient, MADDPG)方法

获得卸载和资源分配策略。文献[32]提出了一个全面的集成传感和通信(Integrated sensing and communication, ISAC)辅助的V2X框架,其中车辆用户设备(Vehicle user equipment, VUE)可以将其任务卸载到位于路边单元(Roadside unit, RSU)的边缘服务器上。通过对所有VUE的卸载决策、ISAC辅助RSU下的计算资源分配、传输功率和所有VUE的资源块分配进行联合优化,以最小化所有VUE的长期平均总服务延迟。为求解公式化的混合整数非线性规划问题,该文献设计了一种基于MADDPG的卸载优化与资源分配算法,该算法在收敛性和所有V-UE之间的长期平均延迟方面具有一定的优势。

### 3 已有研究工作的总结与不足分析

从现有的研究现状来看,基于传统方法的车联网任务卸载策略和基于深度强化学习的车联网任务卸载策略各有优劣,不一样的方法都有着不同的优缺点。传统方法适用于任务卸载场景简单、对实时性要求高的应用,但在复杂动态环境中表现不足。深度强化学习方法能有效应对复杂、高动态的车联网环境,但面临算法复杂度和实际部署的挑战。

随着车联网环境的日益复杂,基于深度强化学习的优化方法逐渐成为研究主流,其发展方向将对车联网技术的实际应用产生深远影响。

目前的研究存在以下的问题:

(1) 在车联网环境中,不同车辆的电量状况存在差异,低电量车辆在执行计算任务时面临较大的挑战。传统的任务卸载策略通常忽略了电量这一关键因素,导致低电量车辆可能承担过多的计算任务,进而加速电池消耗,影响车辆的续航能力并增加危险性。并且以往的研究方法中,传统方法难以适应车联网中车辆移动、网络波动等动态变化且容易陷入局部最优,难以实现全局优化。

(2) 我们还注意到,研究者们从不同的角度来考虑并设计卸载方案,有从优化系统能耗或系统时延上面的,也有从信息新鲜度方面考虑的,或是考虑车辆移动速度方面。例如,尽管有不少的文献提出将无人辅助系统进行任务卸载,但是大多数的方法都集中在提高整个系统效率和降低整个V2X-MEC系统的功耗上,忽略了降低电力有限的自动驾驶汽车的车载功耗这一最紧迫的任务<sup>[33]</sup>。

### 4 结束语

尽管车联网中的任务卸载策略领域的研究已经取得了初步的进展,但是一个好的卸载方案将会大大提高整个系统的效率与可靠性,值得我们持续投入研究。

(1) 车联网中的任务卸载并非简单的任务分配问题,还需考虑更加复杂的实际情况,例如不同车辆的电量状态。低电量车辆面临的主要挑战是:如何在确保高效完成计算任务的同时,避免过度依赖电池消耗,保证车辆的电池寿命。不同剩余电量的自动驾驶汽车,在节能的紧迫性上存在巨大差异。因此,我们可以关注低功耗自动驾驶汽车的掉电风险,在降低车辆功耗与时延的同时,还需要考虑车辆的续航里程需求和剩余功率,以提高车辆续航里程和行驶安全。因此,在车联网的任务卸载决策过程中,需要合理安排不同剩余电量车辆的任务卸载策略,以便进一步提升车联网系统整体性能和整体安全性及延长车辆续航能力。在现有的车联网任务卸载研究中,大多数方法未考虑电量对卸载决策的影响,在研究中可以通过引入车辆电量这一因素,有效避免了低电量车辆过度承担计算任务,从而优化了电量资源的使用,提高了车联网系统的能源效率。因此,可以在关注个体车辆的任务卸载决策的同时,通过全局优化,减少车联网系统中低电量车辆的数量,从而提升整个系统的任务完成效率和能效。合理地进行任务卸载和电量管理,将有助于提高车联网系统的性能,包括减少延迟、降低能耗和提升电池寿命,因此这方面的研究具有较高的应用前景。

(2) 引入多智能体强化学习方法,研究能够有效调度任务并降低低电量车辆数量的任务卸载策略。可以通过引入不同车辆的电量状态,优化车联网中任务的卸载决策,特别是针对低电量车辆的资源分配问题。可以利用多智能体强化学习框架,提升系统的整体性能和安全性。

(3) 多智能体强化学习在车联网任务卸载中的应用具有创新性,可以关注这方面的应用研究。虽然深度强化学习已被广泛应用于任务卸载问题,但大部分研究仅限于单一智能体的决策过程。可以考虑构建多智能体强化学习框架,将多个车辆视为智能体,在协作与竞争的情境下学习最优的任务卸载策略。这种方法能够处理车联网环境中的复杂动态交互问题,优化多车辆之间的任务分配和资源调度。不仅克服了传统方法的局限性,还能为车联网任务卸载策略提供更加智能、灵活、高效的解决方案,在未来的实际应用中具有重要价值。

### 参考文献

- [1] 吕品,许嘉,李陶深,徐文彪.面向自动驾驶的边缘计算技术研究综述[J].通信学报,2021,42(3):190-208.
- [2] 吕品,李凯,许嘉等.无人驾驶汽车协同感知信息传输负载优化技术[J].计算机学报,2021,44(10):1984-1997.
- [3] F Arena, G Pau. An overview of vehicular communications[J]. Future Internet, 2019,11(2):27-1-12.

- [4] Y Mao, C You, J Zhang, et al. A Survey on Mobile Edge Computing: The Communication Perspective[J]. IEEE Communications Surveys & Tutorials, 2017, 19(4):2322-2358.
- [5] N Abbas, Y Zhang, A Taherkordi, et al. Mobile Edge Computing: A Survey[J]. IEEE Internet of Things Journal, 2018, 5(1):450-465.
- [6] Y Hou, C Wang, M Zhu, et al. Joint allocation of wireless resource and computing capability in MEC-enabled vehicular network[J]. China Communications, 2021, 18(6):64-76.
- [7] M Li, Q Wu, J Zhu, et al. A computing offloading game for mobile devices and edge cloud servers[J]. Wireless Communication Mobile Computing, 2018, 2018(12):2179316.
- [8] J Zhang, X Hu, Z Ning, et al. Joint resource allocation for latency-sensitive services over mobile edge computing networks with caching[J]. IEEE Internet Things Journal, 2019, 6(3):4283-4294.
- [9] Y Dai, D Xu, S Maharjan, et al. Joint computation offloading and user association in multi-task mobile edge computing[J]. IEEE Trans. Veh. Technol., 2018, 67(12):12313-12325.
- [10] S Wang, M Zafer, K K Leung. Online placement of multi-component applications in edge computing environments[J]. IEEE Access, 2017, 5: 2514-2533.
- [11] L Bréhon-Grataloup, R Kacimi, A L Beylot. Mobile edge computing for V2X architectures and applications: A survey[J]. Computer Networks, 2022, 206:108797.
- [12] M A Khan. A survey of computation offloading strategies for performance improvement of applications running on mobile devices[J]. Journal of Network Computing Application, 2015, 56(10):28-40.
- [13] J Ahnutairi, M Aldossary, H A Alharbi, et al. Delay-optimal task offloading for UAV-enabled edge-cloud computing systems[J]. IEEE Access, 2022, 10: 51575-51586.
- [14] P Wang, K Li, B Xiao, et al. Multiobjective optimization for joint task offloading, power assignment, and resource allocation in mobile edge computing[J]. IEEE Internet of Things Journal, 2022, 9(14):11737-11748.
- [15] P Chennakesavula, J M Wu, A Ambikapathi. Incentive-driven fog-edge computation offloading and resource allocation for 5G-NR V2X-based vehicular networks[C]. 2023 IEEE 97th Vehicular Technology Conference, Florence, Italy, IEEE Press, 2023:1-5.
- [16] Q Liu, H Liang, R Luo, et al. Energy-efficiency computation offloading strategy in UAV aided V2X network with integrated sensing and communication[J]. IEEE Open Journal of the Communications Society, 2022, 3:1337-1346.
- [17] Annu, P Rajalakshmi. Joint scheduling of communication and computation resources for efficient computation offloading in MEC-based V2X systems[C]. 2023 IEEE 9th World Forum on Internet of Things, Aveiro, Portugal, IEEE Press, 2023:1-8.
- [18] W Feng, S Lin, N Zhang, 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.
- [19] J Zheng, Y Cai, Y Wu, et al. Dynamic Computation Offloading for mobile cloud computing: a stochastic game-theoretic approach[J]. IEEE Transactions on Mobile Computing, 2019, 18(4):771-786.
- [20] C Chen, L Chen, L Liu, et al. Delay-optimized V2V-based computation offloading in urban vehicular edge computing and networks[J]. IEEE Access, 2020, 8:18863-18873.
- [21] J Liu, M Ahmed, M A Mirza, et al. RL/DRL meets vehicular task offloading using edge and vehicular cloudlet: a survey[J]. IEEE Internet of Things Journal, 2022, 9(11):8315-8338.
- [22] B Yin, X Li, J Yan, et al. DQN-based power control and offloading computing for information freshness in multi-UAV-assisted V2X system[C]. 2022 IEEE 96th Vehicular Technology Conference, London, United Kingdom, 2022:1-6.
- [23] A Manzoor, et al. Deep reinforcement learning approach for multi-hop task offloading in vehicular edge computing[J]. Engineering Science and Technology, an International Journal, 2024, 59:101854.
- [24] H Dinh, N H Nguyen, T T Nguyen, et al. Deep reinforcement learning-based offloading for latency minimization in 3-tier V2X networks[C]. 2022 IEEE Wireless Communications and Networking Conference, Austin, TX, USA, IEEE Press, 2022: 1803-1808.
- [25] S M A Kazmi, S Otoum, R Hussain, et al. A novel deep reinforcement learning-based approach for task-offloading in vehicular networks[C]. 2021 IEEE Global Communications Conference, Madrid, Spain, 2021:1-6.
- [26] 田一博, 沈航, 白光伟, 等. 车联网中深度强化学习辅助的 RAN 切片和任务卸载联合优化[J]. 小型微型计算机系统, 2024, 45(04):910-918.
- [27] 李强, 杜婷婷, 童钊, 等. 移动边缘计算中基于深度强化学习的依赖任务卸载研究[J]. 小型微型计算机系统, 2023, 44(07): 1463-1469.
- [28] Y Cui, L Du, P He, et al. Cooperative vehicles-assisted task offloading in vehicular networks[J]. IEEE Transactions on Emerging Telecommunications Technologies, 2022, 33(7): 4472-4487.
- [29] S Yang, J Liu, F Zhang, et al. Caching-enabled computation offloading in multi-region MEC network via deep reinforcement learning[J]. IEEE Internet of Things Journal, 2022, 9(21):21086-21098.
- [30] 于晶, 鲁凌云, 李翔. 车联网中基于 DDQN 的边云协作任务卸载机制[J]. 计算机工程, 2022, 48(12):156-164.
- [31] X Huang, L He, W Zhang. Vehicle speed aware computing task offloading and resource allocation based on multi-agent reinforcement learning in a vehicular edge computing network[C]. Proceedings of 2020 IEEE International Conference on Edge Computing (EDGE), Beijing, China, IEEE Press, 2020:1-8.
- [32] B Hu, W Zhang, Y Gao, et al. Multiagent deep deterministic policy gradient-based computation offloading and resource allocation for ISAC-aided 6G V2X networks[J]. IEEE Internet of Things Journal, 2024, 11(20):33890-33902.
- [33] R Xiong, J Cheng, Q Yuan, et al. Reducing power consumption and latency of autonomous vehicles with efficient task and path assignment in the V2X-MEC based on nash equilibrium[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(10):12954 - 12967.