



综述

AI 算法在车联网通信与计算中的应用综述

康宇^{1,2,3}, 刘雅琼^{1,2,3}, 赵彤雨^{1,2,3}, 寿国础^{1,2,3}

- (1. 先进信息网络北京实验室, 北京 100876;
2. 网络体系构建与融合北京市重点实验室, 北京 100876;
3. 北京邮电大学信息与通信工程学院, 北京 100876)

摘要: 在 5G 时代, 车联网的通信和计算发展受到信息量急速增加的限制。将 AI 算法应用在车联网, 可以实现车联网通信和计算方面的新突破。调研了 AI 算法在通信安全、通信资源分配、计算资源分配、任务卸载决策、服务器部署、通算融合等方面的应用, 分析了目前 AI 算法在不同场景下所取得的成果和存在的不足, 结合车联网发展趋势, 讨论了 AI 算法在车联网应用中的未来研究方向。

关键词: 通信资源分配; 通信安全; 计算卸载; 通算融合; AI 算法; 深度强化学习

中图分类号: TN929

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2023019

A survey on AI algorithms applied in communication and computation in Internet of vehicles

KANG Yu^{1,2,3}, LIU Yaqiong^{1,2,3}, ZHAO Tongyu^{1,2,3}, SHOU Guochu^{1,2,3}

1. Beijing Laboratory of Advanced Information Networks, Beijing 100876, China
2. Beijing Key Laboratory of Network System Architecture and Convergence, Beijing 100876, China
3. School of Information and Communication Engineering, Beijing University of Posts and Telecommunications, Beijing 100876, China

Abstract: In the 5G era, the development of communication and computing in the Internet of vehicles has been limited by the rapidly increasing amount of information. New breakthroughs in communication and computing in Internet of vehicles can be achieved by applying AI algorithms to the Internet of vehicles. Firstly, the application of AI algorithms in communication security, communication resource allocation, computation resource allocation, task offloading decision, server deployment, communication-computation integration were investigated. Secondly, the achievements and shortcomings of the present AI algorithms in different scenarios were analyzed. Finally, combined with the Internet of vehicle development trend, some future research directions for AI algorithms applied in the Internet of vehicles were discussed.

Key words: communication resource allocation, communication security, computation offloading, communication-computation integration, AI algorithm, deep reinforcement learning

收稿日期: 2022-07-22; 修回日期: 2022-12-20

通信作者: 刘雅琼, liuyaqiong@bupt.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61901052)

Foundation Item: The National Natural Science Foundation of China (No.61901052)



0 引言

现如今,互联网无处不在,完全融入了人们的生活,并且进入了智能互联网时代,即物联网时代。物联网即万物相连的互联网,通过各种信息传感器将信息与网络结合起来形成一个巨大网络,生活中的每个物品都将接入网络,实现任何时间、任何地点,人、机、物的互联互通。而车联网(Internet of vehicles, IoV)是物联网中最为成熟、最具前景、最有价值的部分,车联网通过车内网、车载移动互联网和车际网,通过汽车收集并共享大量信息,实现车与人相连、车与车相连、车与路相连、车与外部世界之间的连接,实现车辆的自动驾驶,将人们从繁重的驾驶工作中解放出来,并且有效利用道路资源,解决交通拥堵的问题,改变人们的生活,进一步提高和解放社会生产力。典型的车联网系统架构^[1]主要分为3层,分别是感知层、网络层、应用层,如图1所示。感知层采集大量的数据信息,为车联网系统提供用于精准计算的基础数据信息;网络层在整个车联网系统中起到上传下达的作用,完成大量信息数据的传递任务;应用层是车联网的控制大脑,其以车联网指挥控制平台为核心,实现与车联网相关的其他应用,如交通路况监测、交通事故预防、智慧交通、交通救援等应用。




图1 典型的车联网系统架构^[1]

车联网场景如图2所示,利用蜂窝车联网(cellular vehicle-to-everything, C-V2X)技术^[2-3]中的车辆到车辆(vehicle-to-vehicle, V2V)、车辆到基础设施(vehicle-to-infrastructure, V2I)、车辆到人(vehicle-to-pedestrian, V2P)和车辆到网络(vehicle-to-network, V2N)通信,形成一个动态移动通信系统,实现了车辆网络中各个节点之间的低时延和高可靠性通信。通过该系统,车辆、基础设施、人、传感器等可以实现信息交换与共享,系统可以收集有关车辆、道路及其周围环境的信息,并在信息平台上处理、计算后发布信息,有效地引导和监督车辆,为用户提供各种多媒体和移动互联网应用服务。




图2 车联网场景

6G 已经成为全球的研究热点,在这一背景下,通信设备和终端将具备智能感知和映射数字世界的的能力,而这些会更好地服务于车联网,以实现智慧城市、智慧交通等新型垂直应用场景的应用。而以这些场景为代表的6G典型应用场景中存在大量能力高度差异化的自动化设备,对极低时延、极高可靠性、超大带宽、海量接入等方面的通信需求越发严苛,此时需要通算融合等技术手段,赋予6G以通信能力为基础的广域智能协作

以及不断增强的算力以实现网络的自学习、自运行、自维护。通算融合网络是指同时具备泛在智能通信与计算能力的网络。该网络内的各网元设备通过通算软/硬件资源的协同与共享,实现协作通信、智能计算功能的深度融合、互惠增强。通信网络作为连接用户和传输数据的管道,可感知计算,用于支撑多样性的分布式计算资源的高效使用^[4-7]。多样性计算资源、通算融合等成为业界重要技术趋势。

以深度学习、强化学习、分布式学习等为代表的人工智能(artificial intelligence, AI)技术的兴起,在通信网络优化、控制应用等各个领域产生了广泛而深刻的影响,大大推动了通信—计算领域深度融合的可能。

常见的 AI 算法有朴素贝叶斯、 K 近邻(K -nearest neighbor, KNN)、支持向量机(support vector machine, SVM)、决策树、逻辑回归等传统机器学习算法及神经网络算法等。其中,应用于车联网的神经网络算法有基于单智能体的深度 Q 网络(deep Q-network, DQN)、深度确定性策略梯度(deep deterministic policy gradient, DDPG)、异步优势动作评价(asynchronous advantage actor-critic, A3C)、近短策略优化(proximal policy optimization, PPO)算法,以及多智能体深度确定性策略梯度(multi-agent deep deterministic policy gradient, MADDPG)算法等深度强化学习算法。

1 研究现状

本节分别介绍 AI 算法在车联网通信、计算以及通算融合方面的应用。

1.1 AI 算法在车联网通信中的应用

1.1.1 车联网通信安全方面

AI 算法在车联网通信安全方面的应用广泛,采用的 AI 算法大多数为深度强化学习算法,主要利用车联网通信方面的现有技术和背景进行建

模,从密钥时延、高服务质量(quality of service, QoS)、隐私安全等方面设定学习方案,使设定的智能体在不断的试错与借鉴的学习中,获得最优策略,学会自己处理问题、维护系统,达到最好的效果。下面具体进行介绍。文献[8]提出了一种基于强化学习的低时延车联网群密钥分配管理技术,利用 Q 学习(Q-learning)来优化群密钥的更新频率和密钥长度,通过低时延群集密钥更新实现对密钥窃取和电子欺骗等攻击的抵抗,提升群集通信安全等级,并降低群集内通信时延。文献[9]提出了一种基于强化学习的网格路由协议,通过网格识别号(grid identification number, GID)计算节点之间的距离,以获得从源到汇的最近路径,从而实现最小时延。另外,通过使网格中所有节点进行强化学习,获取其可靠性和时延的性能知识,可以选出可靠性最高的最优网格协调器。这样可以在可靠性和端到端时延方面提供较高的 QoS 性能。文献[10]提出了一种新的考虑车辆速度影响的动态业务迁移方案,实现服务质量和迁移成本之间的平衡;采用了 DQN 算法,其提出的基于深度 Q 学习(deep Q-learning, DQL)的高级迁移方案可以提高 QoS,实现更高的系统利用率。文献[11]提出了一种基于竞争信息的状态表示的基于 DQN 的自适应介质访问控制(media access control, MAC)层算法,可以提高 V2V 安全包广播的性能。文献[12]使用 DQN 算法,使路侧单元(road side unit, RSU)可以立即执行最优调度决策,建立一个达到可接受的 QoS 水平的绿色和安全的车辆网络。文献[13]提出了一种基于深度强化学习的协同感知方案,以提高对周围物体的检测精度。该方案通过深度强化学习选择传输数据,减轻了车载网络中的网络负载,提高了通信可靠性。文献[14]使用 Spark 框架的卷积神经网络—长短期记忆(convolutional neural network-long short-term memory, CNN-LSTM)的深度学习方法,降低了入侵检测的训练和测试时间,可以更



好地满足入侵检测实时性和准确性的要求,满足车联网信息安全入侵检测的需要。文献[15]针对车路协同推断中的黑盒图像还原攻击,采用反卷积网络算法,通过训练一个反卷积网络,学习中间结果和原始图像之间的关系,实验证实了算法能有效防御黑盒图像还原攻击,同时保持车路协同推断的精确度。文献[16]通过多智能体近端策略优化(multi-agent proximal policy optimization, MAPPO)算法求解智能汽车和验证者的交互过程,保证了区块验证的安全性和可靠性。文献[17]提出了一种基于信任的对偶深度强化学习(trust-dueling deep reinforcement learning, T-DDRL)方法,将对偶网络架构部署到软件定义网络(software defined network, SDN)的逻辑集中控制器中。在车载自组网(vehicular Ad Hoc network, VANET)技术中,深度神经网络(deep neural network, DNN)利用 SDN 控制器作为智能体学习最可信的路由路径。文献[18]提出了一种鲁棒的多智能体循环确定性策略梯度与异常检测器

(multi-agent recurrent deterministic policy gradient with anomaly detector, MARDPG-AG)算法,该算法使智能体在给定环境的系统状态中,即使存在部分或操纵的观测,也能鲁棒地学习,增强车载网络的安全性。

表 1 从 AI 算法、优化内容、贡献方面总结了 AI 算法在通信安全方面的应用。

1.1.2 车联网通信资源分配方面

AI 算法针对传统通信资源分配的方案中存在的一些问题,提供了一种高效的、新型的解决办法,如可以将通信资源分配的优化问题转化为凸问题并利用凸优化算法求解,在此基础上利用 AI 算法降低算法复杂度,从而提高效益;某些传统的基于模型的优化技术以非凸结束,则可以通过 AI 算法设计无模型的方法解决。利用 AI 算法优化通信资源的分配问题,可以提高信道容量、提高网络鲁棒性、减少通信系统时延、降低成本,尤其是 V2V 通信的资源分配,可以在每个 V2V 链路设置一个智能体,经过训练后,每个智能体都可以学会如何

表 1 AI 算法在通信安全方面的应用

文献	AI 算法	优化内容	贡献
文献[8]	Q-learning	密钥更新时延 通信加/解密计算时延	提出了一种基于 Q-learning 的车联网群密钥分配管理技术,提升了群集的通信安全等级,降低了通信时延
文献[9]		复杂环境中保证高 QoS	提出了一种基于 Q-learning 的网格路由协议,可以在可靠性和端到端时延方面提供较高的 QoS 性能
文献[10]	DQN	高 QoS	提出了一种基于 DQN 的新的考虑车辆速度影响的动态业务迁移方案,可以提高 QoS,实现更高的系统利用率
文献[11]		提高 V2V 安全包广播的性能	提出了一种基于竞争信息状态表示的自适应 MAC 层算法,并结合 DQN 算法,提高了 V2V 安全包广播的性能
文献[12]		最小化接收信息时延	使用 DQN 算法,使 RSU 可以立即执行最优调度决策,建立一个达到可接受的 QoS 水平的绿色和安全的车辆网络
文献[13]		车联网中的网络负载、通信可靠性	提出了一种基于 DQN 的协同感知方案,减轻了车载网络中的网络负载,提高了通信可靠性
文献[14]	CNN-LSTM	入侵检测的准确性和低时延	提出 Spark 框架的 CNN-LSTM 的深度学习算法,可以很好地满足入侵检测对准确性和实时性的要求
文献[15]	反卷积网络	车路协同推断的隐私问题	提出 3 种基于差分隐私的防御算法,通过理论计算和实验证明所提算法可有效防御黑盒图像还原攻击,同时保持车路协同推断的精确度
文献[16]	MAPPO	区块验证的安全性与可靠性	将智能汽车和验证者之间的交互过程建模成斯坦伯格博弈模型,利用 MAPPO 算法求解,保证了区块验证安全性与可靠性
文献[17]	T-DDRL	车载自组网技术中最可信路由路径的选择	提出了一种 T-DDRL 方法,深度神经网络利用 SDN 控制器作为智能体可以学习最可信的路由路径
文献[18]	MARDPG-AG	车载网络的安全性	提出一种鲁棒的 MARDPG-AG 算法,增强了车载网络的安全性

满足设定的需求, 自主严格地进行资源分配和约束。下面具体对常规 AI 算法和结合 AI 的启发式算法在通信资源分配方面的应用进行介绍。

在常规 AI 算法方面, 文献[19]提出了一种基于竞争信息的状态表示的 DQN 自适应 MAC 层算法, 可以提高 V2V 安全包广播的性能。文献[20]提出了视频语义驱动的资源分配指导模型, 以及在该模型指导下车联网场景中的通信资源分配算法, 能最优地分配每辆车的带宽资源, 从而最大限度正确理解视频语义。文献[21]提出了一种基于 DQN 的路由算法, 有效降低了车辆节点间通信中断的概率。该算法还采用深度强化学习方法选择多跳路由, 可以减少车网路由的传输损耗, 提高传输效率。文献[22]开发了一种基于移动边缘计算 (mobile edge computing, MEC) 技术的在线多址接入方案, 并结合 DQN 算法解决了车联网中的片选择、覆盖选择、资源块和非正交多址接入功率分配问题。基于 IoV 的 DRL 架构如图 3 所示, 其提出的 DQN 算法在具有 MEC 的 gNodeB 范围内应用, gNodeB 观察 IoV 环境中交互得到的信息和奖励, 通过不断训练最终使 gNodeB 学会有效解决复杂的车联网资源分配问题。




图3 基于IoV的DRL架构

文献[23]针对多智能体强化学习存在的非平稳性问题, 提出通过指纹深度强化学习 (deep reinforcement learning, DRL) 的方式, 在保证 V2V 链路可靠性约束下, 学习对应的分配策略以优化网络

容量, 提高网络性能。同时, V2V 链路能够根据高动态车辆环境下的瞬时观测值, 做出自适应决策。文献[24]提出了一种基于联邦深度强化学习的频谱分配和功率控制方案, 在满足链路可靠性要求的前提下, 联合频谱分配和功率控制, 以提高链路的总用户速率, 能够有效地最大化链路的总信道容量。文献[25]提出了一种基于深度强化学习的 V2V 通信分散资源分配机制, 寻找传输的最佳频谱和功率, 同时最大限度地减少对 V2I 通信的干扰。文献[26]提出了一种基于图和深度强化学习的资源分配方法, 车辆通信信道由基站集中分配, 而车辆用户设备使用深度强化学习进行分布式功率控制。文献[27]提出了一种基于长短期记忆和深度强化学习技术的主动算法, 以解决每个车辆用户设备 (vehicular user equipment, VUE) 对所面临的局部网络状态空间的部分可观测性和高维灾难。在该算法下, RSU 根据对全局网络状态的局部观测, 在各个调度时隙进行分散的最优频带分配和分组调度决策。文献[28]在小时间尺度下, 设计了满足内容发送时延约束的车辆联合调度和带宽分配方案, 并提出了一种基于 DDPG 的合作缓存方案, 通过集成深度神经网络和强化学习方法, 系统智能体可以根据历史经验进行联合缓存决策, 为车辆边缘计算 (vehicular edge computing, VEC) 和网络中的内容放置和交付提供了一种新的优化模式。文献[29]研究了一种无人机辅助车载网络, 无人机通过联合调整传输控制 (功率和信道) 和三维飞行来实现总吞吐量的最大化。文献[30]提出的基于强化学习和非正交多址接入的车联网无线资源分配算法可达到同时提升网络容量和降低功耗的目的, 在提高网络容量的同时降低功耗。文献[31]提出了一种基于深度强化学习的异步优势动作评价 (actor-critic based deep reinforcement learning, AC-DRL) 算法的车联网无模型聚类解决方案, 以有效管理车联网产生的流量, 结合环境的动态性, 选择网络中能够最优分配资源的簇头 (cluster head, CH), 以满足用户的



业务和服务等级协定(service level agreement, SLA)需求。文献[32]利用柔性动作—评价(soft actor-critic, SAC)强化学习算法设计神经网络,通过最大化熵与累计奖励来训练智能体,使得 V2V 链路经过不断学习优化频谱资源分配。

在结合 AI 的启发式算法方面,文献[17]提出了一种基于信任的对偶深度强化学习方法,将对偶网络架构部署到软件定义网络的逻辑集中控制器中,并且在 VANET 中,DNN 利用 SDN 控制器作为智能体学习最可信的路由路径。文献[33]针对异构蜂窝网络中异构 QoS 保障的联合信道分配与功率控制问题(V2V 通信链路资源分配问题),提出了一种基于多智能体深度强化学习的资源分配框架,在保证网络中所有蜂窝用户(cellular user, CU)的 QoS 要求的同时最大化车辆用户的效用,优化信道分配和功率控制,以满足异构车辆网络中的 QoS 要求。文献[34]提出了一种面向长期演进—车到外界(long term evolution-vehicle to everything, LTE-V2X)的联合信道估计与均衡的深度神经网络。该文献采用的算法利用了一维卷积神经网络(one dimension convolutional neural network, 1D CNN)和双向长短期记忆神经网络,该算法可以降低通信系统的误码率(bit error rate, BER)。文献[35]提出了一种基于深度学习的信道估计算法,该算法利用 1DCNN 完成频域插值和条件循环单元(conditional recurrent unit, CRU)的时域状态预测,通过引入额外的速度编码矢量和多径编码矢量跟踪环境的变化,对不同移动环境下的信道数据进行精确训练,提升了信道估计精度,降低了误码率和增强了鲁棒性。文献[36]提出了一种将联邦学习与区块链结合的新型模式,可以实现基于联邦学习和区块链授权的车辆网络(federated learning and blockchain empowered vehicular network, FBVN)的边缘智能,并将动态时变的 FBVN 下每个自动驾驶车辆(autonomous vehicle, AV)选择无线信道的过程建模为马尔可夫模型,最后提出联邦对偶

深度 Q 学习(federated duel deep Q-learning, F-DDQL)算法,降低系统时延。

1.2 AI 算法在车联网计算中的应用

随着车联网的飞速发展,一系列涵盖信息服务、驾驶安全、交通效率的车载应用诞生,不同的车载业务产生的海量数据给网络和带宽带来了巨大压力,云计算虽然可以解决车辆资源不足的问题,但是其远距离部署会导致时延较大,同时也会加大带宽的费用开销。MEC 通过将云计算和存储能力下沉到网络边缘,可以实现应用、服务和内容的本地化、近距离、分布式部署,从而缓解云计算带来的问题。将 MEC 应用于车联网,形成的车载边缘计算网络架构如图 4 所示,包含 3 层:用户层、边缘层和云层。

车联网的计算包含计算资源分配、任务卸载决策、服务器部署 3 个方面。本节将介绍 AI 算法在这 3 个方面的应用。




图 4 车载边缘计算网络架构

1.2.1 车联网计算资源分配方面

由于车联网中的任务类型复杂多样,有些任务所需的计算量很大,虽然 MEC 服务器和车辆本身具有一定的计算资源,但这些资源有限,实际运用中需要调整好移动边缘计算、云计算、本地计算之间的协作,以合理分配计算资源,降低成本、实现效益最大化。此外,车辆的高速移动、通信质量的多样性,使得计算资源的分配更加复杂,而 AI 算法在此过程就可以发挥巨大作用,如 AI 算法能以车辆移动速度、计算资源为约束,根

据实际需求设定目标函数,通过训练来有效分配计算资源。下面具体对 AI 算法在车联网计算资源分配方面的应用进行介绍。

文献[37]使用 Q-learning 方法,有效解决了使用移动边缘计算的车辆网络中的资源分配问题。文献[38]提出了一种基于深度强化学习网络的计算资源分配方案。该方案以服务节点的计算能力和车辆移动速度为约束条件,以系统总计算成本最小为目标函数,建立了边缘计算场景下的任务资源分配模型。此外,采用深度 Q-learning 网络求解资源分配的数学模型,采用经验重演方法避免维数灾难,保证低维数据的质量、资源分配的开销和低时延操作要求。文献[39]提出结合强化学习算法 PPO 的启发式算法,利用车辆的移动和停止状态做出更有效的资源配置决策。文献[40]详细研究了区块链支持的车联网(blockchain supported Internet of vehicles, BS-IoV)系统的计算资源分配问题,提出了一种基于新兴 DRL 技术的智能资源分配方法,使车联网系统在提高区块链吞吐量和资源使用效率方面有更良好的性能。文献[41]提出了基于无限时域半马尔可夫决策过程

(infinite time domain semi-Markov decision process, SMDP)算法的车载云计算系统的最优计算资源分配方案,以实现任务卸载能力的提升。文献[42]提出了一种基于遗传算法的卸载策略,能够得到全局近似最优解,并在计算任务时延约束下最小化云边通信流量的问题。文献[43]提出了一种 IoV 环境下基于移动边缘计算的计算资源分配策略,对遗传算法进行改进,降低了时延和开销,提高了计算精度和遗传算法在研究问题中的适用性。文献[44]提出了一种基于 IoV 的智能城市按需计算资源交易管理系统,构建了一个两阶段的斯塔克伯格博弈来刺激买卖双方之间的计算资源交易过程,并用反向归纳法证明了博弈均衡的存在唯一性。最后,进行了安全性分析和数值仿真,以分析系统的性能。

表 2 从 AI 算法、优化内容、贡献方面总结了 AI 算法在计算资源分配方面的应用。

1.2.2 车联网任务卸载决策方面

目前,车联网场景下计算任务卸载决策主要解决车载应用任务是否需要卸载及卸载多少的问题,卸载决策的主要优化目标有任务执行时延、能耗及

表 2 AI 算法在计算资源分配方面的应用

文献	AI 算法	优化内容	贡献
文献[37]	Q-learning	时延	使用 Q-learning 方法,有效解决了使用移动边缘计算的车辆网络中的资源分配问题
文献[38]	DQN	总计算成本	提出了一种基于 DQN 的计算资源分配方案,以系统总计算成本最小为目标函数,可以满足资源分配的低开销和低时延等要求
文献[39]	PPO	时延	提出结合强化学习算法 PPO 的启发式算法,利用车辆的移动和停止状态做出更有效的资源配置决策
文献[40]	PPO	吞吐量、资源使用效率	提出了一种基于 PPO 的智能资源分配方法,该算法在提高区块链吞吐量和资源使用效率方面都有更良好的性能
文献[41]	SMDP	功耗、处理时间	提出了基于 SMDP 算法的车载云计算系统的最优计算资源分配方案,以实现任务卸载能力的提升
文献[42]	遗传算法	网络拥塞	提出了一种基于遗传算法的卸载策略,在计算任务时延约束下可以最小化云边通信流量的问题
文献[43]	遗传算法	时延和开销	提出了一种 IoV 环境下基于移动边缘计算的计算资源分配策略,对遗传算法进行改进,降低了时延和开销,提高了计算精度和遗传算法在研究问题中的适用性
文献[44]	斯塔克伯格博弈	买家和卖家效用	提出了一种基于 IoV 的智能城市按需计算资源交易管理系统,构建了一个两阶段的斯塔克伯格博弈来刺激买卖双方的计算资源交易过程,提高了系统的安全性,优化了交易双方的效用



时延与能耗的权衡等,在复杂多变、实时动态的交通环境中,需要对不同车辆终端进行任务优先级划分并制定卸载决策,以往的传统方案难以做到。而 AI 算法(如 DQN)可以在没有任何先验信息的前提下与环境进行交互,从中学习并调整策略以达到最佳的长期回报,并且可以在时变的环境中根据过去的经验实现卸载策略的自我更新,从而很好地适应动态环境,有效降低任务执行时延、提高车联网车辆终端用户的使用体验。下面从部分卸载和全部卸载两方面,具体对 AI 算法在车联网任务卸载决策方面的应用进行介绍。

AI 算法在全部卸载类型的任务卸载决策方面应用如下。文献[45]提出了车联网中基于软件定义车载网络 (software defined in-vehicle network, SDN-V) 辅助的卸载对象匹配策略,构建了基于 Q-learning 算法的卸载决策,利用乘子法对目标函数进行优化求解。文献[46]设计了一种基于 DQN 的博弈算法,帮助车辆用户进行信道选择,并通过神经网络多次迭代学习,为用户提供最优的功率分配策略。文献[47]研究了 MEC 辅助异构车联网的计算卸载问题,以总计算速率最大化为目标,设计了串行和并行两种卸载方案,并将优化问题表述为马尔可夫决策过程问题,据此提出了一种基于 DQN 的车辆边缘计算卸载方案。文献[48]提出了一种基于 DQN 的计算任务分发卸载算法,根据层次分析法对不同车辆终端的计算任务进行优先级划分,引入基于 DQN 的边缘计算方法,以计算任务处理速率加权和为优化目标建立任务卸载模型,建立基于 DQN 的车辆终端自主最优任务卸载策略,最大化卸载决策制定模型的长期效用。文献[49]提出了一种协同边缘计算框架。首先,提出了一种任务划分与调度算法 (task partition and scheduling algorithm, TPSA),并给出了一种计算卸载策略,用于确定边缘服务器的工作负载分配和任务执行顺序。其次,开发了基于 DDPG 的协同计算方法,确定车辆的任务卸载、计算和结果交付策略,在复杂的城市交通网络中寻

找最优解,该算法可以适应高度动态的环境,具有优异的性能。文献[50]提出了一个多用户端边云异构网络和一种基于 DDPG 的计算卸载和资源分配算法,以减少能源消耗。文献[51]提出了一种新的基于 PPO 的方法来解决计算卸载调度问题,采用一种由 CNN 增强的参数共享 DNN 架构来近似策略函数和值函数。通过大量的仿真实验证明了提出的方法可以在不需要任何环境动力学知识的情况下高效地学习最优卸载调度策略,并在长期成本方面明显优于许多已知的基线算法。文献[52]提出了一种基于策略的深度强化学习卸载方案,在保证依赖关系的前提下,最小化多车场景下所有车联网应用的总任务时延。文献[53]研究了车联网中的部分计算卸载问题,提出了一种基于运动轨迹预测的机动模型来表征车辆的机动强度,建立了从单车场景到多车场景的卸载计算和资源分配问题,还提出了一种基于 A3C 的方案来求解优化问题,并从多个角度研究了所提算法的性能,该算法能够很好地反映复杂的网络环境和车辆的运动强度,优于现有的基于 DQN 的方案和传统的贪心方案。文献[54]提出了一种基于深度强化学习的分布式服务卸载方法 (distributed service offloading method with asynchronous advantage actor-critic, D-SOAC),以降低车联网用户长期的平均服务时延,从而为用户提供高质量的服务体验。

AI 算法在部分卸载类型的任务卸载决策方面应用如下。文献[55]重点研究了 VEC 网络体系结构中车辆部署边缘计算服务器为任务车辆提供计算服务的计算卸载方案,提出了一种结合贝叶斯推理的 DQN 算法来解决时延和能耗问题。文献[56]研究了基于 MEC 的道路网络邻近检测场景下时延与能耗的联合优化问题,将联合优化问题表示为约束优化问题 (constrained optimization problem, COP),使用 DQN 进行求解,并通过仿真验证了该方法的有效性。文献[57]提出了基于 DQN 的车联网边缘计算服务卸载 (DQN based service of-

floading, SODQN) 方法, 以降低车联网用户长期的平均服务时延, 从而为车联网用户提供高质量的服务体验。文献[58]研究了分布式 V2V 计算卸载问题。将任务卸载问题表述为一个序列决策问题, 提出了一种基于强化学习的任务卸载方案, 该方案既考虑了共享空闲计算资源的动机, 又考虑了任务卸载的成本, 并验证了该算法在不同车辆密度下具有更好的性能。文献[59]设计了一个异构车载网络中考虑信道状态和可用带宽变化的 MEC 系统, 提出了一种基于深度强化学习的自适应计算卸载 (adaptive computation offloading based on reinforcement learning, ACORL) 方法, ACORL 方法通过与动态仿真环境的交互, 智能学习策略, 可以解决能源消耗、带宽分配和执行时延之间的权衡问题, 相比两种基准方案 (对偶 DQN 和贪婪算法) 有更好的性能。文献[60]研究了一个具有多个用户和多个 MEC 服务器的车载网络, 提出了一种优化卸载决策的在分布式方案中考虑负载均衡的基于经验优先重放的深度确定性策略梯度算法 (DLPR-DDPG) 来最小化时延和能耗, 该算法的收敛性和鲁棒性均优于基线算法。文献[61]提出了一种基于 DRL 的卸载方法来处理典型 VEC 场景下的任务卸载问题, 采用 DNN 对卸载策略进行近似, 然后使用 PPO 进行训练, 不需要任何环境动态的先验知识, 并分别在静态队列和动态队列两种场景下对该方法进行性能评估, 通过仿真证明了该方法的优越性。文献[62]研究了车联网中车队场景下的分布式任务卸载问题。将任务卸载问题构建为一个顺序决策问题。基于 A3C 算法, 提出一个基于服务节点综合能力的动态定价激励方案, 并进行任务卸载决策。

1.2.3 车联网服务器部署方面

车联网中服务器在网络服务提供中起着重要的作用, 如何选择要部署的 RSU 的数量和位置, 并将流量负载分配给它们, 是一个关键和实用的

开放性问题。每个 RSU 有一个不规则的服务器区域、不同的负载能力, 使得问题比传统的设施选址问题更加困难。目前的车联网中服务器部署的研究, 大部分利用了遗传算法或深度强化学习算法, 相比于其他方法, 这两种方法都可以在部署成本较低的情况下有更好的效果。下面分别从这两种算法在车联网服务器部署方面的具体应用进行介绍。

文献[63]研究了考虑预期交付时延需求和任务分配的二维 IoV 网络的 RSU 部署问题, 设计了一种基于效用的 RSU 部署算法 (utility-based road side unit deployment algorithm, URDA) 和一种基于线性规划 (linear programming, LP) 的聚类算法来解决每个 RSU 的不规则覆盖区域的问题。此外, 还分析了 URDA 与最优解之间的差距, 仿真证明了在部署成本较低的情况下, 相对于其他方法所提出的 URDA 的有效性和优越性接近最优。文献[64]提出了一种基于 QoS 驱动的多媒体边缘云 IoV 应用优化部署方案 (quality of service-driven Internet of vehicles application optimizing deployment scheme in multimedia edge clouds, QaMeC), 通过建立统一的 QoS 模型来屏蔽 QoS 计算的不一致性。此外, 还使用非支配非序遗传算法 II (nondominated sorting genetic algorithm II, NSGA-II) 来解决多云应用的部署问题。文献[65]开发了动态边缘服务器布置方法 (dynamic edge servers (ES) placement approach, DEP)。在技术上, DEP 利用了非支配排序遗传算法 III (nondominated sorting genetic algorithm III, NSGA-III) 进行布置, 具有更好的性能和更少的现有布局重构。采用聚类算法对 NSGA-III 的种群进行初始化, 以获得更高的精度和收敛速度, 并基于库恩—曼克尔斯算法 (Kuhn-Munkres 算法, 或称匈牙利算法)、二部图匹配算法计算最小重构代价的适应度。文献[66]将 ES 布局问题形式化为一个具有 3 个目标的多目标优化问题。然后, 设计了具有基



于聚类的种群初始化策略的 NSGA-III，并将其应用于约束优化问题。文献[67]利用 DQN 算法来获得实现边缘计算覆盖率、ES 工作负载均衡、平均时延等多个目标的最优布置方案。文献[68]提出了一种云边缘计算中具有隐私保护的智能 IoV 服务部署和执行方法 (GoDeep)，还提出了一种基于 DDPG 的服务部署方案，并通过仿真实验对 GoDeep 的性能进行了评估，证明了方案的有效性。文献[69]提出了一种多智能体强化学习 (reinforcement learning, RL) 算法来解决移动边缘服务器的布局问题，最大限度地减少网络时延并平衡边缘服务器上的负载。

AI 算法在服务器部署方面的应用见表 3，从 AI 算法、优化内容、贡献方面总结了 AI 算法在服务器部署方面的应用。

1.3 AI 算法在车联网通算融合中的应用

VEC 网络中具有通信、计算、缓存和协作计算的统一框架如图 5 所示，其中 VEC 网络中具有通信、计算、缓存和协作计算的统一框架道路被分为 N 段，每一段的车辆之间、车辆与 RSU 之间可以通过分配的信道，建立通信链路，进行信息交互与任务卸载。许可带宽分为两类，一类用于车辆到基础设施 (V2I) 通信，另一类用于车辆到

车辆 (V2V) 通信。此外，由于部署了电子通信网络 (electronic communication network, ECN)，RSU 提供了强大的计算能力。




图 5 VEC 网络中具有通信、计算、缓存和协作计算的统一框架

1.3.1 车联网通算资源联合分配方面

云计算、雾计算、边缘计算的发展以及通信技术的发展，对车联网产生了深远影响。虽然二者在各自领域已进行了很多研究，但如何进行通信、计算资源的合理分配并实现不同局部范围内实体间的资源高效利用，仍有很大的发展潜力需要挖掘。目前 AI 算法在通算融合方面的应用包括：将通信和计算资源的分配定义为两个独立的目标，用多目标资源分配的 AI 算法实现最优解；

表 3 AI 算法在服务器部署方面的应用

文献	AI 算法	优化内容	贡献
文献[63]	聚类算法	系统效用	设计了一种基于线性规划的聚类算法解决每个 RSU 的不规则覆盖区域的问题，以最大化系统效用
文献[64]	NSGA-II	高 QoS	采用 NSGA-II 解决多云应用的部署问题，所提方案可以为多媒体边缘云环境中各种不同 QoS 要求的应用提供最优、高效的业务部署方案
文献[65]	NSGA-III	时延 负载均衡	设计了一种多目标进化算法 NSGA-III 和 Kuhn-Munkres 加权二部图匹配算法的 DEP 方法，该算法在时延、负载均衡和重构成本有一定的效果
文献[66]			采用非支配排序遗传算法 NSGA-III 得到一组具有低时延、平衡工作量以及适当 ES 数量的 ES 布局，获得更高的 QoS
文献[67]	DQN		利用 DQN 算法获得实现边缘计算覆盖率、ES 工作负载均衡、平均时延等多个目标的最优布置方案
文献[68]	DDPG	任务计算时间	提出了一种基于 DDPG 的服务部署方案，可以减少任务计算时间
文献[69]	多智能体 RL	时延 负载均衡	提出了一种多智能体 RL 解决方案来解决移动边缘服务器的布局问题，最大限度地减少网络时延并平衡边缘服务器上的负载

将雾计算架构应用于车联网, 建立车联网异构接入的资源优化模型, 通过深度强化学习算法对调度方案进行高效处理; 使无人机和边缘计算服务器使用多智能体强化学习算法来协同决策通算资源的分配。下面具体进行介绍。

文献[70]分析了异构车联雾架构下不同接入方式的传输性能, 针对车联网中车辆移动的特性, 在不同行驶速度下进行了信道容量分析, 给出了车联雾计算架构下多业务的优化模型, 并提出了基于 Q-learning 算法的通信与计算联合资源分配算法。文献[71]提出了一种多目标强化学习策略, 称为智能通信和计算资源分配 (intelligent communication and computation resource allocation, ICCRA), 该策略在移动边缘计算层采用 Q-learning 实现通信和计算资源分配的最优解, 有效地降低了系统总成本。文献[72]提出一个可以支持网络、缓存和计算资源动态编排的集成框架, 采用深度强化学习的方法, 获得了集网络、缓存、计算于一体的车辆网络中的资源分配策略, 以提高车联网性能。为了解决通信和计算能力限制下网络中资源最佳利用的问题, 文献[73]通过联合考虑用于数据调度的通信和计算资源, 建立了一个包含通信、计算、缓存和协同计算的统一框架, 开发了一种协同数据调度方案, 在保证应用程序时延约束的前提下, 最小化系统范围内的数据处理成本; 将数据调度建模为一个深度强化学习问题, 利用 DQN 算法来解决, 仿真实验验证了该方法的有效性。文献[74]提出了一种临时无人机 (unmanned aerial vehicle, UAV) 辅助车载边缘计算网络 (vehicular edge computing network, VECN) 中基于学习的通道分配和任务处理策略, 该策略应用于需求车辆通过临时无人机向一组志愿车辆采集交通数据的情况。该文献还提出了一种基于 DQN 的任务处理模式选择方法, 仿真实验表明, 该方法具有良好的收敛性能。文献[75]提出了一种新的基于强化学习的资源分配算法, 利用 DDPG

算法, 在 MEC 服务器上设计了一种实时自适应算法来分配计算资源和传输资源, 用于任务卸载。仿真实验表明, 对于不同的任务到达概率, 所提出的算法能够在消耗更少的能量的同时取得更好的任务卸载性能。文献[76]研究了一种联合资源优化方案, 以解决车载网络环境的动态和不可预测问题, 为网络运营商增加收益。此外, 还提出了双尺度深度强化学习 (double-scale deep reinforcement learning, DSDRL) 框架, 可以降低动作空间维度以解决复杂的联合优化问题, 满足不同服务的不同需求, 降低成本。文献[77]研究了无人机辅助车辆网络的多维资源管理, 将 MEC 服务器上的资源分配描述为一个分布式优化问题, 以在满足异构服务质量要求的同时最大化卸载任务的数量, 然后使用 MADDPG 方法进行解决, 并通过仿真验证所提方案的优越性。

表 4 从 AI 算法、优化内容、贡献方面总结了 AI 算法在服务器部署方面的应用。

1.3.2 车联网联合考虑计算资源分配和卸载决策方面

AI 算法在联合考虑计算资源分配和卸载决策方面的应用, 大多数为根据具体需求, 如长期效用或时延等, 提出优化问题并将其建模为马尔可夫模型, 利用深度强化学习算法求解。其中, 在根据任务的优先级和计算大小对任务进行分类时, 可以采用如 SAC 的深度强化学习算法进行分类, 优化分配功率, 并利用 AI 算法 (如 DQN 等) 进行计算资源的分配。此外, 还可以将数字孪生技术和 AI 算法结合应用到车联网, 通过评估镜像边缘计算系统中的协作增益, 集中利用潜在的边缘服务匹配, 同时多智能体深度强化学习方法中分布式调度计算任务卸载和边缘资源分配。下面进行具体介绍。

AI 算法在联合考虑计算资源分配和卸载决策方面情况如下。文献[78]提出了一个基于 Q-learning 的智能节点选择卸载算法, 解决了任务卸载以及



表 4 AI 算法在通信和计算资源联合分配方面的应用

文献	算法	优化内容	计算资源	卸载类型	贡献
文献[70]	Q-learning	计算量 时延	任务车辆 MEC 服务器	部分卸载	提出了基于 Q-learning 的通信与计算联合资源分配算法, 缓解异构车联网架构下计算量大、低时延车载应用与车辆有限且不均的资源分布之间的矛盾
文献[71]		时延 可靠性	任务车辆 MEC 服务器 云服务器	全部卸载	在移动边缘计算层采用 Q-learning 实现通信和计算资源的分配的最优解, 有效地降低了系统总成本
文献[72]	DQN	吞吐量	任务车辆 MEC 服务器		采用 DQN 算法优化波束宽度设计, 使得在满足车辆之间公平性的同时系统吞吐量最大
文献[73]		服务成本	任务车辆 MEC 服务器 服务车辆		提出了一种基于 DQN 的 VEC 网络协作数据调度方案, 该方法可以有效地优化数据调度, 以最小化数据丢失
文献[74]			无人机		提出了一种基于 DQN 的无人机临时辅助 VECN 信道分配和任务卸载策略方案, 无人机基于 DQN 算法选择最优任务处理策略
文献[75]	DDPG	能耗 卸载性能	任务车辆 MEC 节点		利用 DDPG, 在 MEC 服务器上设计了一种实时自适应算法来分配计算资源和传输资源, 提高了长期平均任务成功率和发射功率
文献[76]	SAC、PPO	服务成本	任务车辆 MEC 服务器 服务车辆		提出了 DSDRL 框架进行联合资源优化, 可以满足不同服务的不同需求, 降低成本
文献[77]	MADDPG	时延	MEC 服务器 (在无人机上安装)		采用 MADDPG 对每个 MEC 服务器的决策方案进行优化, 使每个 MEC 服务器实时进行车辆关联和资源分配

计算资源分配的问题。文献[79]提出了一种基于 MEC 的 V2X 任务卸载和资源分配机制, 通过初始卸载节点的选择、计算卸载决策、无线资源和计算资源的合理分配来最小化系统开销。文献[80]首先探讨了一种车辆作为移动边缘服务器为附近终端提供计算服务的车辆边缘计算网络体系结构。在此基础上, 提出了考虑计算任务时延的车辆辅助卸载方案以及使车辆边缘计算网络的长期效用最大化的优化问题, 并利用 Q-learning 和深度强化学习两种强化学习方法, 以获得最优的计算卸载和资源分配策略。文献[81]提出了联合考虑移动车辆网络中的通信和计算资源来解决任务卸载问题。该文献提出了一个非线性问题, 以最小化网络资源的能量消耗。此外, 还考虑了一个实际的车辆环境和移动车辆网络的动力学, 通过一种基于 DQN 的方法解决所提出的问题。最后通过数值计算验证了该方法的有效性。文献[82]针对空间辅助车辆网络(space-assisted vehicular network,

SAVN) 中的计算卸载问题, 提出了一种基于异步联合 DQN 和超可靠低时延通信(ultra-reliable and low-latency communication, URLLC)感知的计算卸载算法(ASTEROID), 以在考虑长期 URLLC 约束的情况下实现吞吐量最大化。文献[83]提出了一种基于优先级敏感的车联网任务卸载和资源分配方案, 该方法通过激励车辆与任务车辆共享空闲的计算资源, 设计了一种基于 SAC 的深度强化学习算法, 根据任务的优先级和计算量对任务进行分类, 实现功率的最优分配。此外, 还设计了 DDPG 和双时延 DDPG 算法, 通过最大化所考虑的网络的平均效用, 实现了任务卸载的最优策略, 验证了分布式强化学习在未来车联网中任务卸载的可行性。文献[84]提出了一种车辆雾计算(vehicular fog computing, VFC)中的 V2V 部分卸载方案, 即计算资源有限的车辆可以将部分任务卸载给计算资源空闲的相邻车辆。该文献将 V2V 部分卸载问题归结为一个序列决策问题, 采用基

于柔性动作—评价的部分卸载 (soft actor-critic-based partial offloading, SBPO) 进行求解, 仿真表明, 与其他算法 (如随机卸载、贪婪卸载) 相比, 该文献提出的算法具有更好的性能。文献[85]提出了一种任务类型与车辆速度感知相结合的任务卸载与资源分配策略, 在任务时延、计算资源和无线资源的约束下, 制定任务卸载和资源分配的联合优化方案, 使车辆的效用最大化。为了获得问题的近似最优解, 提出了一种基于多智能体深度确定性策略梯度的联合卸载和资源分配 (joint offloading and resource allocation based on the multi-agent deep deterministic policy gradient, JORA-MADDPG) 算法, 以实现车辆效用水平的最大化。文献[86]将数字孪生技术与人工智能结合, 设计了一个高效的车辆边缘计算网络, 还开发了一种基于重力模型的数字孪生车辆聚合方案, 并基于 MADDPG 提出了相应的多智能体学习算法来优化边缘资源调度。文献[87]提出了一种基于雾的车辆网络 (fog-based vehicular network, FVNET) 的端边云协作模式, 将具有闲置资源的车辆作为雾用户设备 (fog user equipment, F-UE), 并将联合通信和计算资源分配问题转化为多智能体随机博弈, 提出了一种基于深度强化学习的多智能体分布式算法, 以最小化时延总和。

2 AI 算法在车联网通算融合中的未来研究方向

AI 算法在车联网通算中的未来研究方向有以下几个方面。

(1) 无人机辅助覆盖重叠、协同通信协议

未来无人机辅助车联网在研究覆盖重叠、中继选择、能量采集通信、无人机协同通信协议等方面都有很大的发展前景。例如, 可以将多架无人机组成中继网络, 通过建模中继网络和车辆网络的机动性和状态转换, 针对无人机辅助车联网的覆盖重叠/概率问题或者协同通信下的吞吐量

或安全性问题, 考虑无人机回程稳定性对整体系统的影响、动态环境中实现 UAV 之间的无缝切换问题, 利用多智能体强化学习算法进行优化解决。此外, 星地飞行器网络的任务卸载和资源管理问题也是未来要研究的一个方向。

(2) 结合 ES 性能和 QoS 的新的服务器部署

由于车联网的动态变化, 以及不同区域和时间段车辆或终端对计算和通信服务的需求不同, ES 在不同地方的计算能力不同。未来可以结合 AI 算法, 在 ES 计算能力不同的地方设置一种新的 ES 量化和放置方法, 提高 QoS。此外, 在异构车联网中, 综合考虑不同服务的多种 QoS 要求的 RSU 部署问题也需要进一步的研究, 如一些对时延敏感的实时业务, 需要提供低时延的 QoS 服务, 而其他一些普通业务或大数据量业务, 则对丢包率比较敏感。

(3) AI 算法在 RSU 部署的广泛应用

目前车联网中服务器部署的研究大多利用遗传算法, 只有少部分研究从深度强化学习的角度考虑, 且部分遗传算法需要多次迭代, 计算时间过长, 未来需要将更多 AI 算法应用到服务器部署, 提高部署效率, 减小网络时延和开销。

(4) 建立服务车辆辅助计算的组织和系统

针对任务车辆的计算卸载, 周围有空闲资源车辆的辅助十分重要, 若能合理利用周围车辆的计算资源, 实现高效的动态规划, 可以进一步提高车联网计算卸载能力。例如可以成立一个组织, 将该组织的车辆的用户信息都进行登记, 并参考用户终端之间的社会关系设立安全等级和服务报酬, 并且这些车辆的计算能力实时上传更新, 需要服务的车辆可以向组织发送请求, 使有空闲资源的车辆可以提供资源给目标, 提供资源的一方也可以从接受服务方收取一定的报酬。但是这样的组织建立是困难的, 随着服务进行, 所需处理的信息量巨大, 需要一定的时间和一个好的规划。未来可以进一步研究特定任务下的任务卸载决策和资源分配, 以及算



法在复杂车辆行为（如车辆加速、减速、超车和换道）中的适用性和改进方法。

（5）VEC 的安全与隐私问题

由于车载边缘计算的开放性，用户的数据安全和隐私问题的解决变得尤为重要，如 V2V 中，任务车辆将任务卸载到服务车辆，服务车辆的选取会产生一些安全隐私问题，需要在未来的工作中进一步研究解决。目前，安全漏洞是通过使用相同地址的数据包的范围来估计的，这明显受数据包到达率的影响。在未来工作中，将引入新的安全指标，这些指标可以在调整移动目标防御（moving target defense, MTD）触发间隔时捕获攻击者的实际安全漏洞，增强车载网络的安全性。

（6）提高 AI 算法在实践中的性能

仿真中的参数取值方面模拟性质较强，可能导致理论值与真实情况存在一定的偏差。现在大部分文献仅限于使用一些虚拟交通数据进行仿真评估，未来需要尽可能运用真实的交通数据，通过搭建硬件平台获取实际数据，基于实际数据对多设备、多资源下的计算通信资源分配问题与任务卸载决策问题进行研究，提出更具有普适性的联合任务卸载与资源分配的算法，以增强算法的实践性能。

（7）多智能体的 DRL 算法应用和模型改进

未来可以设计更复杂的车联网场景模型，利用多智能体强化学习算法，在动态、复杂的模型中学习最佳计算、卸载策略，以进一步提高车联网的性能。在网络切片中的资源分配方面，部署在网络切片中用于资源分配和 MTD 触发决策的基于多智能体的 DRL 方法比基于单个智能体的 DRL 方法更有效。因为智能体之间的信息交换可以提高视图和策略的同步性，从而使每个 DRL 代理在减少不确定性的情况下做出更有效的决策。

（8）车路协同优化及其隐私问题的解决

车路协同推断把深度网络切分成两部分，分别由车载终端和路侧边缘服务器进行存储和执

行，两者协作完成深度网络的推断。车路协同推断可以提高推断效率，但是存在隐私问题。攻击者在不知道车载终端网络结构的前提下，仍可复原车载终端上传的计算结果对应的图像数据，从而发起图像还原攻击。未来工作可以进一步研究车路协同推断的隐私问题，结合传输压缩等方法，设计更有效的防御算法，同时提高车路协同推断的效率和精确度。

（9）车辆网络的切片选择和覆盖问题

未来在车辆互联网网络中的切片选择、覆盖选择、资源块和非正交多址功率分配问题上，可以研究一种双时间尺度 DRL 方法。该方法在较慢的时间尺度上决定覆盖和切片选择，并且未来还可以研究多切片的公平性问题，利用 AI 算法智能地调配切片资源，高效解决业务需求高动态下的切片选择问题。

3 结束语

本文主要针对 AI 算法在车联网通信计算的应用层面进行了系统性的调研。首先，介绍了车联网的背景、通算一体化网络以及 AI 算法的内容；然后，从通信、计算卸载、通算融合方面归纳总结了 AI 算法的应用；最后，对 AI 算法在车联网领域的应用进行了展望，从几个方面提出了改进和思考的方向。

参考文献：

- [1] 龚媛嘉, 孙海波. 车联网系统综述[J]. 中国新通信, 2021, 23(17): 51-52.
GONG Y J, SUN H B. An overview of internet of vehicles systems[J]. China New Telecommunications, 2021, 23(17):51-52.
- [2] 陈山枝, 葛雨明, 时岩. 蜂窝车联网 (C-V2X) 技术发展、应用及展望[J]. 电信科学, 2022, 38(1):1-12.
CHEN S Z, GE Y M, SHI Y. Technology development, application and prospect of cellular vehicle-to-everything (C-V2X)[J]. Telecommunications Science, 2022, 38(1):1-12.
- [3] CHEN S Z, HU J L, SHI Y, et al. A vision of C-V2X: technologies, field testing, and challenges with chinese development[J]. IEEE Internet of Things Journal, 2020, 7(5): 3872-3881.

- [4] LIU G, LI N, DENG J, et al. The SOLIDS 6G mobile network architecture: driving forces, features, and functional topology[J]. *Engineering*, 2022, 8(1): 42-59.
- [5] 孙韶辉, 戴翠琴, 徐晖, 等. 面向 6G 的星地融合一体化组网研究[J]. *重庆邮电大学学报(自然科学版)*, 2021, 33(6): 891-901.
SUN S H, DAI C Q, XU H, et al. Survey on satellite-terrestrial integration networking towards 6G[J]. *Journal of Chongqing University of Posts and Telecommunications (Natural Science edition)*, 2021, 33(6): 891-901.
- [6] LIU G Y, HUANG Y H, LIN, et al. Vision, requirements and network architecture of 6G mobile network beyond 2030[J]. *IEEE China Communications*, 2020, 17(9): 92-104.
- [7] LIU Y Q, PENG M G, SHOU G C, et al. Toward edge intelligence: multiaccess edge computing for 5G and internet of things[J]. *IEEE Internet of Things Journal*, 2020, 7(8): 6722-6747.
- [8] 徐堂炜, 张海璐, 刘楚, 等. 基于强化学习的低时延车联网群密钥分配管理技术[J]. *网络与信息安全学报*, 2020, 6(5): 119-125.
XU T W, ZHANG H L, LIU C, et al. Reinforcement learning based group key agreement scheme with reduced latency for VANET[J]. *Chinese Journal of Network and Information Security*, 2020, 6(5): 119-125.
- [9] WANG D, ZHANG Q, LIU J, et al. A novel QoS-aware grid routing protocol in the sensing layer of Internet of vehicles based on reinforcement learning[J]. *IEEE Access*, 2019(7): 185730-185739.
- [10] PENG Y, LIU L, ZHOU Y, et al. Deep reinforcement learning-based dynamic service migration in vehicular networks[C]//*Proceedings of 2019 IEEE Global Communications Conference (GLOBECOM)*. Piscataway: IEEE Press, 2019: 1-6.
- [11] CHOE C, CHOI J, AHN J, et al. Multiple channel access using deep reinforcement learning for congested vehicular networks[C]//*Proceedings of 2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring)*. Piscataway: IEEE Press, 2020: 1-6.
- [12] ATALLAH R F, ASSI C M, KHABBAZ M J. Scheduling the operation of a connected vehicular network using deep reinforcement learning[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 20(5): 1669-1682.
- [13] AOKI S, HIGUCHI T, ALTINTAS O. Cooperative perception with deep reinforcement learning for connected vehicles[C]//*Proceedings of 2020 IEEE Intelligent Vehicles Symposium (IV)*. Piscataway: IEEE Press, 2020: 328-334.
- [14] 俞建业, 戚湧, 王宝茁. 基于 Spark 的车联网分布式组合深度学习入侵检测方法[J]. *计算机科学*, 2021, 48(6A): 518-523.
- [15] YU J Y, QI Y, WANG B Z. Distributed combination deep learning intrusion detection method for internet of vehicles based on Spark[J]. *Computer Science*, 2021, 48(6A): 518-523.
- [16] 吴茂强, 黄旭民, 康嘉文. 面向车路协同推断的差分隐私保护方法[J]. *计算机工程*, 2022, 48(7): 29-35.
WU M Q, HUANG X M, KANG J W, et al. Differential privacy protection methods for vehicle-road collaborative inference[J]. *Computer Engineering*, 2022, 48(7): 29-35.
- [17] 李明磊, 章阳, 康嘉文, 等. 基于多智能体强化学习的区块链赋能车联网中的安全数据共享[J]. *广东工业大学学报*, 2021, 38(6): 62-69.
LI M L, ZHANG Y, KANG J W, et al. Multi-agent reinforcement learning for secure data sharing in blockchain-empowered vehicular networks[J]. *Journal of Guangdong University of Technology*, 2021, 38(6): 62-69.
- [18] ZHANG D, YU F R, YANG R, et al. A deep reinforcement learning-based trust management scheme for software-defined vehicular networks[C]//*Proceedings of the 8th ACM Symposium on Design and Analysis of Intelligent Vehicular Networks and Applications*. New York: ACM Press, 2018: 1-7.
- [19] YOON S, CHO J H, KIM D S, et al. DESOLATER: deep reinforcement learning-based resource allocation and moving target defense deployment framework[J]. *IEEE Access*, 2021(9): 70700-70714.
- [20] ZHOU Y, TANG F, KAWAMOTO Y, et al. Reinforcement learning-based radio resource control in 5G vehicular network[J]. *IEEE Wireless Communications Letters*, 2019, 9(5): 611-614.
- [21] 陈九九, 冯春燕, 郭彩丽, 等. 车联网中视频语义驱动的资源分配算法[J]. *通信学报*, 2021, 42(7): 1-11.
CHEN J J, FENG C Y, GUO C L, et al. Video semantics-driven resource allocation algorithm in internet of vehicles[J]. *Journal of Communication*, 2021, 42(7): 1-11.
- [22] YE S, XU L, LI X. Vehicle-mounted self-organizing network routing algorithm based on deep reinforcement learning[J]. *Wireless Communications and Mobile Computing*, 2021(2021): 9934585:1-9.
- [23] MLIKA Z, CHERKAOU S. Network slicing with MEC and deep reinforcement learning for the internet of vehicles[J]. *IEEE Network*, 2021, 35(3): 132-138.
- [24] 王晓昌, 吴璠, 孙彦赞, 等. 基于深度强化学习的车联网资源管理[J]. *工业控制计算机*, 2021, 34(9): 31-33, 36.
WANG X C, WU P, SUN Y Z, et al. Internet of vehicles resource management based on deep reinforcement learning[J]. *Industrial Personal Computer*, 2021, 34(9): 31-33, 36.



- [24] 王晓昌, 吴璠, 孙彦赞, 等. 基于联邦深度强化学习的车联网网资源分配[J]. 电子测量技术, 2021, 44(10): 114-120.
WANG X C, WU P, SUN Y Z, et al. Internet of vehicles resource management based on federal deep reinforcement learning[J]. Electronic Measurement Technology Journals, 2021, 44(10): 114-120.
- [25] YE H, LI G Y. Deep reinforcement learning for resource allocation in V2V communications[C]//Proceedings of 2018 IEEE International Conference on Communications (ICC). Piscataway: IEEE Press, 2018: 1-6.
- [26] GYAWALI S, QIAN Y, HU R. Resource allocation in vehicular communications using graph and deep reinforcement learning[C]//Proceedings of 2019 IEEE Global Communications Conference (GLOBECOM). Piscataway: IEEE Press, 2019: 1-6.
- [27] CHEN X, WU C, CHEN T, et al. Age of information aware radio resource management in vehicular networks: a proactive deep reinforcement learning perspective[J]. IEEE Transactions on Wireless Communications, 2020, 19(4): 2268-2281.
- [28] QIAO G, LENG S, MAHARIAN S, et al. Deep reinforcement learning for cooperative content caching in vehicular edge computing and networks[J]. IEEE Internet of Things Journal, 2019, 7(1): 247-257.
- [29] ZHU M, LIU X Y, WANG X. Deep reinforcement learning for unmanned aerial vehicle-assisted vehicular networks[J]. arXiv Preprint, 2019, arXiv, 1906.05015.
- [30] 韩双双, 李卓珩, 杨林瑶, 等. 基于强化学习和非正交多址接入的车联网无线资源分配[C]//2019 中国自动化大会(CAC2019)论文集. [出版地不详: 出版者不详], 2019: 360-365.
HAN S S, LI Z X, YANG L Y. Wireless resource allocation in vehicular networks based on reinforcement learning and NOMA[C]//Proceedings of the China Automation Congress(CAC2019). [S.l.: s.n.], 2019: 360-365.
- [31] SHARIF A, LI J, SALEEM M A, et al. A dynamic clustering technique based on deep reinforcement learning for internet of vehicles[J]. Journal of Intelligent Manufacturing, 2021, 32(3): 757-768.
- [32] 黄煜楚, 彭诺衡, 林艳, 等. 基于 SAC 强化学习的车联网频谱资源动态分配[J]. 计算机工程, 2021, 47(9): 34-43.
HUANG Y F, PENG N H, LIN Y, et al. Dynamic spectrum resource allocation in internet of vehicles based on SAC reinforcement learning[J]. Computer Engineering, 2021, 47(9): 34-43.
- [33] TIAN J, LIU Q, ZHANG H, et al. Multi-agent deep reinforcement learning based resource allocation for heterogeneous QoS guarantees for vehicular Networks[J]. IEEE Internet of Things Journal, 2021, 9(3): 1683-1695.
- [34] 陈成瑞, 孙宁, 何世彪, 等. 面向 C-V2X 通信的基于深度学习的联合信道估计与均衡算法[J]. 计算机应用, 2021, 41(9): 2687-2693.
CHEN C R, SUN N, HE S B, et al. Deep learning-based joint channel estimation and equalization algorithm for C-V2X communications[J]. Journal of Computer Applications, 2021, 41(9): 2687-2693.
- [35] 廖勇, 田肖懿, 蔡志镨. 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.
- [36] ZHAO N, WU H, YU F R, et al. Deep-reinforcement-learning-based latency minimization in edge intelligence over vehicular networks[J]. IEEE Internet of Things Journal, 2021, 9(2): 1300-1312.
- [37] 王汝言, 梁颖杰, 崔亚平. 车辆网络多平台卸载智能资源分配算法[J]. 电子与信息学报, 2020, 42(1): 263-270.
WANG R Y, LIANG Y J, CUI Y P. Intelligent resource allocation algorithm for multi-platform offloading in vehicular networks[J]. Journal of Electronics & Information Technology, 2020, 42(1): 263-270.
- [38] ZHANG Y, ZHANG M, FAN C, et al. Computing resource allocation scheme of IoV using deep reinforcement learning in edge computing environment[J]. EURASIP Journal on Advances in Signal Processing, 2021, 2021(1): 1-19.
- [39] LEE S-S, LEE S. Resource allocation for vehicular fog computing using reinforcement learning combined with heuristic information[J]. IEEE Internet of Things Journal, 2020, 7(10): 10450-10464.
- [40] XIAO H, QIU C, YANG Q, et al. Deep reinforcement learning for optimal resource allocation in blockchain-based IoV secure systems[C]//Proceedings of 2020 16th International Conference on Mobility, Sensing and Networking (MSN). [S.l.: s.n.], 2020: 137-144.
- [41] 董晓丹, 吴琼. 车载云计算系统中资源分配的优化方法[J]. 中国电子科学研究院学报, 2020, 15(1): 92-98.
DONG X D, WU Q. Optimization method of resource allocation in vehicular cloud computing system[J]. Journal of China Academy of Electronics and Information Technology, 2020, 15(1): 92-98.
- [42] 李振江, 张幸林. 减少核心网拥塞的边缘计算资源分配和卸载决策[J]. 计算机科学, 2021, 48(3): 281-288.
LI Z J, ZHANG X L. Resource allocation and offloading decision of edge computing for reducing core network congestion[J]. Computer Science, 2021, 48(3): 281-288.

- [43] GAO D. Computing resource allocation strategy based on mobile edge computing in internet of vehicles environment[J]. *Mobile Information Systems*, 2022(2): 1-10.
- [44] LIN X, WU J, MUMTAZ S, et al. Blockchain-based on-demand computing resource trading in IoV-assisted smart city[J]. *IEEE Transactions on Emerging Topics in Computing*, 2020, 9(3): 1373-1385.
- [45] 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 H B, JING K L, LIU K J, 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.
- [46] 张海波, 刘香渝, 荆昆仑, 等. 车联网中基于NOMA-MEC的卸载策略研究[J]. *电子与信息学报*, 2021, 43(4): 1072-1079.
- ZHANG H B, LIU X Y, JING K L, et al. Research on NOMA-MEC-based offloading strategy in internet of vehicles[J]. *Journal of Electronics & Information Technology*, 2021, 43(4): 1072-1079.
- [47] LI F, LIN Y, PENG N, et al. Deep reinforcement learning based computing offloading for MEC-assisted heterogeneous vehicular networks[C]//*Proceedings of 2020 IEEE 20th International Conference on Communication Technology (ICCT)*. Piscataway: IEEE Press, 2020: 927-932.
- [48] 赵海涛, 张唐伟, 陈跃, 等. 基于 DQN 的车载边缘网络任务分发卸载算法[J]. *通信学报*, 2020, 41(10): 172-178.
- ZHAO H T, ZHANG T W, CHEN Y, et al. Task distribution offloading algorithm of vehicle edge network based on DQN[J]. *Journal on Communications*, 2020, 41(10): 172-178.
- [49] LI M, GAO J, ZHAO L, et al. Deep reinforcement learning for collaborative edge computing in vehicular networks[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2020, 6(4): 1122-1135.
- [50] DAI Y, ZHANG K, MAHARJAN S, et al. Edge intelligence for energy-efficient computation offloading and resource allocation in 5G beyond[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(10): 12175-12186.
- [51] ZHAN W, LUO C, 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.
- [52] LIU H, ZHAO H, GENG L, et al. A policy gradient based offloading scheme with dependency guarantees for vehicular networks[C]//*Proceedings of 2020 IEEE Globecom Workshops (GC Wkshps)*. Piscataway: IEEE Press, 2020: 1-6.
- [53] WANG J, LV T, HUANG P, et al. Mobility-aware partial computation offloading in vehicular networks: a deep reinforcement learning based scheme[J]. *China Communications*, 2020, 17(10): 31-49.
- [54] 许小龙, 方子介, 齐连永, 等. 车联网边缘计算环境下基于深度强化学习的分布式服务卸载方法[J]. *计算机学报*, 2021, 44(12): 2382-2405.
- XU X L, FANG Z J, QI L Y, et al. A deep reinforcement learning-based distributed service offloading method for edge computing empowered internet of vehicles[J]. *Journal of Computer Science and Technology*, 2021, 44(12): 2382-2405.
- [55] TANG D, ZHANG X, LI M, et al. Adaptive inference reinforcement learning for task offloading in vehicular edge computing systems[C]//*Proceedings of 2020 IEEE International Conference on Communications Workshops (ICC Workshops)*. Piscataway: IEEE Press, 2020: 1-6.
- [56] ZHAO T, LIU Y, SHOU G, et al. Joint latency and energy consumption optimization with deep reinforcement learning for proximity detection in road networks[C]//*Proceedings of 2021 7th International Conference on Computer and Communications (ICCC)*. Piscataway: IEEE Press, 2021: 1272-1277.
- [57] 刘国志, 代飞, 莫启, 等. 车辆边缘计算环境下基于深度强化学习的任务卸载方法[J]. *计算机集成制造系统*, 2022, 28(10): 3304-3315.
- LIU G Z, DAI F, MO Q, et al. A service offloading method with deep reinforcement learning in edge computing empowered internet of vehicles[J]. *Computer Integrated Manufacturing Systems*, 2022, 28(10): 3304-3315.
- [58] SHI J, DU J, WANG J, et al. Distributed V2V computation offloading based on dynamic pricing using deep reinforcement learning[C]//*Proceedings of 2020 IEEE Wireless Communications and Networking Conference(WCNC)*. Piscataway: IEEE Press, 2020: 1-6.
- [59] KE H, WANG J, DENG L, et al. Deep reinforcement learning-based adaptive computation offloading for MEC in heterogeneous vehicular networks[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(7): 7916-7929.
- [60] GENG L, ZHAO H, LIU H, et al. Deep reinforcement learning-based computation offloading in vehicular networks[C]//*Proceedings of 2021 8th IEEE International Conference on Cyber Security and Cloud Computing (CSCloud)/2021 7th IEEE International Conference on Edge Computing and Scalable Cloud (EdgeCom)*. Piscataway: IEEE Press, 2021: 200-206.
- [61] ZHAN W, LUO C, WANG J, et al. Deep reinforcement learning-based computation offloading in vehicular edge computing[C]//*Proceedings of 2019 IEEE Global Communications Conference (GLOBECOM)*. Piscataway: IEEE Press, 2019: 1-6.



- [62] 杨志和, 鲁凌云. 基于强化学习的车辆编队动态定价任务卸载策略[J]. 电子技术与软件工程, 2022(5): 45-51.
- YANG Z H, LU L Y. Task offloading strategy of vehicle platoon dynamic pricing based on reinforcement learning[J]. Electronic Technology & Software Engineering, 2022(5): 45-51.
- [63] NI Y, HE J, CAI L, et al. Joint roadside unit deployment and service task assignment for internet of vehicles (IoV)[J]. IEEE Internet of Things Journal, 2018, 6(2): 3271-3283.
- [64] WU Z, LU Z, HUNG P C K, et al. QaMeC: a QoS-driven IoVs application optimizing deployment scheme in multimedia edge clouds[J]. Future Generation Computer Systems, 2019(92): 17-28.
- [65] SHEN B, XU X, QI L, et al. Dynamic server placement in edge computing toward internet of vehicles[J]. Computer Communications, 2021(178): 114-123.
- [66] XU X, SHEN B, YIN X, et al. Edge server quantification and placement for offloading social media services in industrial cognitive IoV[J]. IEEE Transactions on Industrial Informatics, 2020, 17(4): 2910-2918.
- [67] LU J, JIANG J, BALASUBRAMANIAN V, et al. Deep reinforcement learning-based multi-objective edge server placement in Internet of vehicles[J]. Computer Communications, 2022(187): 172-180.
- [68] LYU W, XU X, QI L, et al. GoDeep: intelligent IoV service deployment and execution with privacy preservation in cloud-edge computing[C]//Proceedings of 2021 IEEE International Conference on Web Services (ICWS). Piscataway: IEEE Press, 2021: 579-587.
- [69] KASI M K, ABU G S, AKRAM R N, et al. Secure mobile edge server placement using multi-agent reinforcement learning[J]. Electronics, 2021, 10(17): 2098.
- [70] 熊凯, 冷魁鹏, 张可, 等. 车联雾计算中的异构接入与资源分配算法研究[J]. 物联网学报, 2019, 3(2): 20-27.
- XIONG K, LENG S P, ZHANG K, et al. Research on heterogeneous radio access and resource allocation algorithm in vehicular fog computing[J]. Chinese Journal on Internet of Things, 2019, 3(2): 20-27.
- [71] CUI Y, DU L, WANG H, et al. Reinforcement learning for joint optimization of communication and computation in vehicular networks[J]. IEEE Transactions on Vehicular Technology, 2021, 70(12): 13062-13072.
- [72] HE Y, ZHAO N, YIN H. Integrated networking, caching, and computing for connected vehicles: a deep reinforcement learning approach[J]. IEEE Transactions on Vehicular Technology, 2017, 67(1): 44-55.
- [73] LUO Q, LI C, LUAN T H, et al. Collaborative data scheduling for vehicular edge computing via deep reinforcement learning[J]. IEEE Internet of Things Journal, 2020, 7(10): 9637-9650.
- [74] YANG C, LIU B, LI H, et al. Learning based channel allocation and task offloading in temporary UAV-assisted vehicular edge computing networks[J]. IEEE Transactions on Vehicular Technology, 2022, 71(9): 9884-9895.
- [75] TAN G, ZHANG H, ZHOU S, et al. Resource allocation in MEC-enabled vehicular networks: a deep reinforcement learning approach[C]//Proceedings of IEEE INFOCOM 2020 - IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS). Piscataway: IEEE Press, 2020:406-411.
- [76] LYU Z, WANG Y, LYU M, et al. Service-driven resource management in vehicular networks based on deep reinforcement learning[C]//Proceedings of 2020 IEEE 31st Annual International Symposium on Personal, Indoor and Mobile Radio Communications. Piscataway: IEEE Press, 2020: 1-6.
- [77] PENG H, SHEN X. Multi-agent reinforcement learning based resource management in MEC-and UAV-assisted vehicular networks[J]. IEEE Journal on Selected Areas in Communications, 2020, 39(1): 131-141.
- [78] 张家波, 吕洁娜, 甘臣权, 等. 一种基于强化学习的车联网边缘计算卸载策略[J]. 重庆邮电大学学报(自然科学版), 2022, 34(3): 525-534.
- ZHANG J B, LYU J N, GAN C Q, et al. A reinforcement learning-based offloading strategy for internet of vehicles edge computing[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science edition), 2022, 34(3): 525-534.
- [79] 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 H B, WANG Z X, HE X F. V2X offloading and resource allocation under SDN and MEC architecture[J]. Journal of communication, 2020, 41(01): 114-124.
- [80] LIU Y, YU H, XIE S, 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.
- [81] KZAMI S. M. A., OTOUM S, HUSSAIN R, et al. A novel deep reinforcement learning-based approach for task-offloading in vehicular networks[C]//Proceedings of 2021 IEEE Global Communications Conference (GLOBECOM). Piscataway: IEEE Press, 2021: 1-6.
- [82] PAN C, WANG Z, LIAO H J, et al. Asynchronous federated deep reinforcement learning-based URLLC-aware computation offloading in space-assisted vehicular networks[J]. IEEE Transactions on Intelligent Transportation Systems, 2022: 1-13.
- [83] HAZARIKA B, SINGH K, BISWAS S, et al. DRL-based resource allocation for computation offloading in IoV networks[J]. IEEE Transactions on Industrial Informatics, 2022, 18(11): 8027-8038.
- [84] SHI J, DU J, WANG J, et al. Deep reinforcement learning-based V2V partial computation offloading in vehicular fog computing[C]//Proceedings of 2021 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2021: 1-6.

- [85] HUANG X, HE L, CHEN X, 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.
- [86] ZHANG K, CAO J, ZHANG Y, et al. Adaptive digital twin and multiagent deep reinforcement learning for vehicular edge computing and networks[J]. IEEE Transactions on Industrial Informatics, 2022, 18(2): 1405-1413.
- [87] ZHANG X, PENG M, YAN S, et al. Joint communication and computation resource allocation in fog-based vehicular networks[J]. IEEE Internet of Things Journal, 2022, 9(15): 13195-13208.

[作者简介]



康宇（1999—），男，北京邮电大学硕士生，主要研究方向为边缘计算、车联网和边缘智能。



刘雅琼（1988—），女，博士，北京邮电大学副教授，主要研究方向为边缘计算、车联网和边缘智能。



赵彤雨（1998—），女，北京邮电大学硕士生，主要研究方向为边缘计算、物联网和边缘智能。



寿国础（1965—），男，博士，北京邮电大学教授，主要研究方向为接入网络与边缘计算、光纤与无线网络虚拟化、网络构建与路由、移动互联网与应用等。